

La perspectiva arxivística i de gestió documental en l'avaluació de les dimensions de qualitat de les dades obertes: una proposta teòrica i metodològica

Sònia Torreblanca Valverde



Com citar aquest article: Torreblanca Valverde, Sònia. (2021) *La perspectiva arxivística i de gestió documental en l'avaluació de les dimensions de qualitat de les dades obertes: una proposta teòrica i metodològica*. Treball de recerca del Màster d'Arxivística i Gestió de Documents de l'Escola Superior d'Arxivística i Gestió de Documents. (Treballs fi de Màster i de postgrau). [Http://...](http://...) (consultat el ...)

Director/s del treball: Raimon Nualart Mercadé i Remo Suppi Boldrito

Màster en Arxivística i Gestió Documental
Escola Superior d'Arxivística i Gestió de Documents
Col·lecció: Treballs fi de màster i de postgrau

ISBN: 13: 978-84-09-49504-7

Data: Curs 2020/2021



Aquesta obra està subjecta a llicència Creative Commons Reconeixement-NoComercial-SenseObraDerivada 3.0 Espanya (<http://creativecommons.org/licenses/by-nc-nd/3.0/es/legalcode.ca>). Es permet la reproducció total o parcial i la comunicació pública de l'obra, sempre que no sigui amb finalitats comercials, i sempre que es reconegui l'autoria de l'obra original. No es permet la creació d'obres derivades.

La perspectiva arxivística i de gestió documental en l'avaluació de les dimensions de qualitat de les dades obertes: una proposta teòrica i metodològica

3



Resum

La present investigació proposa un model conceptual, lògic i metodològic per avaluar les dimensions de qualitat de les dades obertes, a partir de l'articulació de quatre àmbits d'estudi: l'arxivística i la gestió documental, la gestió de les dades, la teoria sistèmica i la teoria procedent de les dades obertes i el govern obert.

El Model de qualitat de les dades obertes, que representa una primera versió unificada de mètriques, pretén esdevenir una eina metodològica per a que les administracions i organitzacions puguin avaluar i conèixer el nivell assolit en relació amb la qualitat de les dades obertes.

Paraules clau:

Qualitat, dades obertes, model, metodologia, mètriques, avaluació, dimensions, indicadors, mesurament, conjunt de dades.

La perspectiva archivística y de gestión documental en la evaluación de las dimensiones de calidad de los datos abiertos: una propuesta teórica y metodológica

Resumen

La presente investigación propone un modelo conceptual, lógico y metodológico para evaluar las dimensiones de calidad de los datos abiertos, a partir de la articulación de cuatro ámbitos de estudio: la archivística y la gestión documental, la gestión de los datos, la teoría sistémica y la teoría procedente de los datos abiertos y el gobierno abierto.

El Modelo de calidad de los datos abiertos, que representa una primera versión unificada de métricas, pretende convertirse en una herramienta metodológica para que las administraciones y organizaciones puedan evaluar y conocer el nivel alcanzado en relación con la calidad de los datos abiertos.

Palabras clave:

Calidad, datos abiertos, modelo, metodología, métricas, evaluación, dimensiones, indicadores, medición, conjuntos de datos.

The archival and document management perspective in the evaluation of the quality dimensions of open data: a theoretical and methodological proposal

5



Abstract

The present research proposes a conceptual, logical, and methodological model to evaluate the quality dimensions of open data, based on the articulation of four areas of study: records management, data management, systemic theory and theory from open data and open government.

The Open Data Quality Model, which represents a first unified version of metrics, aims to become a methodological tool for administrations and organizations to evaluate and know the level achieved in relation to the quality of open data.

Keywords:

Quality, open data, model, methodology, metrics, evaluation, dimensions, indicators, measurement, dataset.

Índex de continguts

Agraïments.....	8	1. 3. 1. Concepte, tipus i característiques dels sistemes.....	51
Introducció.....	9	1. 3. 1. 1. Sistemes cibernètics	55
1. Marc teòric i estat de la qüestió	13	1. 3. 2. Ecosistema de dades obertes, qualitat i cibernètica	57
1. 1. Marc teòric de l'arxivística i la gestió documental	13	1. 4. Marc teòric i metodològic de la gestió de les dades i de la qualitat de les mateixes (<i>data management & data quality management - DQM</i>)	66
1. 1. 1. Conceptes de document, informació i dades	13	1. 4. 1. Consideracions generals	66
1. 1. 2. De la gestió de documents a la governança arxivística de la informació	18	1. 4. 2. Conceptes de qualitat	66
1. 2. Marc teòric de les dades obertes (<i>open data - OD</i>)	24	1. 4. 3. Dimensions de qualitat de les dades (<i>data quality dimensions</i>).....	68
1. 2. 1. Context "Open": <i>open data i open government</i>	24	1. 4. 4. Aproximació a la gestió de la qualitat de les dades (<i>data quality management</i>)	73
1. 2. 2. Principis rectors de les dades obertes.....	29	1. 4. 5. Mesurament i avaluació de la qualitat de les dades	82
1. 2. 2. 1. Els principis de les dades obertes a l'ordenament jurídic espanyol	32	1. 4. 5. 1. Conceptes bàsics	82
1. 2. 3. Beneficis i barreres de l'obertura de dades obertes	35	1. 4. 5. 2. Mètriques i indicadors per avaluar les dimensions de qualitat de les dades	83
1. 2. 4. Polítiques de dades obertes i gestió documental	45	2. Proposta teòrica i metodològica per avaluar la qualitat de les dades obertes	85
1. 2. 5. Marc normatiu de referència	49	2. 1. Característiques bàsiques del model de qualitat de les dades obertes	85
1. 3. Marc teòric de la perspectiva sistèmica: teoria de sistemes i cibernètica.....	51		

2. 2. Marc de referència de les dimensions de qualitat de les dades obertes.....	87	3. 2. Justificació dels conjunts de dades seleccionats	192
2. 2. 1. Categories de la qualitat de les dades obertes.....	88	3. 3. Procés de mesurament	195
2. 2. 2. Dimensions i elements de la qualitat de les dades obertes	90	3. 3. 1. Consideracions bàsiques	195
2. 2. 2. 1. Consideracions de futur.....	117	3. 3. 2. Avaluació del dataset Codis postal per municipis de Catalunya.....	195
2. 2. 3. Ontologia de la qualitat de les dades obertes (ODQ)	118	3. 3. 3. Avaluació del dataset Comissaries	214
2. 3. Vocabulari de metadades per a la descripció de les dades obertes	119	3. 4. Anàlisi dels resultats	234
2. 4. Mesurament i avaluació de les dimensions de qualitat de les dades obertes.....	125	3. 5. Discussió i conclusions	237
2. 4. 1. Mètriques i indicadors per avaluar les dimensions de qualitat de les dades obertes.....	126	3. 5. 1. DAFO i propostes de millora.....	238
2. 4. 2. Pes de les mètriques i indicadors	189	Conclusions i línies de futur.....	242
2. 4. 3. Càlcul del valor final i del valor total	190	Bibliografia i fonts d'informació	244
2. 4. 4. Resum dels criteris de mesura dels elements ODQ.....	190	Bibliografia	244
3. Prova de concepte del model de qualitat de les dades obertes	191	Webgrafia	258
3. 1. Abast i limitacions de la prova de concepte	191	Legislació	262
		Annex.	
		Taula resum dels criteris de mesura.....	266
		Acrònims i abreviatures.....	270
		Índex de taules i figures.....	271

Agraïments

Agraeixo als directors del treball, en Raimon Nualart i en Remo Suppi, el seu suport, acompanyament i consells al llarg de tot el projecte.

També agraeixo al professorat i a la direcció de l'Escola Superior d'Arxivística i Gestió de Documents (ESAGED) el recolzament i l'estímul intel·lectual d'aquests darrers anys. Vull donar les gràcies a l'Ariadna, la Maria A., la Maria C., la Jessica, l'Oriol i en Guillem pels seus ànims durant l'elaboració del projecte.

La realització d'aquest llibre ha sigut possible gràcies a l'Associació de professionals de l'Arxivística i la Gestió de Documents de Catalunya (AAC) i l'ESAGED. Moltes gràcies per fomentar la recerca en l'àmbit de l'arxivística i la gestió de documents.

Així mateix, el projecte d'investigació no hagués estat possible sense la confiança, l'amor i la comprensió de l'Ander i la Sara. Per últim, agrair a la meva família el seu suport incondicional, molt especialment a la meva mare, a qui li dedico el llibre.

Barcelona, setembre de 2022

La present investigació se centra en l'estudi de les dimensions de qualitat de les dades (obertes) a fi d'elaborar un model teòric i metodològic de qualitat de les dades obertes (*open data quality* – ODQ, en anglès), la finalitat del qual és esdevenir una eina per a poder mesurar, mitjançant un conjunt de mètriques i un indicador, el grau de qualitat de cada un dels elements ODQ identificats així com el nivell total de la qualitat de les dades obertes d'una organització.

El treball parteix de la idea ja apuntada per Joan Soler (2013) de que «*de res servirà “obrir” i disposar de “grans quantitats” de dades, si aquestes no són de qualitat i si no es mostren amb qualitat.*» L'article del que s'extreu la frase anterior va suposar un primer punt de partida que, juntament amb una reflexió teòrica entorn què pot aportar l'arxivística i la gestió de documents a la gestió i explotació de les dades, va permetre descobrir un àmbit poc tractat fins el moment, atès que són pocs els autors i les autores (Casellas, 2016; Soler, 2013; Thurston, 2012) que han explorat la qualitat de les dades (Casadesús, 2018). Convé destacar que per qualitat de les dades obertes s'entén tot un conjunt d'atributs o propietats jeràrquiques, tal com la integritat, l'autenticitat, la fiabilitat, la traçabilitat, la usabilitat, la disponibilitat, l'exactitud, la reutilització o l'actualització, entre altres.

Enfront d'aquest buit per part de l'arxivística i la gestió de documents, proliferen els estudis i les propostes metodològiques des d'altres disciplines, majoritàriament des de l'anomenada ciència de dades, però també des d'enginyeria informàtica, telecomunicacions, econòmiques i empresarials, gestió i administració pública, etc. Davant d'aquest increment, i en una societat cada cop més datificada on les dades s'equiparen al nou petroli (Kroes, 2012) o inclús al nou sòl (McCandless, 2010), és important que des de l'arxivística es transcendeixin els límits marcats per tal d'aportar el seu corpus teòric i metodològic a la gestió i explotació de les dades en general, i a l'avaluació de la qualitat de les dades obertes en particular a fi de transformar aquest combustible en nou or (Soler, 2014).

Convé senyalar que en aquest estudi es parteix de dues consideracions relacionades amb la qualitat: d'una banda, la noció es concep com a multidimensional i multinivell ja que engloba diferents propietats o característiques de les dades. I d'altra banda, la qualitat comprèn diferents processos un dels quals és la millora contínua a partir del cicle de planificació, execució, avaluació i actuació (*Plan, Do, Check, Act* - PDCA, en anglès).

A partir de les afirmacions anteriors es plantegen dues preguntes d'investigació que són les que es detallen a continuació:

- Primerament, quines són les dimensions de qualitat de les dades obertes?
- I en segon lloc, quines mètriques permeten avaluar les dimensions de qualitat de les dades obertes?

Per al desenvolupament d'aquestes qüestions es parteix de quatre àmbits d'estudi diferenciats, però que s'interrelacionen en aquesta investigació: l'arxivística i la gestió documental, la gestió de les dades, la teoria provinent de les dades obertes i el Govern obert i, finalment, la teoria sistèmica (vid. **Figura 1**). La hipòtesi principal és que la integració del corpus teòric i, en alguns casos, metodològic de les quatre disciplines permet millorar l'aproximació a l'avaluació de les dimensions de qualitat de les dades obertes. Pel que fa a l'arxivística i la gestió documental convé destacar molt especialment que es tracta d'una disciplina que s'ha dotat d'estàndards, normatives i una metodologia per a gestionar el document electrònic que pot ser adaptada i aplicada a la generació, gestió i explotació de les dades (Bustelo, 2018). En aquest sentit, Carlota Bustelo (2018, 42) senyala que «(...) *publicar datos abiertos de las administraciones públicas españolas no parece que tenga que atenerse a unas reglas o especificaciones muy estrictas. Pero ¿es que las cuatro características de los*

documentos: integridad, autenticidad, fiabilidad y disponibilidad no sería aplicables a los datos? (...)». Tal com es desenvoluparà en capítols posteriors, aquesta investigació planteja que les propietats essencials dels documents fidèdignes conformen algunes de les dimensions de la qualitat de les dades obertes.

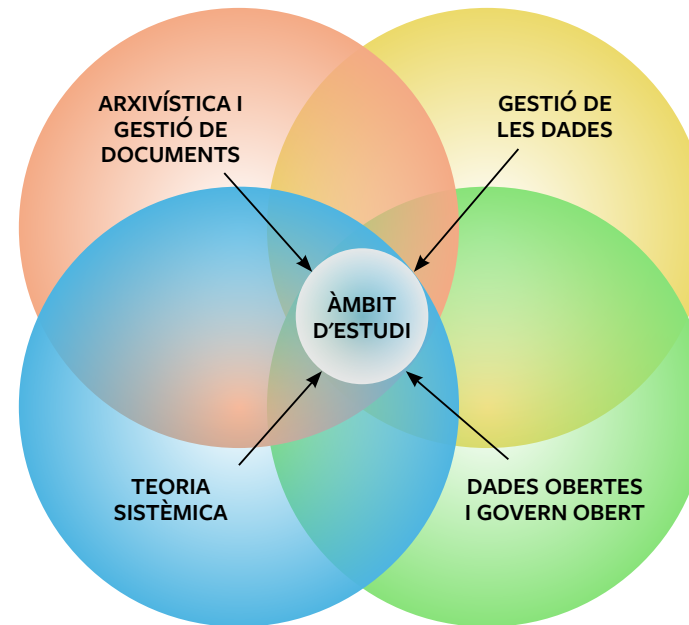


Figura 1. Camps d'estudi de la investigació. (Font: Elaboració pròpia, 2021).

En aquest estudi s'han fixat els següents objectius generals:

- El primer objectiu general (OG1) és establir criteris per avaluar les dimensions de qualitat de les dades obertes.

- El segon objectiu general (OG2) és integrar la teoria provinent de la gestió de les dades a la gestió documental.
- I el tercer objectiu general (OG3) és adaptar i aplicar la teoria i metodologia pròpies de l'arxivística i la gestió de documents, així com la teoria sistèmica, a l'àmbit de les dades obertes.

Altrament, del primer objectiu general sorgeixen tres objectius específics:

- El primer objectiu específic (OE1) és identificar, definir i relacionar les dimensions de qualitat de les dades obertes (model conceptual i lògic).
- El segon objectiu específic (OE2) és dissenyar una proposta metodològica com a eina per avaluar les dimensions de qualitat identificades prèviament (model metodològic).
- I el tercer objectiu específic (OE3) és provar la proposta elaborada en un conjunt de dades a fi de valorar la seva aplicabilitat (prova de concepte).

Convé destacar que, malgrat la investigació no se centra en l'objecte primari d'estudi de l'arxivística, és a dir, en els documents i el seu context de creació; es tracta d'un estudi d'investigació arxivística ja que, seguint les consideracions de

Luciana Duranti i Giovanni Michetti (2017), algunes investigacions s'enfoquen en objectes, mètodes i activitats que ja són reconegudes per la disciplina, mentre que altres estudis exploren diferents àmbits o metodologies amb la intenció d'incrementar el camp de coneixement de l'arxivística i la gestió documental (Duranti & Michetti, 2017; Casadesús, 2018). En aquest sentit, el present treball s'inclou dins aquesta última categoria ja que l'articulació entre les disciplines enumerades, a efecte d'elaborar una proposta per avaluar la qualitat de les dades obertes, vol contribuir al desenvolupament del que s'ha anomenat "Arxivística de les dades" (Soler, 2014).

Pel que fa a la metodologia i estructura de la investigació aquesta s'organitza entorn tres capítols principals. Al primer capítol s'elabora el marc teòric, conceptual i l'estat de la qüestió de les disciplines que integren l'estudi. Així mateix, per a l'elaboració dels subapartats que integren el capítol s'ha realitzat una revisió i anàlisi bibliogràfic de la literatura centrada en dades obertes, qualitat de les dades, teoria de sistemes i cibernètica, gestió de les dades, gestió documental, etc. En el segon i tercer capítols es desenvolupa el cos de la recerca duta a terme segons els objectius generals i específics fixats. Concretament, al capítol 2 es presenta, en primer lloc, el model teòric i lògic ODQ en el qual s'identifiquen els quatre nivells jeràrquics i les relacions que s'hi estableixen; altrament es distingeixen i defineixen les dimensions i els elements ODQ que conformen el model. Seguidament, hi ha un subapartat dedicat al vocabulari de metadades en el qual

es concreten i comparen els estàndards existents per a la descripció dels conjunts de dades publicats, amb especial èmfasis al DCAT, el DCAT-AP i la Guia d'emplenament de les metadades del conjunt de dades per a la tramesa de dades obertes al portal de dades obertes de la Generalitat de Catalunya. En últim lloc, es dissenya el model metodològic a partir d'una proposta d'agregació i ampliació de les mètriques analitzades durant la fase de revisió bibliogràfica. La metodologia la integren un conjunt de mètriques (una per cada element ODQ identificat) i un indicador final on s'estableix una correlació entre la puntuació total i el nivell de qualitat de les dades obertes de l'organització. En conjunt, la proposta es desenvolupa a través de tres models específics que interactuen: el model conceptual, el model lògic i el model metodològic. En relació amb el capítol 3 es realitza un procés de validació experimental del mateix a partir de l'avaluació de dues mostres seleccionades, en particular són el dataset Codis postal per municipis de Catalunya i el conjunt Comissaries, el primer emmagatzemat i recuperat del Portal de dades obertes de la Generalitat de Catalunya i el segon es localitza al Portal de dades obertes dels Mossos d'Esquadra. El capítol se centra en el procés de mesurament de cada un dels elements ODQ, a continuació en l'anàlisi dels resultats obtinguts i, finalment, en un apartat de discussió i conclusions en el que s'empra l'anàlisi DAFO. Així mateix, aquest capítol segueix el cicle PDCA de la millora continua, cosa que es reflecteix en les millores aportades en el model ODQ arran de la prova de concepte. En aquest

sentit, els apartats es desenvolupen seguint les fases de planificació de la prova de concepte, execució del procés de mesurament, avaluació tant dels resultats com del model, i actuació o introducció de millores (*vid.* **Figura 2**).

Per acabar, el treball finalitza amb un capítol de conclusions i identificació de línies de futur per a la continuïtat de la recerca i perfeccionament del model ODQ.

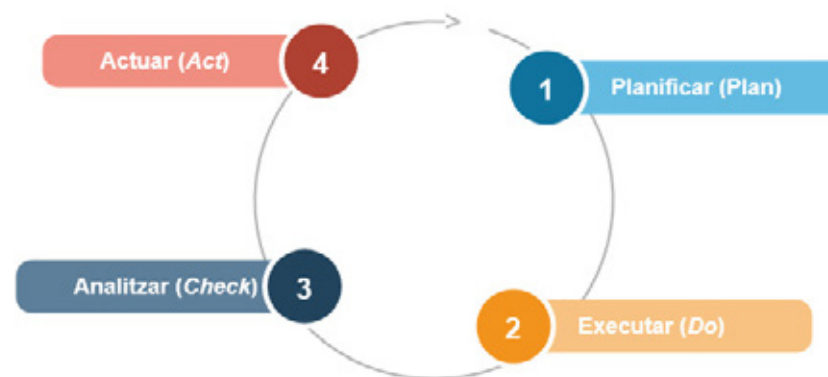


Figura 2. Cicle PDCA aplicat a la investigació. (Font: Elaboració pròpia, 2021).

NOTA 1. En el temps transcorregut entre la finalització del treball i la publicació del mateix hi ha normativa que ha quedat derogada, la qual era plenament vigent durant l'elaboració de la investigació.

NOTA 2. En aquesta investigació hi ha fórmules en les que s'utilitzen símbols matemàtics que representen operacions i relacions entre valors. Aquests casos concrets no s'han de confondre amb símbols ortogràfics, com per exemple un guió.

En aquest capítol es presenta el marc teòric i conceptual, el marc normatiu i l'estat de la qüestió dels eixos i disciplines principals de la investigació, que són l'arxivística i la gestió documental (*records management*), les dades obertes (*open data*), la teoria de sistemes i la cibernètica, les dimensions de qualitat de les dades (*data quality dimensions*) i les mètriques i indicadors existents per avaluar aquestes dimensions de qualitat (*data quality assessment*). Aquests dos últims aspectes integren el camp de la qualitat de les dades (*data quality*) i, de forma més genèrica, formen part de la gestió de les dades (*data management*).

La metodologia utilitzada per a l'elaboració d'aquest capítol s'ha fonamentat, d'una banda, en la revisió bibliogràfica procedent de diverses disciplines, tal com la gestió documental i l'arxivística, la gestió de les dades, les matemàtiques o dret, amb l'objectiu de realitzar una recerca detallada, analítica, crítica i selectiva de tots aquells aspectes essencials per a la investigació. I, d'altra banda, s'ha efectuat una revisió de la legislació europea i nacional, així com de les normes o estàndards d'aplicació, com per exemple la UNE-ISO 15489:2016, la UNE-ISO 30300:2021, la ISO 9000:2015 o la UNE 178301:2015, entre d'altres.

1. 1. Marc teòric de l'arxivística i la gestió documental

1. 1. 1. Conceptes de document, informació i dades

Una de les qüestions que es planteja quan es parla de transformació digital¹ és si aquesta ha suposat canvis en el concepte de document i d'informació en el sector públic, i si aquests canvis impliquen que no existeixen avui dia diferències entre documents, informació i dades (Mendo, Ramos, *et al.*, 2013). A partir de la revisió bibliogràfica i normativa de les definicions d'aquests termes es distingeixen principalment dues tendències conceptuals, que són les que a continuació es detallen.

La primera corrent, de caràcter datacèntric, parteix de la idea que les dades són la matèria prima de la transformació digital, i això porta a considerar que les dades constitueixen un dels principals actius estratègics de les organitzacions (Fernández, 2019, 2). En aquesta tendència, que és la que s'infereix de la literatura adreçada al mercat empresarial, es constata que «*much of the rhetoric that has come to surround concepts of information is often*

¹ El concepte de transformació digital, que s'associa a la quarta revolució industrial, es defineix com la combinació de l'estratègia i operacions de negoci amb la innovació tecnològica, l'analítica de dades i el disseny o redisseny de nous productes i serveis, amb la finalitat de millorar la productivitat i l'eficiència, i el creixement de la cadena de valor (PwC, 2019). Així mateix, no només es tracta d'un canvi tecnològic sinó que també implica noves aptituds, tant individuals como organitzacionals (Fuente, 2018), el que suposa que la transformació digital ha d'anar acompanyada d'una gestió del canvi de les persones i les organitzacions.

transferred to a parallel discourse about data» (Yeo, 2018, 105). Així doncs trobem que la visió que es té de les dades coincideix amb el d'informació, ja sigui perquè el terme informació és substituït pel de dades o ja sigui perquè ambdós mots s'utilitzen indistintament. Un exemple d'aquesta última casuística la trobem a la definició d'informació que presenten Shapiro & Varian (2000, 2), els quals entenen la informació com a qualsevol cosa que pugui ser digitalitzada, és a dir, codificada com un conjunt de bits. Tanmateix, tal com apunten Boisot & Canals (2004), aquesta indistinció ignora la forma en la que les dades i la informació es relacionen entre sí. Paral·lelament, en aquest context en que les dades són concebudes com un actiu estratègic per a l'organització es desenvolupa un procés de datificació de la informació, entès com el procés de capturar informació i registrar-la en un format quantificable per a que pugui ser mesurada i analitzada (Mayer-Schönberger & Cukier, 2013). La lògica de la datificació es resumeix en la famosa cita del físic Lord Kelvin: «*lo que no se define no se puede medir. Lo que no se mide, no se puede mejorar. Lo que no se mejora, se degrada siempre.*»² És en aquesta conjuntura de datificació on alguns professionals de l'arxivística i la gestió documental consideren que s'ha produït una crisi del document – objecte a favor del principi de la dada única (Serra, 2017), o que el document ha sigut deconstruït i en el seu lloc seria millor parlar d'evidències i de conjunts de dades com a documents (Casellas, 2020).

La segona tendència, de caràcter generalista, és la que s'infereix del concepte de document que es recull tant a la legislació vigent nacional en matèria de reutilització de la informació del sector públic (RISP) com a la Directiva (UE) 2019/1024 del Parlamento Europeo y del Consejo de 20 de junio de 2019 relativa a los datos abiertos y la reutilización de la información del sector público. A tall d'exemple trobem que a l'annex de la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic es defineix document com «*toda información o parte de ella, cualquiera que sea su soporte o forma de expresión, sea esta textual, gráfica, sonora, visual o audiovisual, incluyendo los metadatos asociados y los datos contenidos con los niveles más elevados de precisión y desagregación. A estos efectos no se considerarán documentos los programas informáticos que estén protegidos por la legislación específica aplicable a los mismos.*». En el preàmbul de la citada llei, el legislador justifica l'ús genèric del terme document «*acorde con la evolución de la sociedad de la información y que engloba todas las formas de representación de actos, hechos o información, y cualquier recopilación de los mismos, independientemente del soporte (...)*». Pel que fa a la Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la qual s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos de la informació, convé subratllar que els recursos d'informació reutilitzable són definits com a «*documentos que*

² Enciclopedia Libre Universal en Español, a http://enciclopedia.us.es/index.php/Lord_Kelvin

obran en poder de las Administraciones, órganos y entidades de Derecho Público del sector público, por personas físicas o jurídicas, con fines comerciales o no comerciales (...)». I en quant a la Directiva (UE) 2019/1024 la definició que es proporciona en el considerant 30 és semblant a la de la llei 37/2007. Així doncs, de l'anàlisi de la normativa s'infereix un concepte tan genèric de document que engloba els tres conceptes indistintament (document, informació i dades). D'una banda, trobem que el terme document s'equipara a dades, tal com es reflecteix en el glossari (article 2) de la citada directiva europea on es defineixen les dades d'investigació, les dades dinàmiques i els conjunts de dades d'alt valor com a documents en format digital. I d'altra banda, a l'ordenament jurídic en matèria de RISP els conceptes de document i d'informació són intercanviables. (Martín, 2014). Com molt bé precisen Mendo, Ramos *et al.* (2013), plantejar un concepte de document que convergeix amb el d'informació del sector públic suposa una feblesa conceptual al no tenir en consideració, no només les diferències existents entre ambdós termes, sinó les relacions que s'estableixen entre un i altre.

Altrament, el concepte de document emprat a les citades lleis no contempla les característiques definitòries i diferenciadores d'aquest vocable, algunes de les quals ja apareixen a la segona accepció emprada en el *Diccionario de la Real Academia Española* (2020), on es precisa que un document és un «*escrito en que constan datos fidedignos o susceptibles de ser empleados como tales para probar algo.*»³ Aquest caràcter probatori és un tret essencial a la definició que apareix tant a la norma UNE-ISO 15489-1:2016 com a la UNE-ISO 30300:2021. En aquesta última es precisa que un document és aquella «*información creada o recibida y mantenida como evidencia⁴ y como activo por una organización, en cumplimiento de obligaciones legales o en el curso de su actividad.*» (p. 13)⁵. Tanmateix, aquestes definicions encara deixen fora certs elements diferenciadors del document, tal com el seu caràcter seriat, l'origen, la unicitat/exclusivitat, l'objectivitat o els components que el conformen. Finalment convindria afegir dos postulats més en relació als documents: en primer lloc que el document, per a ser considerat evidencia fidedigna de les accions, funcions i decisions d'una organització o persona, hauria de ser

3 Real Academia Española. Diccionario de la lengua española (actualització 2020), a <https://dle.rae.es/documento>

4 Convé destacar que el mot evidencia no es limita al sentit jurídic del terme, sinó que tal com s'indica a la norma UNE-ISO 30300:2021 és «*información que podría utilizarse por sí sola o en combinación con otra información, para establecer pruebas sobre un acontecimiento o acción.*» (p.13) Altrament, tal com senyala Remei Perpinyà (2020), el criteri d'evidència s'articula amb el principi de provenença ja que reconeix el context de producció dels documents.

5 És important senyalar que a la norma UNE-ISO 30300:2011 s'indicava a la nota 3 de la definició de document que el concepte s'aplicava a la informació en qualsevol mitjà, forma o format; el que incloïa documents, conjunts de dades o altre tipus d'informació tant digital com analògica. En la nova versió aquesta nota ha sigut eliminada, no obstant, la definició és substancialment similar a la de la norma anterior.

autèntic, íntegre, fiable i usable (UNE-ISO 15489-1:2016, 10-11)⁶. I en darrer lloc que el document, en tant que produït o rebut i conservat en l'exercici d'unes funcions o activitats com a evidència d'aquestes, posseeix un conjunt de valors que són intrínsecs des del moment del seu naixement i que varien o es combinen amb el temps. Aquests valors, ja siguin primaris (administratiu, legal i/o fiscal) o secundaris (informatiu i/o històric), conviuen en els documents des de la seva creació i no es substitueixen o exclouen, sinó que fins i tot es poden superposar.⁷ (Perpinyà, 2020).

De manera global, i en relació al trinomi dades, informació i documents, es pot afirmar que les tendències anteriors tendeixen cap al biaix ideològic afavorint un concepte en detriment dels altres, ja sigui perquè impera la corrent datacèntrica, ja sigui perquè s'usa un concepte de document tan genèric que, a la pràctica, és un calaix de sastre on els tres conceptes s'utilitzen indistintament. Tanmateix considerem que hi ha una connexió entre dades, documents

i informació la qual cosa fa que no se'n pugui prescindir de cap. Tal com senyala Joan Soler (2014 i 2020) aquestes interrelacions es resumeixen en la fórmula $I = i(D, S, t)$ del professor Börje Langefors; a partir de l'expressió anterior s'infereix que la informació (I) és el resultat d'un procés interpretatiu (i) que dota de significat a certes dades (D), a la vegada que utilitza el nostre preconeixement (S), durant un temps determinat (t). En aquest sentit, la proposta planteja que les dades serien les unitats bàsiques de contingut i que quan s'enllacen entre elles i es doten de sentit, a partir d'un procés interpretatiu, es genera informació. Altrament, quan aquesta informació comença a ser contextualitzada, s'organitza segons una estructura determinada, i es fixa en un suport, ja sigui analògic o digital, és quan es conforma el document⁸. És a dir, quan a aquest contingut se li afegeix context i estructura es crea el document. Seguint a Soler (2014 i 2020), per aportar més claredat podem pensar la connexió existent entre dades, informació i documents com si es tractés d'una cèl·lula, on el nucli serien les dades, el

6 La norma UNE-ISO 15489-1:2016 indica que les característiques d'autenticitat, fiabilitat, integritat i usabilitat les tenen els documents fidedignes; amb això implícitament es reconeix que hi ha documents que són evidència d'una activitat o funció, però que no són fidedignes. (Bustelo, 2018).

Cal indicar que a la norma UNE-ISO 30300:2021 s'inclou, com a novetat envers l'anterior versió, la definició de document fidedigne dins el conjunt de termes relacionats amb el concepte de documents.

7 En són un exemple els expedients de la sèrie documental procediments judicials militars (sumaríssims) 1939-1980 del Tribunal Militar Territorial Tercer de Barcelona. Aquesta sèrie, conservada pel seu caràcter històric, s'està utilitzant per a protegir i restituir drets, cas de la nul·litat de les sentències i resolucions de les causes instruïdes i dels consells de guerra, gràcies a la Llei 11/2017, del 4 de juliol, de reparació jurídica de les víctimes del franquisme.

8 De manera gairebé coincident, la norma ISO 9000:2015 defineix dades com «*hechos sobre un objeto*», informació com a «*datos que poseen significado*» i document com «*información y el medio en el que está contenida.*» (p. 23 – 24). No obstant, pel que fa al terme dades la present investigació emprarà el concepte fixat tant a la Guia de aplicació de la Norma Técnica de Interoperabilidad de Documento Electrónico (2016) com a la UNE 178301:2015, segons les quals les dades son la «*representación de hechos, conceptos o instrucciones de un modo formalizado y adecuado para su comunicación, interpretación o procesamiento por medios automáticos o humanos.*»

citoplasma la informació i la membrana cel·lular representaria el document, tal com es reproduïx a la següent figura:

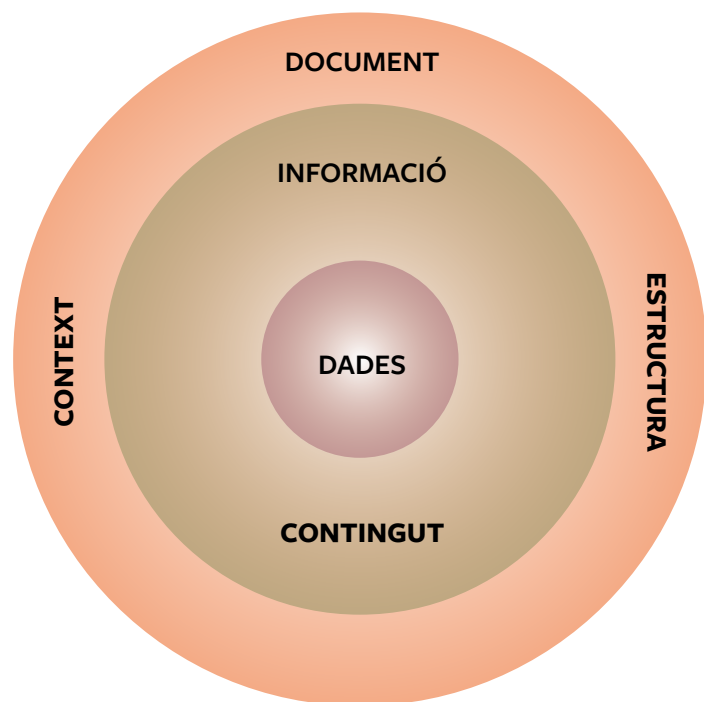


Figura 3. Símil de la cèl·lula (Font: Adaptació a partir de Joan Soler, 2014 i 2020).

A partir dels conceptes així formulats, Soler (2020) afirma que les dades, la informació i els documents integren el capital informacional⁹ de les organitzacions, les quals l'utilitzen per a la presa de decisions, oferir uns serveis, entre altres. Tanmateix, l'autor senyala que «*dels tres elements, evidentment en predomina un, el de la informació, que és l'objecte definit però que, per disposar-ne, necessita dels altres dos. Així, les dades, la informació i els documents són inherents al concepte de capital informacional i no es pot prescindir de cap.*» (2020, 2). En termes semblants s'expressen Mendo, Ramos, et al. (2013) al sostenir que existeixen diferències entre documents, dades i informació, encara que totes tres entitats conformen el concepte "informació del sector públic¹⁰". Així mateix, aquesta visió també s'albira en el Decret 76/2020, de 4 d'agost, d'Administració digital, on es planteja des d'una perspectiva datacèntrica que el pilar fonamental de l'Administració digital és el govern de les dades que es fonamenta en la gestió de les dades i dels actius digitals en general, entès

9 El capital informacional és un concepte introduït per Pierre Bourdieu (1993) que fa referència a tots aquells productes i recursos d'informació que acumula l'Estat, els tracta i/o gestiona i els redistribueix a fi d'unificar i totalitzar el mercat cultural. El capital informacional, així plantejat, seria un agent passiu que instrumentalitza l'Estat per a imposar una cultura dominant. Aquest concepte és ampliat i superat per Cees Jan Hamelink (2015), segons el qual el capital informacional comprèn «*la capacidad financiera para pagar por el uso de redes y servicios de información, la habilidad técnica para manejar infraestructura de redes, la capacidad intelectual de filtrar y evaluar información, y también la motivación para buscar información activamente y la habilidad de traducir la información en prácticas sociales.*» (2015, 47). D'aquesta definició s'infereix que els diferents nivells d'acumulació o apropiació es relacionen amb l'accés, amb la formació i capacitació en l'ús de les tecnologies, i en el desenvolupament d'un marc de reflexió que es tradueixi en canvis socials i organitzacionals. (A partir de Joan Soler, 2020). Dit d'una altra forma, el capital informacional té una doble vessant: d'una banda pot ésser un agent passiu (enfocament instrumental) i, d'altra banda, pot actuar com un agent actiu que genera noves activitats i relacions, el que s'expressa en canvis organitzacionals i de funcionament (enfocament transformador).

10 La informació del sector públic la integren tots aquells productes i serveis d'informació que han sigut generats, creats, recollits, processats, preservats, mantinguts, disseminats o finançats per un govern o institució pública, i que consideren els requeriments i restriccions legals pertinents. (Ubalde, 2013, 5).

aquest últim com «*la dada o la informació obtinguda o generada per l'actuació de les administracions públiques. Són exemples d'actius digitals els fitxers de dades, d'imatges, de sons, de text, multimèdia o qualsevol altre tipus de dada o de representació d'informació.*» (p. 37) En aquest sentit, entenem que les dades, la informació i els documents integren el concepte d'actiu digital i que, similarmet al que s'exposava amb relació al capital informacional, no se'n pot excloure cap. Finalment s'ha de fer esment a la norma UNE-ISO 30300:2021, la qual té en consideració —a diferència de la versió anterior de l'any 2011— la relació existent entre dades, informació i documents. D'aquesta manera les dades, enteses com la unitat bàsica, són definides com un «*conjunto de caracteres o símbolos a los que se asigna o podría asignarse un significado*», la informació es defineix en relació amb les dades («*datos en un contexto con un significado particular*») i, en darrer terme, els documents es conceben com a informació. Donat que els conceptes no són independents els uns dels altres, es remet a la següent figura per a un millor enteniment de la connexió existent entre aquestes entitats.

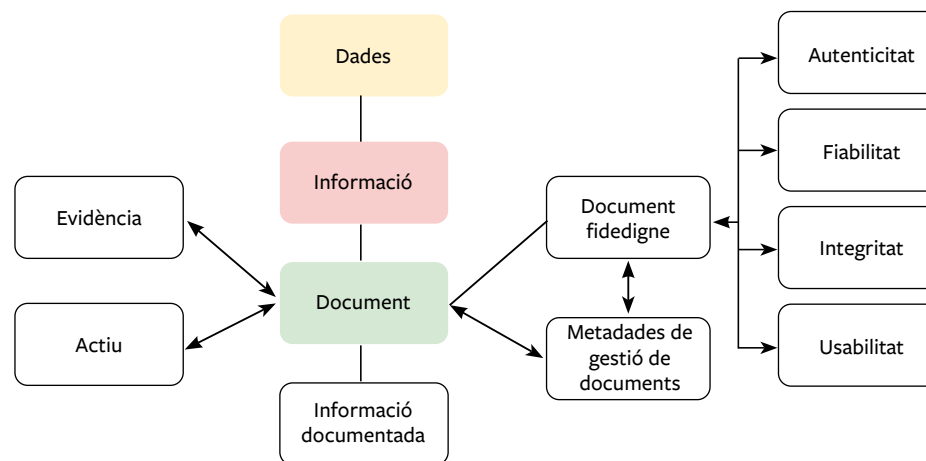


Figura 4. Conceptes relacionats amb el document

(Font: Adaptació a partir de la norma UNE-ISO 30300:2021).

1. 1. 2. De la gestió de documents a la governança arxivística de la informació

La norma UNE-ISO 15489-1:2016 defineix la gestió de documents¹¹ (*records management*) com aquella «*área de gestión responsable de un control eficaz y sistemático de la creación, la recepción, el mantenimiento, el uso y la disposición de los documentos, incluidos los procesos para capturar y mantener, en forma de documentos, la información y*

¹¹ En el marc d'aquesta investigació s'utilitzaran els termes arxivística i gestió de documents (o documental) sense distincions ja que ambdues àrees comparteixen principis, conceptes, processos i tècniques. De fet, la irrupció del document i expedient electrònic ha posat de manifest la necessitat de participar i aplicar els principis i processos arxivístics des del mateix disseny dels sistemes de gestió documental (SGD) i no només en la fase inactiva dels documents, tal com desenvolupa la metodologia DIRKS (*Design and Implementation of a Record Keeping System*).

evidencia de las actividades y operaciones de la organización.» (p.9). Més recentment, la norma UNE-ISO 30300:2021 la defineix com el «*campo responsable de la gobernanza sistemática y eficiente de los documentos, usando procesos de gestión de documentos, instrumentos de gestión de documentos y aplicaciones de gestión documental.*» (p.15) Altrament, la gestió de les dades (*data management*) és definida, segons DAMA International¹², com «*the business function of planning for, controlling and delivering data and information assets.*» Aquestes funcions inclouen «*the disciplines of development, execution, and supervision of plans, policies, programs, projects, processes, practices and procedures that control, protect, deliver, and enhance the value of data and information assets.*» (2009, 4) És a dir, segons aquesta definició integrarien la gestió de dades pràctiques tan diverses com, per exemple, la qualitat de les dades (*data quality*), la seguretat de les dades (*data security*), l'arquitectura de dades (*data architecture*) o la gestió de metadades (*metadata management*), entre altres.

A l'examinar aquestes conceptualitzacions trobem que hi ha un marc de referència comú entre aquestes disciplines ja que ambdues intervenen en tots els estadis del cicle de vida, la primera en relació amb els documents i la segona pel que fa a les dades i els actius d'informació.¹³ Aquesta

participació en les diferents etapes implica l'aplicació de diferents processos, com la captura, l'emmagatzematge, l'ús i reutilització, la preservació, etc. En quant a aquesta qüestió, ja hi ha professionals de l'arxivística, i de la informació i la documentació en general, que des dels anys 80 advoquen per la convergència entre la gestió documental i la gestió de les dades, argumentant que la integració d'eines, tècniques i principis d'ambdós camps ofereix una visió més holística i evita les illes informacionals que genera la fragmentació i la nul·la comunicació entre els diferents sistemes d'informació que pot albergar una organització. (García-Alsina, 2017; McDonald, 1989 i 2010). També es planteja la necessitat d'aplicar els processos de gestió documental a la generació de les dades, a fi de garantir que les dades compleixin amb les característiques d'autenticitat, integritat, fiabilitat i usabilitat, la qual cosa possibilitaria parlar del concepte de dades fidedignes. (Bustelo, 2018).

En el context de la transformació digital trobem dues tendències relacionades amb la progressió de la disciplina. La primera és la que es relaciona amb l'objecte d'estudi de la disciplina ja que la gestió documental ha evolucionat de la gestió d'objectes/documentos a la incorporació de la gestió de dades i de la informació, degut, en part, a la pròpia crisi del concepte document. Una bona mostra d'aquesta

¹² La *Data Management Association International* (DAMA International) fou fundada l'any 1980 i és la principal organització internacional per a professionals de la gestió de les dades. Per a més informació es remet a la seva pàgina web <https://www.dama.org/cpages/home>

¹³ Tal com indica Jordi Serra (2021) quan es parla d'actius d'informació també s'inclouen documents. En aquest sentit, en la publicació *DAMA-DMBOK: Data Management Body of Knowledge* (2a edició) (2017) hi ha un capítol dedicat a la gestió de documents i continguts.

tendència es reflecteix en la diversitat de termes que han sorgit en els últims anys per a referir-se a la professió, tal com Arxivística de les dades (Soler, 2014), Gestió documental datificada (Serra, 2020), Governança de la informació (Soler, 2018 i 2020), Governança arxivística de la informació (Casellas, 2020) o Gestió arxivística de les dades i dels actius digitals (Decret 76/2020). Al respecte, és important preguntar-se dos aspectes: d'una banda si, avui dia, és suficient el concepte de gestió documental per a definir les funcions que es realitzen, o, en cas contrari, és necessari ampliar-lo i redefinir-lo. I de l'altra si l'objecte de la professió es gestiona o es governa. En relació a la primera qüestió es parteix de la idea que la noció de capital informacional, ja plantejada a l'apartat 1.1.1, és l'objecte d'estudi de la disciplina ja que inclou dades, informació i documents com a elements inherents d'aquest concepte. Així doncs, degut al context de transformació digital i a la deconstrucció del document (entès en el seu concepte més "clàssic"), la disciplina ha ampliat les seves fronteres incorporant dades, informació i documents, és a dir, capital informacional com el seu objecte d'estudi a fi de possibilitar una gestió holística i transversal de la informació de les organitzacions. En quant a la segona qüestió, aquest nou context encamina a la professió cap a un procés de transformació que va del gestionar documents al governar la informació. Segons l'empresa *Gartner Inc.* la governança de la informació «*is the specification of decision rights and an accountability framework to encourage desirable behaviour in the valuation, creation, storage, use, archival and deletion of information. It*

includes the processes, roles, standards and metrics that ensure the effective and efficient use of information in enabling and organization to achieve its goals.» (Logan, 2010). La definició proposada situa la governança de la informació en una esfera política, incidint en la importància de la presa de decisions, en l'assumpció de responsabilitats i en un control sobre les mateixes, actuant com el paraigües que cobreix tota la informació d'una organització i afavorint el seu control holístic i transversal per part de les organitzacions. (García-Morales, 2012; Soler, 2018). Aquesta conceptualització presenta un enfocament dinàmic, proactiu i orientat al negoci on la informació és percebuda i governada com un actiu de l'organització (García-Morales, 2012). Enfront d'aquest enfocament, Joan Soler (2020) senyala que la gestió documental es queda curta per incompleta degut essencialment a que està orientada al control, manteniment i preservació de documents com a evidència de les activitats de les organitzacions, però que es manté al marge de les decisions estratègiques i per tant, aquestes evidències en forma de documents són conceptualitzades com un agent passiu, i no com un vertader actiu. Al respecte, Soler (2018 i 2020) advoca per la implantació d'un sistema de governança de la informació que tingui en consideració les diverses peces que conformen el capital informacional, a la par que defensa la necessitat de definir bé quines són les funcions de la disciplina en relació amb altres professions, especificant quines són exclusives i quines es comparteixen amb altres professionals. En termes similars s'expressa Lluís-Esteve Casellas (2020)

al formular que s'imposa el context de la governança de la informació i que, en aquest nou context, la gestió documental tal com l'enteníem ha mort. Amb relació a això, exposa que és necessari que la professió s'encamini cap a una governança arxivística de la informació on es fa indispensable re-formular i consensuar la metodologia i la seva aplicabilitat, però no els principis.

La segona tendència és la que es relaciona amb la integració de tècniques, metodologies i conceptes provinents de les ciències de la computació, a fi de que la professió s'adapti a un context canviant dominat per la tecnologia. D'aquesta conjunció ha emergit una nova transdisciplina anomenada Ciència arxivística computacional (*computational archival science* – CAS) que és definida en els següents termes:

«A transdisciplinary field concerned with the application of computational methods and resources to large-scale records/archives processing, analysis, storage, long-term preservation, and access, with the aim of improving efficiency, productivity, and precision in support of appraisal, arrangement and description, preservation, and access decisions.

The intent is to engage and undertake research with archival materials as well as apply the collective

knowledge of computer and archival science to understand the ways that new technologies change the generation, use, storage, and preservation of records and the implications of these changes for archival functions and the societal and organizational use and preservation of authentic digital records.

This suggests that computational archival science is a blend of computational and archival thinking.»
(Marciano; Lemieux; Hedges *et al.* 2018, 181)

Malgrat tractar-se d'una definició extensa i provisional, que, entre altres aspectes, no reflecteix adequadament l'intercanvi bidireccional de coneixements entre ambdues disciplines; es considera que es tracta d'una descripció prou completa, raó per la qual s'ha transcrit en la seva totalitat. Segons Richard Marciano, Victoria Lemieux, Marc Hedges *et al.* (2018) tant l'arxivística i la gestió documental com les ciències de la computació comparteixen un problema central: ambdues busquen utilitzar la procedència com un mitjà per a capturar i avaluar la confiabilitat de la informació—quan aquesta és creada, processada i emmagatzemada en múltiples sistemes distribuïts— com a evidència de les activitats de les organitzacions. En particular, sostenen que al combinar totes dues ciències en aquest àmbit d'investigació comú es pot avançar molt més que no pas si cada una treballés per si mateixa; més concretament, la idea central

és que l'aplicació del pensament¹⁴ i mètodes computacionals expandeix els mètodes i teories arxivístiques, i a la inversa. No obstant això, precisen que cada disciplina ha de continuar essent un camp separat ja que cada una té preocupacions i àrees d'investigació pròpies.

Altrament, Devon Mordell (2019) defensa que l'ús dels arxius digitals per parts dels arxivers i arxiveres com un conjunt de dades a fi de recolzar l'aplicació de mètodes computacionals —per exemple en iniciatives per a la transcripció i descripció automàtiques o en projectes de visualització de dades per a valoritzar els arxius— representa un canvi de paradigma. Mordell argumenta que està emergint un cinquè paradigma, que anomena *Archives-as-data*, posterior als quatre paradigmes arxivístics teoritzats per Terry Cook, que són els d'evidència, memòria, identitat i comunitat. Aquest nou paradigma s'erigeix sobre la conceptualització de les dades com a matèria bruta, sense processar (*raw data*). Ara bé, aquesta idea és un oxímoron ja que sempre estan cuinades; a més, aquesta representació de les dades implica que se succeeixen abans dels fets, és a dir, que són el punt de partida. I això condueix a una altra suposició: les dades són objectives, neutrals, transparents i representen per si mateixes la veritat (Gitelman &

Jackson, 2013). Tal com indica Geoffrey Bowker (2013), el concepte *raw data* es pot alinear al terme *raw* emprat per Claude Lévi-Strauss en la seva obra *The Raw and the Cooked*, on la tesis fonamental és que molts dels mites que descriu conformen conjunts binaris que, en última instància, són variants de l'oposició natura / societat. En aquesta dicotomia la natura s'assimila al mot crua (*raw*), i la societat al terme cuita (*cooked*). Així mateix, el fet d'identificar les dades com a matèria prima, com a natura, obvia que les dades són la representació de fets prèviament existents i el resultat d'actes interpretatius.

Mordell (2019), que anomena aquesta dimensió ideològica del paradigma com a *Archives-as-data-as-raw-material*, indica que això representa ressuscitar vells mites. En concret, assenyalava que la tornada de les nocions de neutralitat i objectivitat eludeix que tant els arxius com les pràctiques arxivístiques s'insereixen i participen de les estructures de poder; i considera que «*as a profession, we can embrace the use of computational methods and tools without sequestering our practices or failing to consider how they are enmeshed in systemic structures of power and privilege; indeed, an archives-as-data paradigm is perhaps one of the most important sites where this work will be performed.*»

14 Amb relació al pensament computacional, Jeannette M. Wing (2006) sosté que és una forma de resolució de problemes que utilitza el pensament recursiu. Altrament, indica que les característiques del pensament computacional són les següents: a) el seu eix central és la conceptualització en múltiples nivells d'abstracció, no la programació; b) és una habilitat fonamental, no relacionada amb l'habilitat de memoritzar o amb rutines mecàniques; c) és una forma en la que els humans resolen problemes, la seva finalitat no és fer que els humans pensin com ordinadors; d) complementa i combina pensament matemàtic i enginyeria; e) desenvolupa idees, no programes; i f) és un pensament que pot desenvolupar tothom.

(p. 161) Per tal de superar aquests perills, advoca per a que els i les professionals de l'arxivística assumeixin un paper més actiu i s'involucrin en el desenvolupament dels sistemes, qüestionant críticament el seu disseny i demanant explicacions, en un llenguatge entenedor, del seu funcionament ja que «*a lack of transparency regarding the system's training process may thus make it difficult for archivists to assess or critique what occurs between the input and output of data.*» (p. 153)¹⁵ Finalment, cal remarcar que en el marc de la CAS la participació dels i de les professionals de l'arxivística i la gestió de documents en el disseny, seguiment i avaluació de la capacitat dels algoritmes d'aprenentatge, per exemple en l'aprenentatge automàtic de processament d'àudio¹⁶, pot contribuir a evitar biaixos ideològics i combatre l'opacitat dels algoritmes¹⁷. (Esteva, 2021)

15 La reflexió i adopció de criteris ètics sobre l'ús de les dades és un pilar fonamental en el desplegament de noves tecnologies i ús massiu de les dades, així com en la consolidació d'una Administració digital fonamentada en la gestió de les dades. En el cas de Catalunya, i a fi de garantir aquesta eticitat de les dades, s'ha aprovat l'Acord GOV/6/2021, de 19 de gener, pel qual es crea el Comitè d'Ètica de les Dades.

16 A grans trets l'aprenentatge automàtic de processament d'àudio consta d'una primera fase d'entrenament i validació de la qualitat de la transcripció automàtica d'àudio a text (discurso-a-texto) i d'una segona fase d'entrenament i d'avaluació de l'assignació de metadades al text (texto-a-etiqueta). (Esteva, 2021)

17 Els algoritmes són considerats caixes negres (*black box*) degut a la seva opacitat la qual pot estar motivada per causes tècniques, jurídiques o organitzatives. A fi de facilitar la transparència dels algoritmes és important que les organitzacions, per exemple en el cas de polítiques *smart city* que utilitzen *big data* i aprenentatge automàtic (*machine learning*), prenguin mesures que garanteixin la transparència a través de l'accés als algoritmes, al coneixement del seu contingut i, finalment, a la comprensió del seu funcionament i del fonament de les decisions que es prenen a través seu. (Cerrillo, 2019)

1.2. Marc teòric de les dades obertes (*open data* - OD)

1.2.1. Context “Open”: *open data* i *open government*

Segons la norma tècnica d'AENOR UNE 178301:2015 les dades obertes (*open data*, en anglès) són dades que qualsevol és lliure d'utilitzar, reutilitzar i distribuir sota, com a molt, les condicions de reconeixement i compartir igual. Amb els mateixos criteris es defineix aquest terme a *Open data handbook*. Tal com es desenvolupa en aquest manual —elaborat per l'organització sense ànim de lucre *Open Knowledge Foundation*— l'element característic és l'atribut obert, el qual presenta les següents accepcions:

- Disponibilitat i accés: les dades han d'estar disponibles de manera integral i a un cost raonable de reproducció, preferiblement descarregant-la d'internet. A més, les dades s'han d'oferir en un format convenient i modificable.
- Reutilització i redistribució: les dades s'han de posar a disposició sota termes d'ús que permetin la seva reutilització i redistribució, i que també permeti la seva integració amb altres conjunts de dades.
- Participació universal: qualsevol persona ha de poder utilitzar, reutilitzar i redistribuir les dades. Altrament s'ha de garantir que no existeixi cap tipus de discriminació en relació a iniciatives, persones o grups.

Aquestes característiques es poden sintetitzar en les tres lleis de les dades obertes concretades per David Eaves (2009):

1. Si les dades no poden ser trobades o indexades a la Web, no existeixen.
2. Si les dades no estan disponibles en un format obert i llegible per màquina, no podrà ser reutilitzat.
3. Si el marc legal no permet que les dades siguin compartides, no seran útils.




Figura 5. Les tres lleis de les dades obertes (Font: Elaboració pròpia, 2021. A partir de David Eaves, 2009)

Així mateix, tal com s'indica en el manual *Open Data Handbook* és important tenir clar el significat del terme obert ja que d'aquesta manera es facilita la interoperabilitat organitzativa, semàntica i tècnica, a l'establir quines són les condicions que han de respectar les iniciatives de dades obertes.

No obstant, les definicions anteriors, si bé fixen el significat del terme dades obertes, se centren essencialment en clarificar les paraules que componen aquest concepte; obviant que són el producte d'un procés històric i que, per tant, es vinculen a una ideologia política i econòmica determinada. En aquest sentit, és rellevant concebre l'*Open data* dins el context "open", entenent que es tracta d'una faceta més dels ecosistemes oberts que inclou l'*Open Source* o la posada en comú del codi font d'aplicacions mitjançant llicències *copyleft*, l'*Open Innovation*¹⁸ o mecanismes de cooperació real entre el coneixement intern de les empreses i el coneixement extern per a desenvolupar projectes d'I+D+i, i l'*Open Governance* (Abella, 2011). Convé destacar que la governança, segons el TERMCAT, és la manera de governar a través de la qual interactuen, mitjançant negociacions i de forma autònoma, els governs, la societat i el mercat formulant i implementant polítiques

públiques a través de xarxes autoregulades, interdependents, horitzontals i relativament estables dins d'un marc regulador i normatiu, amb una finalitat de caràcter públic. Partint d'aquesta proposta, la governança oberta o *open governance* es pot definir com «*[working towards] governance relationships and processes that are transparent, accountable and participatory, and which allow the perspectives, needs and rights of all citizens to be addressed, including those most marginalised by power relations*» (McGee & Edwards, 2016, 14). Les iniciatives de dades obertes són un aspecte de la governança oberta i col·laborativa i, més concretament, s'han de concebre com un moviment i una pràctica vinculades a la doctrina política del govern obert o *open government*. Segons el Portal d'Administració Electrònica (PAe)¹⁹ del Govern d'Espanya, el govern obert²⁰ té com a objectiu que la ciutadania col·labori en la creació i la millora dels serveis públics i en l'enfortiment de la

18 Segons Henry Chesbrough (2003) el paradigma de la innovació oberta (*open innovation*, en anglès) està substituint el paradigma de la innovació tancada (*closed innovation*). L'*Open innovation* significa «*that valuable ideas can come from inside or outside the company and can go to market from inside or outside the company as well. This approach places external ideas and external paths to market on the same level of importance as that reserved for internal ideas and paths to market during the Closed Innovation era*» (p. 43) És a dir, aquest paradigma emergent representa una nova lògica de la innovació basada en la cooperació de coneixements interns —de la pròpia organització— amb coneixements externs —d'organitzacions i professionals externs— en l'àmbit d'I+D+i. Així doncs, la difusió i integració de coneixements interns i externs permet «*creatively combining that knowledge in new and different ways to create new products or services*» (p. 52)

19 Per a més informació es remet a

https://administracionelectronica.gob.es/pae_Home/pae_Estrategias/pae_Gobierno_Abierto_Inicio.html#YEFlaNyCHIU

20 Des de l'any 2011, Espanya forma part de l'*Open Government Partnership (OGP)* que és una organització internacional que té com a finalitat promoure una governança transparent, participativa, inclusiva i responsable. Així mateix, segons la Declaració de Govern Obert de la OGP els integrants es comprometen a l'acompliment de les següents fites: a) augmentar la disponibilitat d'informació sobre les activitats governamentals; b) recolzar la participació ciutadana; c) aplicar els més alts estàndards d'integritat professional en tots els governs i d) augmentar l'accés a les noves tecnologies per a l'obertura i el retiment de comptes. En <https://www.opengovpartnership.org/es/declaracion-de-gobierno-abierto/>

transparència i el retiment de comptes. Aquesta doctrina se sustenta en els principis de transparència, col·laboració i participació en un marc de governança oberta. Altrament impulsa l'obertura i l'intercanvi d'actius per mitjà de les dades obertes, els serveis oberts i les decisions obertes, la qual cosa permet la col·laboració i incrementa les formes participatives ascendents —de baix a dalt— de disseny, producció i prestació de serveis. (Comissió Europea, 2013)

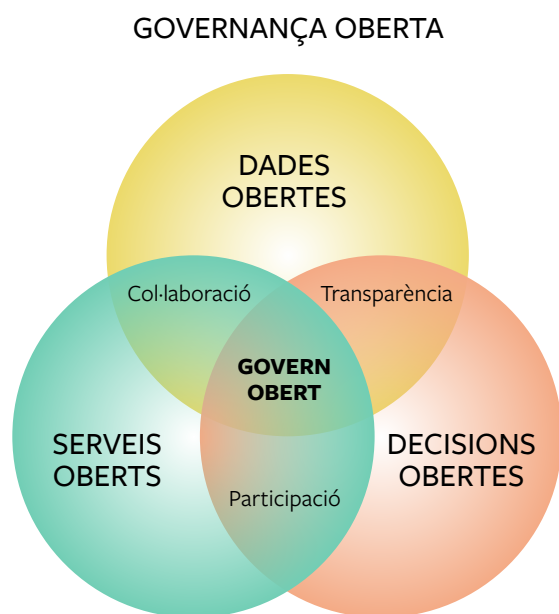


Figura 6. Els tres pilars del govern obert o *open government* (Font: Adaptació a partir de la Comissió Europea, 2013)

De la figura anterior s'infereix que els conceptes de governança oberta (*open governance*), govern obert (*open government*) i dades obertes (*open data*) estan lligats ja que són interdependents. En aquest context, l'*open data* es concep com una faceta més del govern obert on les Administracions públiques —o el sector públic institucional segons la Llei 37/2007— posen a disposició de la ciutadania les dades que tenen en el seu poder a fi de permetre la seva reutilització i redistribució per a la creació de nous serveis i/o productes o la millora dels existents per part d'agents reutilitzadors i/o infomediaris. Degut a això, les dades obertes es vinculen al concepte de reutilització de la informació del sector públic (RISP), entès com l'ús per part de persones físiques o jurídiques de les dades generades i custodiades pel sector públic institucional, amb fins comercials o no (Portal d'Administració electrònica del Govern d'Espanya – PAe²¹). És important destacar que el terme *open data* també comprèn les dades que el sector privat publica per a la seva reutilització, mentre que el terme *open government data* es refereix exclusivament a la publicació de dades custodiades o produïdes per les Administracions públiques a través dels Portals *open data*. (Álvarez, 2014, 15) Ara bé, habitualment ambdós conceptes se solen utilitzar com a equivalents, per la qual cosa en el marc de la present investigació també s'empraran de forma anàloga.

21 Per a més informació es remet a https://administracionelectronica.gob.es/pae_Home/pae_Estrategias/pae_Gobierno_Abierto_Inicio/pae_Reutilizacion_de_la_informacion_en_el_sector_publico.html#.Y_TZxy8zk3g

Malgrat estar relacionades, convé distingir les dades obertes respecte de la transparència i la reutilització. Com molt bé precisa Martín (2014), «(...) *transparencia, reutilización y datos abiertos son conceptos inseparablemente unidos en la lógica de la generación de conocimiento y del otorgamiento de un valor agregado a la información.*» (p. 5); no obstant, existeixen alguns matisos conceptuals que són els que a continuació es detallen. Concretament, la transparència és un principi d'actuació de l'Administració pública en virtut de la qual les administracions han de donar a conèixer la informació necessària a fi que la ciutadania pugui controlar i avaluar l'actuació de l'Administració, en especial la utilització dels recursos públics; participar en els assumptes públics i exercir els seus drets. Altrament inclou tant l'obligació de fer públiques determinades informacions de manera proactiva (publicitat activa), com l'obligació d'atendre les sol·licituds d'informació que faci la ciutadania (dret d'accés a la informació) (Escola d'Administració Pública de Catalunya – EAPC, 2015). És a dir, la transparència no és un fi en si mateixa, sinó un instrument de control de l'actuació pública a partir de la difusió d'informació (Martín, 2014). En el nostre ordenament jurídic, el principi de transparència està regulat a la legislació estatal (Llei 19/2013, de 9 de desembre, de transparència, accés a la informació pública i bon govern) i també a l'autònoma catalana (Llei 19/2014, del 29 de desembre, de transparència, accés a la informació pública i bon govern, i Decret 8/2021, de 9 de febrer, sobre la transparència i el dret d'accés a la informació pública). En canvi, la reutilització —també RISP— es regeix pels articles 16 i 17 de la Llei 19/2014 i per la Llei 37/2007, de

16 de novembre, de reutilització de la informació del sector públic, modificada per la Llei 18/2015, de 9 de juliol; i s'ha de concebre com l'ús per part de tercers de la informació pública que es troba en poder de les Administracions i organismes del sector públic. Finalment, el tercer concepte és el de dades obertes —també obertura de dades públiques—, que s'ha d'entendre com l'acció de posar a disposició de la ciutadania i de les empreses conjunts de dades en formats oberts, interoperables i amb llicències per al seu accés, lliure reutilització i redistribució, a través de l'ús intensiu de les TIC. (Álvarez, 2014; Cerrillo, 2014) Certament, com precisa Cerrillo (2012), l'obertura de dades públiques «*constituye una evolución facilitada por las TIC de la reutilización de la información del sector público que fija la atención no tanto en garantizar las condiciones necesarias para que la información sea reutilizada como en que las administraciones públicas faciliten información que pueda ser fácilmente reutilizada.*» (p. 714) Si bé, segons sosté Martín (2014), el context natural de l'obertura de dades obertes és el de la reutilització, la realitat és que es tracta d'un terme més proper conceptualment al govern obert i, per tant, vinculat a les idees de col·laboració i participació, no només al principi de transparència. Per a visualitzar aquest aspecte es remet a la **Figura 6**.

Així mateix, el moviment *open data* també es relaciona amb la productivitat econòmica i la generació de riquesa. En aquest sentit, una de les finalitats principals de les dades obertes és potenciar el creixement econòmic, a partir de la creació de nous serveis i productes de valor afegit

basats en les dades publicades. A banda d'això, també impulsar la millora de l'eficàcia i eficiència de les Administracions així com la consolidació democràtica dels poders públics. Convé subratllar que l'obertura de dades públiques no ha sigut objecte de regulació jurídica específica, més enllà de la que se'n deriva de la normativa vinculada a la transparència i la RISIP, així com dels principis de l'Administració electrònica (Cerrillo, 2012; Martín, 2014). Tanmateix, si bé és cert que l'obertura de dades públiques comparteix algunes finalitats i també regulació amb la reutilització i la transparència, supera alguns dels seus límits, concretament els que es deriven de la pròpia actitud de les administracions públiques pel que fa a la difusió d'informació i, a més, atorga un major protagonisme a la ciutadania al poder disposar de milers de *datasets* en formats llegibles per màquina (Cerrillo, 2012 i 2014).

D'altra banda, la transparència es fonamenta en el Portal de transparència, que és l'instrument o plataforma web on es publica la informació necessària per a donar compliment a les obligacions de transparència (publicitat activa) establertes per la Llei. Convé destacar que en el Portal de transparència la informació que es publica és primordialment per a la seva consulta. En canvi, els conjunts de dades obertes es publiquen en el Portal de dades obertes que és la plataforma web —també es defineix en termes de software— que possibilita la publicació de dades, la gestió de les metadades, l'emmagatzematge, el control d'accés, les cerques i les visualitzacions (Ajuntament de

l'Hospitalet, s.d). A diferència del Portal de transparència, les dades que es publiquen són per a la seva reutilització i redistribució.

En relació amb els usos de les dades convé afegir una altra distinció que, encertadament, concreta Martín (2014): en el principi de transparència —entesa en la seva doble vessant— l'Administració pública continua mantenint el control sobre la informació, ja que valora les sol·licituds d'accés i decideix sobre la forma de difusió, dins dels marges delimitats per la normativa d'aplicació. Per contra, la reutilització «*permite romper esos límites y multiplicar los efectos diseminadores de la publicidad de la información por la vía de la generación de aplicaciones que convierten datos públicos en conocimiento (...)*» (p. 6) És a dir, el dret de reutilització i redistribució genera que les Administracions perdin el control exclusiu de la informació pública, a favor d'una major democratització de la informació gràcies a l'ús de les TIC, que s'expressa no només en l'accés sinó també en la possibilitat de crear-ne productes a partir dels conjunts de dades publicats per part de la ciutadania i les empreses. Al seu torn, aquesta creació de coneixement pot retornar en benefici per a la pròpia Administració a partir de fluxos circulars d'informació entre els diferents components de l'ecosistema. [Per a més informació sobre l'ecosistema de dades obertes es remet a l'apartat 1.3.2].

En conjunt, al nostre ordenament jurídic no hi ha una clara definició del contingut i abast dels conceptes de transparència, reutilització i dades obertes —on a més aquest últim

no disposa de regulació específica—, la qual cosa deriva en confusió de termes i en la inexistència de línies divisòries entre conceptes. Així mateix, tal com s’ha vist anteriorment existeixen matisos conceptuals, tot i que és innegable que hi ha una clara connexió entre termes en la lògica de creació de coneixement on la transparència seria la premissa de la reutilització, mentre que l’ús de formats oberts seria una de les maneres per a fer possible la transparència, així com la participació i la col·laboració (Martín, 2014).

1. 2. 2. Principis rectors de les dades obertes

La idea subjacent de les iniciatives *open data* és que les Administracions Públiques (AAPP) disposen de dades que poden ser valuoses per a les persones físiques i jurídiques en general, sempre i quan les AAPP aconseguixin posar-les en valor i els agents reutilitzadors sàpiguen que fer amb aquestes dades. Tal com senyala Llinares (2010) la filosofia *Open data* consisteix en «*coger datos que en sí mismos no ofrecen ningún valor y dotarlos de significado para convertirlos en conocimiento válido y con valor para*

los demás» (p. 62) Així doncs, per a que les iniciatives de dades obertes compleixin amb les finalitats d’accés universal, reutilització i redistribució és necessari que les dades compleixin amb un conjunt de característiques conegudes com a “Principis de les dades obertes”; els quals es troben recollits, primer, a l’anomenada llista de Sebastopol²², que conté 8 principis, i posteriorment ampliada a 10 per part de la *Sunlight Foundation*²³. Aquests principis són els que a continuació es detallen:

- 1. Complets (*completeness*).** Els conjunts de dades publicats han de ser el més complets possible i reflectir la totalitat del que està enregistrat sobre un tema concret. Així mateix, s’hauria de publicar les dades en brut, exceptuant en aquells casos en què concorren límits al dret d’accés a la informació pública, com per exemple dades afectades per qüestions relatives a la privacitat o la seguretat, entre altres.

També s’han d’incloure metadades que defineixin i expliquin les dades en brut, juntament amb fórmules i explicacions de com es van calcular les dades derivades.

²² Aquesta llista fou creada el 7 i 8 de desembre de 2007 per part de 30 defensors del govern obert que es van reunir a la localitat de Sebastopol, Califòrnia. Arran d’aquesta reunió es van identificar 8 principis a fi de garantir l’ús, reutilització i redistribució de les dades obertes per part de qualsevol persona ja sigui física o jurídica. També es van identificar 7 principis addicionals que, finalment, no es van tenir en consideració. Per a consultar els 8 principis originals es remet a <https://opengovdata.org/>

²³ *Sunlight Foundation* és una organització sense ànim de lucre que advoca per un govern obert. Per a consultar els 10 principis es remet a <https://sunlightfoundation.com/policy/documents/ten-open-data-principles/>. Altrament convé destacar que existeixen altres iniciatives, com per exemple el G8 Open Data Charter (2013) on s’identifiquen 5 principis estratègics a fi de facilitar la publicació i l’accés a la informació del sector públic (<https://www.gov.uk/government/publications/open-data-charter/g8-open-data-charter-and-technical-annex>); o la International Open Data Charter (2015) on s’identifiquen 6 principis, els quals foren adoptats per la Generalitat de Catalunya l’any 2018 (<https://opendatacharter.net/principles/>).

Aquest principi es vincula al concepte de *Data integrity* (DI) que es defineix, segons la *World Health Organization* (2019), com el grau en què les dades son completes, consistents, precises i fiables. I en última instància es relaciona amb la característica d'integritat, definida a la UNE-ISO 30300:2021 com la qualitat de ser complet i inalterat.

- 2. Primaris (*primacy*).** Els conjunts de dades publicats han de ser dades primàries originals. A més s'ha de facilitar informació sobre com es van recollir les dades i on es troben els documents originals, a fi de que els usuaris puguin verificar si les dades s'han recopilat i emmagatzemat adequadament.

Aquest principi es relaciona amb la traçabilitat, que és segons la Guia d'aplicació de la NTI de document electrònic (2016) el procés mitjançant el qual es facilita el seguiment de la creació, incorporació, moviment, ús i eventual modificació dels documents dins un sistema de gestió de documents (SGD). Per tant, i aquest aspecte és important, els projectes de dades obertes haurien de relacionar-se amb els SGD de les organitzacions. [En relació a aquesta idea es remet a l'apartat 1.2.4]

- 3. Oportuns (*timeliness*).** Els conjunts de dades publicats han d'estar disponibles de manera oportuna, és a dir, les dades s'han de facilitar tan bon punt es recopilin. Així mateix s'ha de donar prioritat a la difusió

de dades, la utilitat de les quals sigui sensible en el temps; i finalment les actualitzacions de dades han de ser en temps real de tal forma que es pugui maximitzar el seu valor.

- 4. Accessibles de forma física i electrònica (*ease of physical and electronic access*).** Els conjunts de dades publicats haurien de ser el més accessibles possible, ja sigui per mitjans físics o electrònics a fi d'evitar desplaçaments o la necessitat de sol·licitar formalment l'accés a la informació. Altrament, pel que fa als mitjans electrònics es recomana l'ús d'una interfície de programació d'aplicació (API) per tal que les dades siguin més accessibles. Un aspecte relacionat amb això és la "facilitat de cerca" (*"findability"*) que és la capacitat de localitzar i descarregar contingut fàcilment.
- 5. Llegibilitat per màquina (*Machine readability*).** Els conjunts de dades han d'estar disponibles en formats d'ús generalitzat i que es puguin processar per màquina. En aquest sentit, no es recomana l'ús del PDF ja que es tracta d'un format difícil d'analitzar per les màquines i, per tant, no permet la seva reutilització de manera senzilla.
- 6. No discriminatoris (*non-discrimination*).** Els conjunts de dades publicats han d'estar disponibles per a tothom i en qualsevol moment, sense necessitat d'identificar-se ni motivar l'accés.

7. Ús d'estàndards oberts en la difusió de la informació (*commonly owned or open standards*). Els conjunts de dades s'haurien de publicar en formats oberts, sense propietari a fi de garantir l'accés a tothom sense necessitat de disposar de llicència de programari.

8. Sense llicència (*licensing*). Els conjunts de dades publicats no haurien de sotmetre's a restriccions pel que fa a la seva reutilització i redistribució, és a dir, a determinades condicions d'ús del servei. Així doncs es recomana que la informació estigui disponible sense restriccions d'ús com a part del domini públic. Tanmateix, es poden establir excepcions raonables si hi ha aspectes relatius a la privacitat o la seguretat. (Cerrillo, 2014)

9. Permanència (*permanence*). Els conjunts de dades publicats haurien d'estar a disposició de forma permanent. En aquest sentit s'afirma que «*for best use by the public, information made available online should remain online, with appropriate version-tracking and archiving over time.*» (Sunlight Foundation, 2010 i 2017). Així mateix, en el cas que la informació s'actualitzés, canviés o eliminés s'hauria d'indicar.

Aquest principi es relaciona amb l'històric dels conjunts de dades i la capacitat de trobar la informació al llarg del temps. En última instància es vincula a la preservació dels *datasets*, és a dir, al conjunt de processos i operacions realitzats per a garantir el seu manteniment al llarg del temps; inclou, entre altres aspectes, la comprensibilitat de la informació i la conservació d'evidències que sostinguin la seva autenticitat.

10. Cost d'ús (*usage costs*)²⁴. Els conjunts de dades publicats han de ser accessibles o reutilitzables sense establir cap contraprestació a canvi, ja que la imposició de taxes al públic pot limitar el número de persones que poden o estan disposades a accedir a la informació, i també «*may preclude transformative uses of the data that in turn generates business growth and tax revenues.*» (Sunlight Foundation, 2010 i 2017)

²⁴ Convé destacar que la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic, preveu tant al preàmbul com a l'article 7 que en determinats casos les Administracions i organismes puguin exigir contraprestacions econòmiques per a facilitar la reutilització de les dades amb fins comercials. Tanmateix, la quantia ha de ser raonable i orientada al cost, és a dir, els ingressos obtinguts no poden superar els costos totals de recollida, producció, reproducció i difusió de les dades.

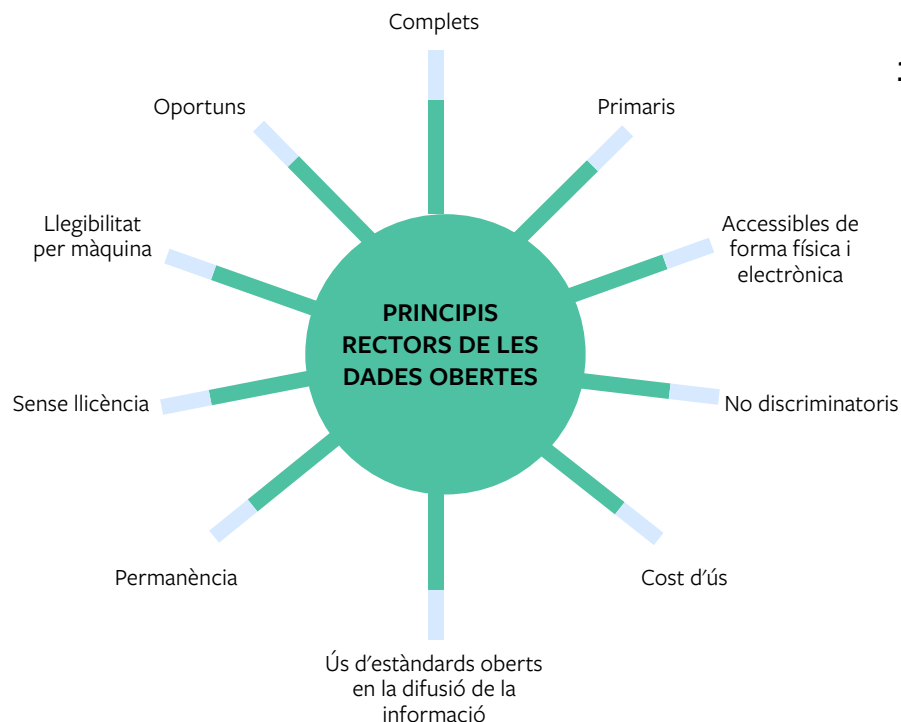


Figura 7. Els 10 principis rectoros de les dades obertes

(Font: Elaboració pròpia, 2021)

1. 2. 2. 1. Els principis de les dades obertes a l'ordenament jurídic espanyol

Tal com indica Agustí Cerrillo (2014) els principis de les dades obertes no es troben recollits explícitament en cap norma de l'ordenament jurídic espanyol. Tanmateix, a partir de la lectura de la normativa vigent es poden inferir un conjunt de principis relatius a la difusió i reutilització de les dades. En concret, Cerrillo (2014) identifica els principis aplicables que a continuació es mencionen; el detall dels quals s'ha ampliat a partir de l'anàlisi que s'ha fet del marc normatiu:

- 1. Accessibilitat.** Els conjunts de dades publicats han de ser accessibles i comprensibles. Així mateix, tal com s'indica tant a l'article 5.5 de la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic (en endavant, LRISP), i també a l'article 2.2 del Reial Decret 1495/2011, de 24 d'octubre, pel qual es desenvolupa la LRISP, tant els *datasets* com els mitjans electrònics de posada a disposició han de ser accessibles a les persones amb discapacitat, d'acord amb la normativa vigent d'aplicació sobre aquesta matèria. Així mateix, l'article 5.5 de la Llei 19/2013, de 9 de desembre, de transparència, accés a la informació pública i bon govern indica que la informació ha de ser comprensible i estar a disposició de les persones amb discapacitat, segons el principi d'accessibilitat universal i disseny per a tothom.

- 2. Qualitat.** Els conjunts de dades publicats han de satisfer les finalitats de transparència i reutilització, a més han de donar resposta a les necessitats dels usuaris. Altrament les dades han de ser completes, primàries, permanents i oportunes.

Les propietats abans esmentades es vinculen a la idea de que el concepte de qualitat de les dades és multidimensional, tal com es desenvolupa a l'apartat 1.4.3.

- 3. Responsabilitat.** Els portals de dades obertes han de garantir l'autenticitat i veracitat dels conjunts de dades publicats. A més, les Administracions i organismes han

d'establir mecanismes per a respondre en cas de que així no sigui o de que la informació publicada generi danys. No obstant, tal com es menciona a l'article 4.7 de la LRISP i a l'annex del Reial Decret 1495/2011, el sector públic institucional queda exclòs de responsabilitat davant l'ús dels *datasets* per part dels usuaris i dels danys a tercers que se'n puguin derivar d'aquesta utilització.

- 4. Seguretat.** Els conjunts de dades publicats han de garantir la seva integritat i conservació, i, per tant, que no es poden modificar per un tercer.

Al respecte, tant a l'article 8 de la LRISP com a l'article 7 del Reial Decret 1495/2011 s'indica, entre les condicions generals de reutilització, que el contingut de la informació, incloent les metadades associades, no es poden alterar. Així mateix, a l'apartat III de la NTI de Reutilització de recursos d'informació²⁵ s'explicita que s'han d'evitar les modificacions de la informació existent en la font, això implica que les dades han de ser primàries.

- 5. Neutralitat tecnològica.** Els conjunts de dades obertes s'han d'oferir en formats oberts i llegibles per màquina. A més, s'han de procurar conjuntament amb les seves metadades i en el nivell granular més fi possible.

Altrament a l'article 5.2 de la LRISP s'indica que tant els formats com les metadades han de complir amb estàndards i normes formals obertes. En concret, i tal com es defineix a l'annex III de la NTI de Reutilització de recursos d'informació, la representació semàntica es basa en el vocabulari DCAT, que es desplega en tres nivells: catàleg, *dataset* i distribució.

- 6. Eficàcia.** Els conjunts de dades publicats han de complir amb les finalitats pels quals han sigut generats a fi de facilitar la màxima transparència i reutilització. Tal com es preveu a l'article 5.4 de la Llei 19/2013, de 9 de desembre, de transparència, accés a la informació pública i bon govern, les dades que es difonen s'han de publicar de forma clara, estructurada i comprensible pels usuaris.

- 7. Interoperabilitat.** Els conjunts de dades publicats han de ser interoperables per tal de facilitar l'intercanvi de les dades i la seva reutilització.

Segons la NTI de Reutilització de recursos d'informació, així com la guia d'aplicació d'aquesta NTI, la interoperabilitat pot ser tant tècnica com semàntica. En relació a aquesta última, destaca l'ús d'un mateix vocabulari de metadades, anomenat DCAT, per tal que les dades

²⁵ Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la qual s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos d'informació.

intercanviades puguin ser interpretables de forma automàtica i reutilitzables mitjançant l'ús d'aquest model conceptual comú.

8. Protecció de dades personals. Els conjunts de dades publicats han de respectar el dret a la protecció de dades, d'acord amb la normativa vigent d'aplicació en aquesta matèria²⁶. Així mateix, la LRISP indica en el seu article 3.3 que la reutilització no és aplicable en determinats casos, per exemple, dades a les quals no es pot accedir o estan limitades degut a motius de protecció de dades, o perquè existeixen drets de propietat intel·lectual o industrial per part de tercers, o a causa de prohibicions o limitacions al dret d'accés segons regulació a l'article 14 de la Llei 19/2013, de 9 de desembre, de transparència, accés a la informació pública i bon govern, i també a la normativa autonòmica en la matèria. En el cas de Catalunya, els límits a la informació pública es troba regulat a la Llei 19/2014, del 29 de desembre, de transparència, accés a la informació pública i bon govern, en concret als articles 21, 23, 24 i 25.

Els principis esmentats es concreten en els Portals de dades obertes mitjançant els avisos legals, els quals s'han de concebre com un instrument de seguretat jurídica per als agents

reutilitzadors (Cerrillo, 2014). Així mateix, tal com s'indica a l'article 7 del Reial Decret 1495/2011, en aquests avisos legals s'ha d'informar de les condicions generals de posada a disposició dels conjunts de dades obertes, i s'ha de poder accedir-hi per mitjans electrònics, de forma permanent, fàcil i directa.



Figura 8. Els 8 principis de les dades obertes a l'ordenament jurídic espanyol (Font: Elaboració pròpia, 2021)

²⁶ És d'aplicació el Reglament (UE) núm. 2016/679 del Parlament Europeu i del Consell, de 27 d'abril de 2016, relatiu a la protecció de les persones físiques pel que fa al tractament de dades personals i a la lliure circulació d'aquestes dades i pel qual es deroga la Directiva 95/46/CE (RGPD); la Llei orgànica 3/2018, de 5 de desembre, de protecció de dades personals i garantia dels drets digitals i el Reial decret 1720/2007, de 21 de desembre, de protecció de dades de caràcter personal [aquest últim aplicable en tot allò que no s'oposi al RGPD].

1. 2. 3. Beneficis i barreres de l'obertura de dades obertes

Aquest apartat parteix de la idea de que la literatura sobre *open data* s'ha centrat en explorar els beneficis i les implicacions positives de l'obertura de dades obertes, mentre que els obstacles i les conseqüències negatives d'aquesta obertura han quedat en segon pla (Janssen, Charalabidis & Zuiderwijk, 2012; Kitchin, 2014). Per consegüent, i a fi de comprendre la situació actual de les polítiques de dades obertes, és important examinar tant els beneficis que se'n deriven de l'obertura com les barreres a superar i les crítiques que recentment han començat a sorgir entorn l'*open data*²⁷.

A continuació, a la **Taula 1** es presenta el llistat de fortaleeses i/o beneficis que se'n deriven de l'anàlisi de la literatura i que s'ha dividit en les tres categories identificades

per Janssen, Charalabidis & Zuiderwijk (2012): beneficis polítics i socials, beneficis econòmics i beneficis tècnics i operatius. Aquesta classificació és extensible als principals interessats que donen forma a l'ecosistema *open data* [sobre aquest tema es remet a l'apartat 1.3.2], que es poden dividir en proveïdors de dades (sector públic), intermediaris de dades (empreses infomediàries) i usuaris de dades (ciutadania en general, periodistes, investigadors/investigadores, etc.). Pel que fa al sector públic, convé subratllar la idea de que «*no es únicamente un gran proveedor de datos abiertos, sino que es también uno de los mayores usuarios y beneficiarios de la apertura de datos gubernamentales*», ja que utilitza les dades obertes per a retroalimentar-se, reflexionar, col·laborar, comprendre i aprendre. (APORTA, 2017, 3 i 30) Finalment cal esmentar que alguns dels beneficis identificats se superposen i/o es relacionen entre ells.

²⁷ Aquestes crítiques es sintetitzen en: a) les polítiques de dades obertes se sustenten en una ideologia política i econòmica determinada, que promou la neoliberalització i mercantilització dels serveis públics ja que, d'una banda, facilita que les empreses accedeixin a costosos productes obtinguts sense cost i, d'altra, a falta d'un model de finançament basat en les dades, el sector públic es veu obligat a subcontractar serveis al sector privat; b) les polítiques de dades obertes serveixen als interessos del capital, no a la construcció d'una societat més justa i equitativa, atès que s'obren les dades que més interessen a les empreses i, a més, no es té en compte els diferents nivells d'habilitats dels usuaris, la qual cosa contribueix a donar més poder als apoderats i reproduir i aprofundir els desequilibris de poder; c) les polítiques de dades obertes es caracteritzen per la falta de sostenibilitat, d'utilitat i d'usabilitat dels conjunts publicats, ja que els portals de dades obertes actuen com a repositoris de dades i no disposen de les eines i elements contextuais necessaris per a facilitar l'anàlisi de les mateixes.

És important subratllar que aquestes crítiques no suggereixen abandonar el moviment *open data*; al contrari, defensen que les iniciatives han de ser més conscients de com les dades estan disponibles, com s'utilitzen i com es financen (en Kitchin, 2014)

Categories	Beneficis	Fonts
(1) Beneficis polítics i socials	(1.1) Foment de la transparència i el retiment de comptes a l'obrir les dades a l'escrutini públic. Això permet el seguiment de les accions i decisions de govern, i també facilita la comprensió de les polítiques públiques.	UNE 178301:2015 (introducció) Directiva (UE) 2019/1024 (considerant 13) Llei 19/2014 (article 16) Open Data Handbook (s.a.) APORTA (2017) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012) Prado (2017)
	(1.2) Afavoreix la participació i la col·laboració ciutadana, és a dir, promou la democràcia participativa a través, per exemple, d'aplicacions i plataformes de participació. Altrament pot ser un instrument per a impulsar l'apoderament de la ciutadania mitjançant la presa de decisions més informades.	UNE 178301:2015 (introducció) Reial Decret 1495/2011 (preàmbul) NTI de RISP (preàmbul) Comissió Europea (2011) Open Data Handbook (s.d) APORTA (2017) Álvarez (2014) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.3) Permet recuperar la confiança de la ciutadania en els seus governs ja que, entre altres aspectes, apropa l'Administració pública a la societat civil.	APORTA (2017) Álvarez (2014) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.4) Desenvolupa el dret al coneixement com a principi bàsic de la democràcia. Altrament genera nou coneixement a partir de fonts de dades combinades i patrons en grans volums de dades.	Llei 37/2007 (preàmbul) Directiva (UE) 2019/1024 (considerant 43) Open Data Handbook (s.d) APORTA (2017) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.5) Optimitza l'eficiència i l'efectivitat de les organitzacions a partir de la millora de la planificació dels recursos disponibles, la col·laboració entre àrees departamentals, l'auditoria per al correcte ús dels recursos, la identificació d'àmbits de millora, la interoperabilitat de les dades i processos i l'adopció d'estàndards per a compartir i emmagatzemar dades. Així doncs, es fomenta l'eficiència operativa i la productivitat de les organitzacions a través del seguiment i la presa de decisions fonamentades en proves.	Comissió Europea (2011) APORTA (2017) Álvarez (2014) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012) Prado (2017)

Categories	Beneficis	Fonts
	(1.6) En relació amb la fortalesa anterior, es fomenta la millora i/o creació dels serveis que ofereixen les Administracions públiques, ja que la ciutadania es pot beneficiar de serveis de valor afegit basats en la RISP tal com prediccions meteorològiques personalitzades, informació cartogràfica digital, etc.	Llei 37/2007 (preàmbul) UNE 178301:2015 (introducció) Directiva (UE) 2019/1024 (considerant 16) Open Data Handbook (s.d) APORTA (2017) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.7) En relació amb les fortalezes (1.5) i (1.6), es fomenta la millora de la satisfacció i benestar social de la ciutadania.	Janssen, Charalabidis & Zuiderwijk (2012) Prado (2017)
	(1.8) Facilita la creació de productes i serveis per part d'empreses i de la ciutadania. Això permet, d'una banda, dinamitzar l'activitat econòmica i empresarial i, d'altra banda, generar valor per a la ciutadania al crear productes i serveis segons les seves necessitats. Es relaciona amb els beneficis (2.1) i (2.3)	Llei 37/2007 (preàmbul) UNE 178301:2015 (introducció) Directiva (UE) 2019/1024 (considerant 16) Open Data Handbook (s.d) APORTA (2017) Kitchin (2014)
	(1.9) Impulsa la innovació pública a partir de la identificació de patrons que recolzen la presa de decisions; el desenvolupament, implementació, seguiment i avaluació contínua de les polítiques públiques; i la millora de la qualitat de les dades a partir del <i>feedback</i> públic.	Llei 37/2007 (preàmbul) UNE 178301:2015 (introducció) Directiva (UE) 2019/1024 (considerant 16) Open Data Handbook (s.d) APORTA (2017) Kitchin (2014) Open Data Handbook (s.d) APORTA (2017) Janssen, Charalabidis & Zuiderwijk (2012)
(2) Beneficis econòmics	(2.1) Desenvolupament econòmic i creixement de l'ocupació de qualitat, en particular en benefici de les comunitats locals. També estimula la competitivitat. Es relaciona amb els beneficis (2.2) i (2.3)	Reial Decret 1495/2011 (preàmbul) NTI de RISP (preàmbul) Directiva (UE) 2019/1024 (considerant 13) Comissió Europea (2011) Álvarez (2014) Janssen, Charalabidis & Zuiderwijk (2012) Prado (2017)

Categories	Beneficis	Fonts
	<p>(2.2) Creació de nous serveis i productes i, per tant, de nous mercats que afavoreix el creixement econòmic. Segons l'informe del sector infomediari (2020), s'estima que el volum de negoci del sector infomediari està en alça des de l'any 2018, després d'una forta davallada en 2016 i 2017.</p> <p>Es relaciona amb els beneficis (1.8), (2.1) i (2.3)</p>	<p>Comissió Europea (2011) APORTA (2017) Asociación Multisectorial de la Información (ASEDIE) (2020) Álvarez (2014) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012)</p>
	<p>(2.3) Promou la col·laboració entre les parts. És a dir, compartir el coneixement contribueix a millorar l'eficàcia de les organitzacions i a desenvolupar nous models de negoci.</p> <p>Es relaciona amb els beneficis (1.5), (2.1) i (2.2).</p>	<p>Álvarez (2014) Janssen, Charalabidis & Zuiderwijk (2012)</p>
	<p>(2.4) Estimula la innovació dels productes i serveis fonamentat en noves formes de combinar i utilitzar la informació.</p> <p>Es relaciona amb els beneficis (2.1), (2.2) i (2.3)</p>	<p>Directiva (UE) 2019/2014 (considerant 16 i article 1) Álvarez (2014) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012) Prado (2017)</p>
(3) Beneficis tècnics i operatius	<p>(3.1) La capacitat de reutilitzar dades possibilita que les mateixes dades no s'hagin de recopilar novament i, per tant, contraresta duplicacions innecessàries i costos associats.</p>	<p>Janssen, Charalabidis & Zuiderwijk (2012)</p>
	<p>(3.2) Optimitza els processos administratius i de prestació de serveis.</p> <p>Es relaciona amb el benefici (1.5)</p>	<p>Comissió Europea (2011) APORTA (2017) Kitchin (2014) Janssen, Charalabidis & Zuiderwijk (2012)</p>
	<p>(3.3) Fomenta la millora de les polítiques públiques i contribueix a un funcionament eficient.</p> <p>Es relaciona amb el benefici (1.5)</p>	<p>Álvarez (2014) Janssen, Charalabidis & Zuiderwijk (2012)</p>
	<p>(3.4) Contribueix a la presa de decisions més justes i informades al permetre la comparació. Així mateix, es relaciona amb el concepte d'intel·ligència competitiva (IC), entesa com l'activitat d'obtenció i tractament d'informació estratègica per a la presa de decisions.</p> <p>Es relaciona amb els beneficis (1.5), (1.9) i (2.1)</p>	<p>García (2015) Janssen, Charalabidis & Zuiderwijk (2012)</p>
	<p>(3.5) Possibilita un accés més fàcil a les dades i també el descobriment de conjunts de dades, a través dels catàlegs de dades obertes.</p>	<p>Janssen, Charalabidis & Zuiderwijk (2012)</p>

Categories	Beneficis	Fonts
	(3.6) Fomenta la creació de noves dades a partir de la combinació de dades. Es relaciona amb el benefici (2.4)	Janssen, Charalabidis & Zuiderwijk (2012)
	(3.7) Possibilita comprovacions/validacions externes de la qualitat de les dades, la qual cosa permet la seva millora. Es relaciona amb el benefici (1.9)	APORTA (2017) Janssen, Charalabidis & Zuiderwijk (2012)
	(3.8) Impulsa la capacitat de fusionar, integrar i combinar dades públiques i privades. Així mateix, se sosté que la veritable potència econòmica s'obté combinant les dades de caràcter públic amb informació d'empreses privades, la qual cosa fomenta la creació de nous productes o serveis. Es relaciona amb els beneficis (1.8), (2.1), (2.2), (2.3) i (2.4)	Álvarez (2014) Janssen, Charalabidis & Zuiderwijk (2012)

Taula 1. Beneficis de l'obertura de dades obertes. (Font: Elaboració pròpia, 2021)

A continuació, a la **Taula 2** es presenta el llistat d'obstacles que se'n deriven de l'anàlisi de la literatura i que s'ha dividit en les sis categories identificades per la Comissió Europea (2020): barreres polítiques, barreres organitzacionals, barreres financeres, barreres de conscienciació, barreres legals i barreres tècniques. Pel que fa a les barreres polítiques s'ha cregut oportú afegir també el terme cultural ja que alguns dels obstacles descrits es relacionen

amb aspectes de la cultura de les organitzacions, tal com identifica APORTA (2017). Per tant, aquest grup quedaria com a barreres polítiques i culturals. En relació amb l'ecosistema *open data*, és important senyalar que aquestes sis categories apliquen tant als proveïdors de dades com als usuaris de les mateixes. Finalment convé destacar que alguns dels obstacles identificats se superposen i/o es relacionen entre ells.

Categories	Obstacles/Barreres	Fonts
(1) Barreres polítiques i culturals	(1.1) Falta de voluntat política que es pot relacionar amb diversos factors, com per exemple, a la falta de recursos o la falta de coneixença sobre el valor i potencials beneficis de l'obertura de les dades obertes. Es relaciona amb els obstacles (1.2), (2.5), (5.1) i (5.2)	APORTA (2017) Comissió Europea (2011, 2020) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.2) Por a la pèrdua de control de les dades. Aquest temor es relaciona amb l'aversion al canvi, per la qual cosa, és important gestionar el canvi cultural com un aspecte rellevant de la implementació d'una política de dades obertes per part de les organitzacions. Es relaciona amb els obstacles (1.1), (1.4), (6.1) i (6.2)	APORTA (2017) Comissió Europea (2011, 2020) Almansa (2017) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.3) Falta d'una política uniforme per a la publicació de conjunts de dades que es relaciona amb l'estructura i organització polítiques. En el cas d'Espanya, tot i disposar —a través de la iniciativa APORTA— d'un catàleg nacional que actua com a pont entre les diferents Administracions, les empreses i la ciutadania, la realitat es que les polítiques d'obertura de dades obertes divergeixen entre entitats. En aquest sentit, al document <i>Estudio del Sector Infomediario 2014</i> s'identifica la impossibilitat d'accedir a informació homogènia en les diferents Comunitats Autònomes com la major barrera per a les empreses reutilitzadores. Es relaciona amb l'obstacle (3.1)	APORTA (2017) Comissió Europea (2020) ONTSI (2014) Janssen, Charalabidis & Zuiderwijk (2012)
	(1.4) Falta d'equilibri entre valors públics (transparència vs protecció de dades). Això genera un clima de desconfiança i limita l'obertura de dades fonamentant-se en la protecció de dades, la privacitat i la seguretat. Es relaciona amb els obstacles (1.2) i (3.3)	Almansa (2017) Janssen, Charalabidis & Zuiderwijk (2012)

Categories	Obstacles/Barreres	Fonts
(2) Barreres organitzacionals	(2.1) Necessitat d'institucionalitzar la publicació de dades obertes. Per a fer-ho, la publicació ha de transformar-se en una part integral del procés de creació de dades, en lloc d'una activitat separada dels processos i rutines. Es vincula a la millora de la governança de dades, l'actualització i automatització dels fluxos de treball.	Comissió Europea (2020)
	(2.2) Foment dels interessos de les organitzacions en lloc dels interessos de la ciutadania. En aquest sentit, al document <i>Estudio del Sector Infomediario 2014</i> s'identifica la falta d'interès de les AAPP per conèixer les necessitats de les empreses com una de les barreres pel sector infomediari.	Comissió Europea (2020) ONTSI (2014) Janssen, Charalabidis & Zuiderwijk (2012)
	(2.3) Necessitat d'alinejar l'organització interna amb l'ús de les dades obertes, és a dir, les organitzacions han d'integrar l'ús de les dades obertes en els seus processos operatius. Aquest canvi implica tant un augment de recursos, humans i econòmics, com una nova estructura organitzativa.	Comissió Europea (2020)
	(2.4) Falta d'habilitats per part de les AAPP per a produir i publicar dades, especialment els nivells més inferiors (municipis). Altrament, aquesta falta de formació i capacitat també és aplicable als usuaris de dades que requereixen de certes habilitats per aprofitar al màxim el potencial de les dades obertes. Es relaciona amb l'obstacle (6.2)	Almansa (2017) Comissió Europea (2020) Janssen, Charalabidis & Zuiderwijk (2012)
	(2.5) Falta d'interacció i de coordinació entre les parts que conformen l'ecosistema <i>open data</i> . La millora de la interacció entre proveïdors i intermediaris/usuaris de dades pot permetre, d'una banda, que els proveïdors coneguin quins conjunts de dades són més valuosos i s'han d'obrir primer i, d'altra banda, millorar la qualitat de les mateixes davant problemes dels quals han informat els usuaris. Convé destacar que al document <i>Estudio del Sector Infomediario 2014</i> s'identifiquen la falta de resposta de les AAPP davant la informació no disponible i la falta de criteri a l'hora d'oferir la informació com a barreres pel sector infomediari. Es relaciona amb l'obstacle (1.1)	Comissió Europea (2020) ONTSI (2014) Janssen, Charalabidis & Zuiderwijk (2012)

Categories	Obstacles/Barreres	Fonts
(3) Barreres legals	(3.1) Existeixen diferències significatives en les normes i pràctiques nacionals, la qual cosa genera una fragmentació del mercat interior de la informació i dificulta la creació de serveis d'informació transfronterers. Es relaciona amb l'obstacle (1.3)	Comissió Europea (2011, 2020)
	(3.2) Falta completar la regulació sobre la matèria, a fi d'evitar tant les llacunes legals existents com la inseguretat jurídica que aquestes puguin provocar.	APORTA (2017) Almansa (2017)
	(3.3) Falta d'equilibri entre l'obertura de conjunts de dades i la privacitat, a favor d'aquest últim valor. La falta d'una regulació clara al respecte és una barrera per a la reutilització de les dades. Es relaciona amb l'obstacle (1.4)	Comissió Europea (2020) Janssen, Charalabidis & Zuiderwijk (2012)
	(3.4) En alguns casos, falta de llicència per a utilitzar les dades. Sense llicència, les dades publicades no són realment obertes ja que no es poden ni reutilitzar ni redistribuir. Es relaciona amb l'obstacle (4.1)	Comissió Europea (2020) Janssen, Charalabidis & Zuiderwijk (2012)
	(3.5) En altres casos, les llicències presenten condicions que limiten l'ús i redistribució de les dades. O inclús es requereix un permís previ per escrit per a la reutilització de les dades. Es relaciona amb l'obstacle (4.1)	Comissió Europea (2020) Janssen, Charalabidis & Zuiderwijk (2012)
	(3.6) Els avisos legals que hi ha en els portals de dades obertes són confusos i no promouen l'efectiva reutilització dels conjunts de dades publicats. La falta de claredat genera inseguretat jurídica als agents reutilitzadors.	Cerrillo (2014)
(4) Barreres tècniques	(4.1) Baixa qualitat de les dades obertes que inclou, sense caràcter limitatiu, conjunts de dades desactualitzats o incomplets, la qual cosa repercuteix en la fiabilitat i usabilitat de les dades, i, en última instància, pot ocasionar un potencial perjudici a tercers. Es relaciona amb els obstacles (3.4), (3.5) i (4.4)	APORTA (2017) Comissió Europea (2020) ONTSI (2014) Janssen, Charalabidis & Zuiderwijk (2012)

Categories	Obstacles/Barreres	Fonts
(4) Barreres tècniques	(4.2) Falta d'estandardització en els formats de les dades publicades. Altrament un percentatge de conjunts de dades es publiquen en formats no reutilitzables, el que suposa, d'una banda, poca interoperabilitat, i d'altra banda, dificulta la reutilització i redistribució d'aquests conjunts. Es relaciona amb l'obstacle (4.3)	Comissió Europea (2020) ONTSI (2014) Almansa (2017) Janssen, Charalabidis & Zuiderwijk (2012)
	(4.3) Carència d'estàndards tècnics i semàntics. Pel que fa als estàndards tècnics, manca d'un estàndard únic que hagi sigut àmpliament acceptat i implementat, pel que fa a formats, interfícies i sistemes de comunicació per a permetre l'intercanvi automatitzat de la informació. En quant a les qüestions semàntiques falta d'estàndards de descripció de dades (models semàntics) àmpliament utilitzats. Aquestes carències perjudiquen la interoperabilitat tant tècnica com semàntica. Es relaciona amb els obstacles (4.1), (4.2) i (4.4)	APORTA (2017) Comissió Europea (2011, 2020) Almansa (2017) Janssen, Charalabidis & Zuiderwijk (2012)
	(4.4) Baixa qualitat de les metadades que es caracteritza, d'una banda, per una gran disparitat en la forma en la que els portals ofereixen les metadades i, de l'altra, per conjunts de dades que no s'acompanyen de la informació de context que explica l'origen, l'àmbit, l'abast i les característiques de les dades publicades a fi de millorar la seva comprensió per part dels usuaris. Aquests aspectes repercuteixen tant en la fiabilitat dels conjunts de dades per part dels usuaris, com en la interoperabilitat de la informació. Es relaciona amb els obstacles (4.1) i (4.3)	Comissió Europea (2020) Peset & Fernández-López (2014) Janssen, Charalabidis & Zuiderwijk (2012)
	(4.5) Els sistemes d'informació (SSII) de les AAPP no estan preparats per a publicar dades obertes per defecte, la qual cosa pot generar dispersió d'informació i falta d'interoperabilitat entre diferents SSII. A més, la infraestructura tècnica resulta insuficient, tant per mantenir l'emmagatzematge i subministrament de dades de forma continua, com per disposar de la capacitat de resposta davant les noves demandes i necessitats de tercers.	APORTA (2017) Almansa (2017) Janssen, Charalabidis & Zuiderwijk (2012)

Categories	Obstacles/Barreres	Fonts
	(4.6) Dificultats per a descobrir conjunts de dades per part dels usuaris, que es relaciona amb els nivells de qualitat en les descripcions dels <i>datasets</i> així com en la pluralitat de plataformes on les dades es poden localitzar.	Comissió Europea (2020) Janssen, Charalabidis & Zuiderwijk (2012)
(5) Barreres financeres	(5.1) Resistència a la publicació com a dades obertes d'aquells conjunts de dades que ja suposen ingressos públics. Això es relaciona amb el model de generació d'ingressos públics on les dades formen part del model de finançament públic, i la publicació de dades obertes (que es recomana que siguin d'accés lliure i gratuït) limita aquest model. Es relaciona amb l'obstacle (1.1)	APORTA (2017) Comissió Europea (2020)
	(5.2) Falta de finançament, és a dir, necessitat de fons addicionals per a la implementació d'una política de dades obertes, que requereix d'inversions en infraestructura, persones i processos. A més, aquest finançament s'ha de mantenir en el temps i ha de ser sostenible a fi de garantir la perdurabilitat de les polítiques <i>open data</i> . Es relaciona amb els obstacles (1.1) i (5.3)	Comissió Europea (2020)
	(5.3) Pagament d'una tarifa per a la reutilització i redistribució dels conjunts de dades publicats, basat en la implementació d'un model de recuperació de costos per part de les Administracions. Aquest model dificulta l'accés i la reutilització de les dades, especialment als col·lectius amb menys capacitat econòmica. Es relaciona amb l'obstacle (5.2)	Comissió Europea (2020) Almansa (2017) Janssen, Charalabidis & Zuiderwijk (2012)
(6) Barreres de conscienciació	(6.1) Falta de coneixement entorn la rellevància i l'impacte de les dades obertes, sent els seus beneficis poc clars per a la vida quotidiana. A més, en relació amb aquesta falta de coneixement poden sorgir qüestions relacionades amb la privacitat, l'anonimització i el consentiment. Es relaciona amb els obstacles (1.2) i (6.2)	Comissió Europea (2020) Almansa (2017)

Categories	Obstacles/Barreres	Fonts
	(6.2) Aversió al canvi. Necessitat de promoure un canvi cultural per part dels proveïdors de dades i també de formar a personal expert en les Administracions per a la publicació de dades obertes, a fi d'impulsar les polítiques <i>open data</i> . Es relaciona amb els obstacles (1.2), (2.4) i (6.1)	APORTA (2017) Comissió Europea (2020)
	(6.3) Poques activitats de sensibilització sobre la disponibilitat de les dades obertes i els beneficis de la reutilització de la informació del sector públic.	Comissió Europea (2020)

Taula 2. Barreres de l'obertura de dades obertes. (Font: Elaboració pròpia, 2021)

1. 2. 4. Polítiques de dades obertes i gestió documental

Segons Prado (2017), en el marc de les polítiques *open data* «uno de los principales desafíos para las actuales administraciones públicas es lograr una eficaz y eficiente gestión de los datos que de modo masivo²⁸ atesoran, abrirlos para que puedan ser conocidos y reutilizados, y enlazarlos²⁹ con los de otras entidades para enriquecerlos e

incrementar su valor.» (p. 5) Una de les principals estratègies per superar aquest desafiament és la vinculació dels sistemes de gestió de dades amb els sistemes de gestió de documents (SGD). Al respecte, convé aclarir que un sistema de gestió documental és definit segons la norma ISO 15489-1:2016 com un «sistema de informació que captura, gestiona y facilita el acceso a los documentos a lo largo del tiempo.» (p. 9) Un altre exemple de definició el trobem en el Codi deontològic dels arxivers catalans (2002) on es

²⁸ Les dades massives (*big data*) són el conjunt d'infraestructures, tecnologies i serveis que possibiliten la gestió i anàlisi de grans volums de dades (Prado, 2017). Les característiques que defineixen al Big Data es poden sintetitzar en les 4V: volum, varietat, velocitat i veracitat. (Fundación Telefónica, 2018). Posteriorment s'han afegit tres atributs més, com són la viabilitat, la visualització i el valor de les dades (Instituto de Ingeniería del Conocimiento, 2016)

²⁹ El concepte de dades enllaçades o vinculades (*linked data*, en anglès) fou proposat per Tim Berners-Lee i descriu un conjunt de pràctiques recomanades per a publicar i interconnectar dades estructurades en la web. Aquesta proposta es basa en tecnologies estàndards del W3C com un protocol HTTP, un model de dades RDF i l'identificador uniforme de recursos (URI) (CRUE, 2017). Convé destacar que no totes les dades enllaçades són obertes, i a la inversa. Així mateix, per aconseguir dades obertes vinculades (*linked open data*) aquestes han de complir amb l'esquema de cinc estrelles de Berners-Lee que permet mesurar el grau d'obertura i usabilitat dels conjunts de dades publicats. En concret, les dades obertes vinculades se situarien a l'últim nivell (5 estrelles) de l'esquema, tal com s'indica a <https://5stardata.info/es/>

precisa que un SGD és «*el conjunt d'operacions i de tècniques, integrades en la gestió administrativa general, basades en l'anàlisi de la producció, la tramitació i els valors dels documents, que es destinen a la planificació, el control, l'ús, la conservació i l'eliminació o la transferència dels documents a un arxiu, amb l'objectiu de racionalitzar-ne i unificar-ne el tractament i aconseguir-ne una gestió eficaç i rendible*» (p. 11) En els mateixos termes és descrit aquest concepte en el *Diccionario de Archivística* elaborat per José Ramón Cruz (2011). A banda d'això, Prado (2017) ressalta que al SGD, regit per una Política de gestió de documents electrònics (PGDE)³⁰ aprovada i impulsada per l'alta direcció, li correspon —sense caràcter limitatiu—:

- Garantir l'autenticitat, integritat, confidencialitat, qualitat, disponibilitat, protecció i conservació a llarg termini dels documents electrònics i, per tant, de les dades.
- Identificar i vincular les dades i documents amb el seu context de producció.
- Aplicar les polítiques de disposició i acreditar una eliminació segura i controlada dels documents i les dades, en aplicació de les TAAD associades.

Així mateix, tal com s'ha vist a l'apartat 1.1.1, el terme document fixat tant a les normes ISO 15489 i 30300 com a la llei 37/2007 presenta una definició tan àmplia que admet qualsevol actiu d'informació; per tant, sota aquesta concepció es pot inferir que els SGD no només es poden desplegar sobre els documents (en la seva visió “tradicional”), sinó que funcions com «*(...) la creación, la captura, el registro, la clasificación, la descripción, la conservación, la calificación o la destrucción de documentos podrían aplicarse a cualquier recurso de información, lote de datos, contenido web u otros activos informativos identificados.*» (Moyano, 2015, 47)

Partint d'aquesta premissa, hi ha diverses veus professionals que posen de manifest la necessitat d'interrelacionar les polítiques *open data* amb els SGD (Thurston, 2012; Cerdá, 2013, 2015; Prado, 2017; Fernández, 2016). En particular, Anne Catherine Thurston (2012) exposa que el treball inicial sobre dades obertes s'ha centrat en la publicació de *datasets* sense una metodologia que garanteixi l'exactitud, confiabilitat i traçabilitat d'aquestes dades a fonts d'informació fiables. A fi de resoldre aquest problema, advoca per integrar aquestes dades als SGD ja que les dades haurien de derivar de documents que fossin autèntics, íntegres i disponibles. Així doncs, a l'examinar els conjunts de dades publicats en el marc de les polítiques *open*

30 Segons la Guia d'aplicació de la NTI de Política de gestió de documents electrònics, la PGDE és un document que conté «*orientaciones o directrices que define una organización para la creación y gestión de documentos auténticos, fiables y disponibles a lo largo del tiempo, de acuerdo con las funciones y actividades que le son propias. La política se aprueba al más alto nivel dentro de la organización, y asigna responsabilidades en cuanto a la coordinación, aplicación, supervisión y gestión del programa de tratamiento de los documentos a través de su ciclo de vida.*» (2016, 41)

data senyala que «*need to be asked about the veracity of the data available and the relationship of the data to the records that should support it.*» (p. 3)

Certament la importància dels SGD en el garantiment de l'autenticitat, integritat, fiabilitat, usabilitat, traçabilitat, confidencialitat i la conservació a llarg termini de les dades i la informació també ha sigut percebuda pel legislador, ja que a l'article 4.5 de la llei 37/2007 s'esmenta que «*las Administraciones y organismos del sector público crearán sistemas de gestión documental que permitan a los ciudadanos la adecuada recuperación de la información, disponibles en línea y que enlacen con los sistemas de gestión puestos a disposición de los ciudadanos por otras Administraciones (...)*» (p. 7) Altrament, tal com remarca Prado (2017) una gestió documental electrònica obliga a disposar d'una infraestructura tecnològica que li doni suport; en concret, a l'article 21.2 del Reial Decret 4/2010, de 8 de gener, pel qual es regula l'Esquema Nacional d'Interoperabilitat en l'àmbit de l'Administració Electrònica s'indica que «*(...) las Administraciones públicas crearán repositorios electrónicos, complementarios y equivalentes en cuanto a su función a los archivos convencionales, destinados a cubrir el conjunto del ciclo de vida de los documentos electrónicos*»; així mateix, les lleis 39/2015 (article 17) i 40/2015 (article 46) obliguen a que tots els documents utilitzats en les actuacions

administratives s'emmagatzemin per mitjans electrònics, i a l'efecte d'acomplir amb aquest deure cada Administració haurà de mantenir un arxiu electrònic únic dels documents electrònics que corresponguin a procediments finalitzats. A més, aquests mitjans electrònics han de disposar de mesures de seguretat, d'acord amb el que preveu l'Esquema Nacional de Seguretat, que garanteixin la integritat, autenticitat, confidencialitat, qualitat, protecció i conservació dels documents emmagatzemats; així com el compliment, entre altres aspectes, de la legislació en matèria de protecció de dades. En relació amb aquests repositoris segurs de confiança, hi ha professionals que subratllen la seva importància com a proveïdors dels portals de dades obertes, la qual cosa suposa que la interoperabilitat entre ambdós sistemes d'informació és un requisit imprescindible (Thurston, 2012; Prado, 2017). Tanmateix, tal com sosté Moyano (2015) la pràctica ha sigut deixar aquests repositoris al marge dels portals *open data*, fet que ha creat una bretxa entre tots dos sistemes; a més d'una separació entre els drets d'accés, ús i reutilització que emanen de les polítiques de dades obertes dels drets que dimanen de l'arxivística i la gestió documental, que són els que es desprenen del Codi deontològic dels arxivers catalans (2002), és a dir, els drets a la cultura, a la informació, a l'accés, a la consulta i a l'ús, així com la protecció de les dades personals, de la propietat intel·lectual i del dret a la intimitat personal i familiar.

En darrer terme, convé remarcar que la vinculació dels sistemes de gestió documental —i de la gestió documental³¹ en si— amb les polítiques de dades obertes és una estratègia que genera diversos avantatges, tal com s’infereix de l’anàlisi de la literatura i que, a continuació, es recapitula a la **Taula 3**:

Beneficis	Fonts
La vinculació assegura una font primària de dades públiques, de qualitat, autèntiques, fidedignes, actualitzades i disponibles al llarg del temps. Aquestes dades s’alliberen per a la seva reutilització i redistribució en un context de govern obert, on adquireixen un nou valor polític, cultural, social i econòmic. Paral·lelament es maximitzen els beneficis de la gestió documental al fer-los extensius a la societat i transformant la gestió de les dades obertes en una <i>res publica</i> .	Cerdá (2013, 2015) Prado (2017)
La vinculació assegura la generació i difusió de dades de major qualitat, disponibles, usables, autèntiques, íntegres i fiables. És a dir, garanteix que les dades que es publiquen són evidència fidedigna de les actuacions administratives que els produeixen o reben. En relació amb la qualitat, Casellas (2016) sosté que els SGD són un primer filtre de control de la qualitat ja que l’objectiu primari és la creació de documents de qualitat i si això es garanteix, serà més fàcil extraure conjunts de dades de qualitat.	Bustelo (2018) Casellas (2016) Cerdá (2013 i 2015) Fernández (2016) Prado (2017)
La vinculació evidencia la relació existent entre les dades i el seu context de producció. Així doncs, es facilita la relació — i la representació de dita relació — dels <i>datasets</i> amb el seu context orgànic, funcional i de control en el que es produeixen/reben i gestionen. Altrament no només és important documentar el context de creació, sinó també la relació entre els sistemes d’informació. Finalment, convé subratllar que la publicació de dades obertes amb context i procedència genera confiança i autenticitat en les mateixes.	Casellas (2016) Fernández (2016) Prado (2017) Thurston (2012)
La vinculació proporciona antecedents i continuïtat als conjunts de dades, la qual cosa facilita la publicació de sèries històriques.	Prado (2017)

31 En quant a la gestió documental és important subratllar la seva importància no només pel que fa a les polítiques *open data*, sinó també en relació a l’*open government*. Aquesta vàlua ha sigut percebuda per diferents administracions, un bon exemple d’això és el memoràndum presidencial del govern d’Obama (*Presidential Memorandum – Managing Government Records*, 2011) en el qual s’afirma que la gestió de documents és la columna vertebral del govern obert ja que permet: 1) millorar l’eficiència de l’organització; 2) promoure l’obertura i el retiment de comptes al documentar millor les accions i decisions de l’organització; 3) avaluar l’impacte dels programes; 4) reduir esforços redundants; 5) estalviar diners i 6) compartir coneixements dins la mateixa organització però també entre organitzacions.

Beneficis	Fonts
<p>La vinculació facilita la reutilització, el lliure accés i l'explotabilitat de les dades, entesa aquesta explotabilitat com «la capacidad de un conjunto de datos extraídos de un sistema de información para preservar su valor informativo y aprovechar su potencial fuera del sistema en el que fue creado.» (Casellas, 2016, 166) Aquesta capacitat es relaciona amb la descripció i documentació de l'estructura de dades, amb el context de producció i amb el garantiment de les característiques d'autenticitat, integritat, fiabilitat i usabilitat de les dades.</p>	<p>Casellas (2016) Cerdá (2013 i 2015)</p>
<p>La vinculació facilita la preservació de les dades a partir de la gestió del cicle de vida dels actius d'informació. Per tal de desenvolupar-ho el primer pas és identificar aquesta informació, mitjançant el Catàleg d'actius d'informació —del qual sorgirà el Catàleg de dades obertes amb els conjunts publicats— (Casellas, 2016) o el Catàleg d'informació pública (Cerdá, 2013 i 2015). Aquest instrument permet identificar i avaluar els actius d'informació, preservar la seva autenticitat, i extraure dades de forma regular i normalitzada sota la forma documental de registre a fi d'incorporar-los al SGD. Així mateix, la identificació d'aquests conjunts permet un control més efectiu i eficient dels mateixos, i també facilita l'aplicació sistemàtica dels requisits que estableix la NTI de Reutilització de recursos d'informació sobre aquests conjunts.</p>	<p>Casellas (2016) Cerdá (2013 i 2015)</p>
<p>La vinculació facilita un control més efectiu i complet dels actius que contenen dades personals, així com l'aplicació de procediments d'anonimització d'aquestes dades, per exemple en la fase de disseny dels processos d'extracció.</p>	<p>Casellas (2016)</p>
<p>La vinculació garanteix l'aplicació de calendaris de conservació i accés sobre aquests actius, així com l'aplicació de procediments per a la seva correcta disposició.</p>	<p>Casellas (2016)</p>

Taula 3. Avantatges de la vinculació entre SGD i polítiques de dades obertes. (Font: Elaboració pròpia, 2021)

1. 2. 5. Marc normatiu de referència

Tal com s'ha vist en apartats anteriors, l'obertura de dades públiques no ha sigut objecte de regulació jurídica específica. En aquest sentit, a continuació es presenta el marc legal europeu, estatal i autonòmic català en matèria de reutilització de la informació del sector públic (RISP). També s'incorporen el marc regulador en matèria de transparència i accés a la informació pública, atès que

es tracta de lleis rellevants per a l'impuls de les polítiques d'obertura de dades obertes; les normes relacionades amb la protecció de dades al tractar-se d'un àmbit que cal tenir en consideració en els projectes *open data*, a fi de no publicar dades que puguin associar-se i identificar a una persona física; i la regulació específica en matèria d'Administració digital. Finalment s'inclouen els estàndards i bones pràctiques que es vinculen directament a les dades obertes i la RISP.

Normativa europea

- Directiva 2003/98/CE del Parlament Europeu i del Consell, de 17 de novembre de 2003, relativa a la reutilització de la informació del sector públic (OJ L 345, 31/12/2003, p. 90–96) [Aquesta directiva queda derogada per la Directiva (UE) 2019/1024 amb efectes a partir del 17 de juliol de 2021]
- Directiva 2013/37/UE del Parlament Europeu i del Consell, de 26 de juny de 2013, per la que es modifica la Directiva 2003/98/CE relativa a la reutilització de la informació del sector públic (OJ L 175, 27/06/2013, p. 1–8)
- Reglament (UE) 2016/679 del Parlament Europeu i del Consell, de 27 d'abril de 2016, relatiu a la protecció de les persones físiques pel que fa al tractament de dades personals i a la lliure circulació d'aquestes dades i pel qual es deroga la Directiva 95/46/CE (Reglament general de protecció de dades) (OJ L 119, 04/05/2016, p. 1–88)
- Directiva (UE) 2019/1024 del Parlament Europeu i del Consell, de 20 de juny de 2019, relativa a les dades obertes i la reutilització de la informació del sector públic (OJ L 172, 26/06/2019, p. 56–83) [Els Estats membres tenen com a molt tard fins el 17 de juliol de 2021 per a realitzar la transposició de la directiva europea]

Normativa estatal

- Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic («BOE» núm. 276, de 17/11/2007, p. 47160–47165)
- Reial decret 1720/2007, de 21 de desembre, de protecció de dades de caràcter personal («BOE» núm. 17, de 19/01/2008) [Aplicable en allò que no s'oposi al Reglament (UE) 2016/679]
- Reial Decret 1495/2011, de 24 d'octubre, pel qual es desenvolupa la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic, per a l'àmbit del sector públic estatal («BOE» núm. 269, de 08/11/2011, p. 116296–116307)
- Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos de la informació («BOE» núm. 54, de 04/03/2013, p. 17045–17071)
- Correcció d'errors de la Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos de la informació («BOE» núm. 132, de 03/06/2013, p. 41898–41899)

- Llei 19/2013, de 9 de desembre, de transparència, accés a la informació pública i bon govern («BOE» núm. 295, de 10/12/2013)
- Llei 18/2015, de 9 de juliol, per la qual es modifica la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic («BOE» núm. 164, de 10/07/2015, p. 57436–57450)
- Llei Orgànica 3/2018, de 5 de desembre, de Protecció de Dades Personals i garantia dels drets digitals («BOE» núm. 294, de 06/12/2018, p. 119788–119857)

Normativa autonòmica catalana

- Llei 19/2014, del 29 de desembre, de transparència, accés a la informació pública i bon govern (DOGC, núm. 6780, de 31/12/2014)
- Decret 76/2020, de 4 d'agost, d'Administració digital (DOGC, núm. 8195, de 06/08/2020)
- Decret 8/2021, de 9 de febrer, sobre la transparència i el dret d'accés a la informació pública (DOGC, núm. 8339, de 11/02/2021)

Estàndards i bones pràctiques

- UNE 178301:2015 Ciudades Inteligentes. Datos Abiertos (*Open Data*)

1.3. Marc teòric de la perspectiva sistèmica: teoria de sistemes i cibernètica

1.3.1. Concepte, tipus i característiques dels sistemes

Segons Bertalanffy (1968, reimpr. 1989) un sistema «puede ser definido como un complejo de elementos interactuantes» (p. 56) o també «como un conjunto de elementos interrelacionados entre si y con el medio circundante.» (p. 263) En termes semblants s'expressa la norma ISO 9000:2015 al conceptualitzar un sistema com un conjunt d'elements interrelacionats o que interactuen. D'aquestes definicions es dedueix que una de les propietats essencials de qualsevol sistema és la interacció, que suposa que les relacions que s'estableixen entre els components d'un sistema són biunívocues (Thomas, 1993)

$$A \leftrightarrow B$$

$$A \rightarrow B$$

$$B \rightarrow A$$

Figura 9. Representació de la interacció (Font: Adaptació a partir de Thomas, 1993)

Des d'un punt de vista matemàtic, un sistema es pot definir segons el conjunt d'equacions diferencials simultànies³² que es reproduïx a la **Figura 10**, on Q_i representa alguna magnitud d'elements p_i ($i=1,2,\dots,n$), per a un número finit d'elements; i f_i simbolitza les funcions, és a dir, les relacions i interaccions dins el sistema (Bertalanffy, 1989, 56).

32 Una equació diferencial (ED) és una equació que relaciona una funció (o variable dependent), la seva variable o variables (variables independents) i les seves derivades. Hi ha de dos tipus: si l'equació conté derivades en relació a una sola variable independent, s'anomena equació diferencial ordinària (EDO); mentre que si conté derivades parcials respecte a dos o més variables independents és una equació diferencial en derivades parcials (EDP). (Varona, 1996)

33 Aquest conjunt d'equacions presenta dues limitacions: primerament, en la representació es prescindeix de condicions espacials i temporals que s'haurien d'expressar mitjançant equacions diferencials en derivades parcials; i, segonament no s'estableixen afirmacions en relació a la naturalesa de les magnituds o de les funcions —o sigui pel que fa a la naturalesa del sistema, dels seus elements o de les relacions existents entre ells—. (Bertalanffy, 1989, 57, 86 i 264)

$$\frac{dQ_1}{dt} = f_1(Q_1, Q_2, \dots, Q_n)$$

$$\frac{dQ_2}{dt} = f_2(Q_1, Q_2, \dots, Q_n)$$

$$\frac{dQ_n}{dt} = f_n(Q_1, Q_2, \dots, Q_n)$$

Figura 10. Conjunt d'equacions que representen un sistema (Font: Bertalanffy, 1968, reimpr. 1989, 56)

Malgrat no és objecte d'aquesta investigació entrar en disquisicions teòriques en relació a les matemàtiques i les ciències de la computació; és important destacar que el sistema d'equacions anterior³³ s'engloba dins el tipus d'equació diferencial ordinària on dQ_n/dt designa la derivada de Q_n respecte a la derivada de t . Altrament en la fórmula $dQ_n/dt = f_n(Q_1, Q_2, \dots, Q_n)$ la part ressaltada en blau simbolitza que tots aquells elements es combinen utilitzant diferents operacions en un interval de temps determinat. Així doncs, d'aquesta definició matemàtica

s'infereix una altra de les propietats essencials dels sistemes, la seva totalitat; doncs l'expressió enuncia que «*el cambio de cualquier magnitud Q_i es función de todas las Q_j , de Q_1 a Q_n ; a la inversa, el cambio de cualquier Q_i acarrea cambio en todas las demás magnitudes y en el sistema en conjunto.*» (1989, 56) És a dir, el sistema funciona com un tot on els canvis que tenen lloc en cada element depenen de tots els demés, i on els canvis que es produeixen en un element també suposen canvis en els altres components i en el sistema en la seva totalitat. La totalitat o sinergia pot explicar-se mitjançant l'aforisme “el tot és més que la suma de les parts”, el que implica que un sistema és diferent a la suma dels components i, per tant, posseeix característiques pròpies i una identitat que no es redueix als seus elements. Així mateix la sinergia és una propietat que sorgeix de les interaccions entre els elements d'un sistema i, per tant, és un efecte de la interacció. (Thomas, 1993; Arnold & Osorio, 2008). Una tercera propietat dels sistemes, i que no es desprèn de cap de les formulacions presentades, és l'organització la qual és definida com la disposició de les relacions entre els components, que produeix una unitat o sistema nou amb qualitats diferents a les dels elements. (Thomas, 1993)

A partir de les tres propietats identificades es pot concloure que un sistema és un conjunt d'elements que interactuen o s'interrelacionen entre si i amb el medi circumdant, que presenten certa organització interna, i que configuren una totalitat nova que no es redueix a les característiques de cada component.

De la proposta anterior es dedueixen alguns dels principis estructurals d'un sistema:

- Els elements que el componen.
- Les relacions que s'estableixen entre aquests components i el seu entorn.
- Els límits del propi sistema que defineix les fronteres i determina quins elements formen part del sistema i quins no en formen part.

Adicionalment també s'han d'incorporar els següents aspectes a l'estructura d'un sistema (Thomas, 1993):

- L'emmagatzemament, entès com l'energia acumulada que necessita el sistema per a funcionar, per exemple, la informació.
- I la xarxa de comunicacions que permet l'intercanvi d'energia, matèria i informació entre els elements que conformen els diversos processos interns.

En relació amb la tipologia de sistemes, aquests es poden classificar en funció de diversos criteris, tal com el seu grau de complexitat (simples/complexos), el seu comportament (deterministes/probabilistes) o la seva relació amb l'entorn (tancats/oberts). Concretament, pel que fa a aquest últim agrupament, des de la teoria de sistemes o teoria general

de sistemes (TGS)³⁴ es sosté que un sistema tancat és un sistema que es considera aïllat del medi circumdant, ja que no hi ha intercanvi de matèria, energia i informació amb el seu entorn; mentre que un sistema obert és definit com un «*sistema que intercambia materia con el medio circundante, que exhibe importación y exportación, constitución y degradación de sus componentes materiales.*» (Bertalanffy, 1989, 146) Aquest tipus de sistema es pot descriure en

termes d'entrades i sortides, ja que reacciona davant uns determinats *inputs* donant una determinada resposta que es presenta com a *outputs*. (Acosta, 2000) Altrament entre ambdós sistemes existeixen diferències que es poden resumir al voltant de dos principis: el principi d'equifinalitat³⁵ i el segon principi de la termodinàmica o entropia³⁶. A continuació, a la **Taula 4** es detalla amb més profusió aquestes dissimilituds entre les dues tipologies de sistemes:

Principis	Sistema tancat	Sistema obert
Principi d'equifinalitat	No s'aplica als sistemes tancats, ja que l'estat final està inequívocament determinat per les condicions inicials.	Sí s'aplica als sistemes oberts ja que es pot arribar a un mateix estat final partint de diferents condicions inicials i per distintes vies.

34 La teoria general de sistemes (TGS) és una disciplina científica que té com a objecte la formulació de principis que siguin aplicables als sistemes en general, ja siguin físics, biològics, socials. Així mateix es planteja com una perspectiva holística i integradora que uneixi diferents ciències. (Bertalanffy, 1968, reimpr. 1989) Actualment, la teoria de sistemes està conformada per diferents tendències i/o enfocaments, tal com la teoria dels conjunts (Mesarovic), la teoria cibernètica (Wiener), la teoria de la informació (Shannon & Weaver), la teoria dels autòmats (Turing), etc. (Bertalanffy, 1968, reimpr. 1989; Arnold i Osorio, 2008)

35 El principi d'equifinalitat es refereix a la capacitat d'un sistema obert d'arribar a un mateix estat final partint de diferents condicions inicials i per diferents camins. (Bertalanffy, 1968, reimpr. 1989, 40)

36 Segons la Gran enciclopèdia catalana, el segon principi de la termodinàmica és aquell en que «*les transformacions termodinàmiques més probables que poden tenir lloc en un sistema aïllat són aquelles en les quals la variable extensiva, anomenada entropia (S), augmenta o roman constant, segons que la transformació sigui irreversible o reversible, respectivament.*» Essencialment, dit principi es refereix al canvi qualitatiu i irreversible que pateix l'energia quan és sotmesa a un procés físic i estableix que la tendència dels sistemes és la seva progressiva desorganització i homogeneïtzació amb l'entorn. (Arnold & Osorio, 2008) Altrament, l'entropia s'ha de concebre com la mesura de degradació de l'energia en els sistemes, que té el seu origen en les contradiccions internes i externes del sistema; o dit d'una altra forma, l'entropia és la desorganització. Finalment, convé destacar que l'entropia es divideix en positiva i negativa/negantropia. (Thomas, 1993)

Principis	Sistema tancat	Sistema obert
Segon principi de la termodinàmica - Entropia	<p>Es compleix el segon principi de la termodinàmica, ja que en els sistemes tancats l'entropia és positiva, és a dir, hi ha contínua destrucció de l'ordre. El motiu rau en que les contradiccions són mes fortes que els mecanismes reguladors i els residus del sistema bloquegen el seu funcionament i el desorganitzen.</p> <p>Aquesta tendència general es pot representar mitjançant l'equació de Clausius:</p> $dS \geq 0$	<p>Es contradiu el segon principi de la termodinàmica, ja que en els sistemes oberts l'entropia és negativa —també anomenada negantropia—. En aquest tipus de sistemes no només hi ha producció d'entropia, sinó també entrada d'energia, és a dir, importació d'entropia que pot ser negativa. D'aquesta manera, es pot evitar l'augment d'entropia al mantenir un estat estable i, fins i tot, desenvolupar nivells més alts d'ordre i organització. Aquesta l'equació³⁷ es representa mitjançant l'equació de Prigogine:</p> $dS = d_e S + d_i S$

Taula 4. Diferències entre sistemes oberts i tancats en relació a l'equifinalitat i l'entropia (Font: Elaboració pròpia, 2021. A partir de Bertalanffy, 1968, reimpr. 1989; Thomas, 1993; Arnold & Osorio, 2008).

1. 3. 1. 1. Sistemes cibernètics

Existeixen un tercer tipus de sistema que són els sistemes o models cibernètics que són una forma de sistema obert en quant intercanvien matèria, energia i informació amb l'entorn, però divergeixen de la conceptualització de sistema obert de Bertalanffy pel que fa al seu funcionament i comportament. Així doncs, la base d'un model de sistema obert és la interacció dinàmica

entre els seus components i la seva formulació resideix en la cinètica —que és mecanicista— i la termodinàmica; per contra, el model de sistema cibernètic es basa en la retroalimentació i la informació. (Bertalanffy, 1968, reimpr. 1989) Des del paradigma cibernètic³⁸, es concep un sistema on l'element central del funcionament és la retroalimentació o *feedback*, que es defineix com el «*proceso por el cual los efectos producidos por una función afectan a la ejecución misma de esa función.*» (Aguado, 2004) Aquests circuits o

³⁷ En aquesta expressió matemàtica, $d_i S$ simbolitza la producció d'entropia degut a processos irreversibles en el sistema que, en articulació amb el segon principi de la termodinàmica, sempre serà positiu. En canvi, $d_e S$ representa el canvi d'entropia per importació que pot ser positiu i negatiu. (Bertalanffy, 1968, reimpr. 1989, 149)

³⁸ La Cibernètica —deriva del grec *κυβερνήτης* (*kybernetes*) que significa timoner, pilot— fou creada per Norbert Wiener i és definida com la teoria del control i de la comunicació, tant en la màquina com en l'animal. (Wiener, 1986, 36) Així mateix, la cibernètica pot entendre's com la ciència que analitza racionalment el què significa governar (Acosta, 2000, 233), ja que el seu focus d'interès se centra en el funcionament i comportament dels sistemes.

bucles de retroalimentació —també anomenats *feedback loop*—tenen la funció de controlar i/o regular l'activitat d'acord amb la consecució dels objectius establerts pel sistema, per la qual cosa es pot afirmar que es tracta de models adaptatius i teleològics. Aquests mecanismes de control permeten que el sistema s'autoreguli i s'autogoverni dins uns límits específics, a partir de les relacions dialèctiques entre sistema / medi i dels objectius prefixats del propi sistema. Segons Colom (1975) el funcionament d'aquest tipus de sistema s'ha de considerar en els següents termes:

«(...) Los mecanismos de control posibilitan la adaptación del mismo a las variables ambientales. La retroacción (...) estaría ligada como “contestación” a las estimulaciones del exterior. Ello nos proporciona una concepción de las relaciones entre sistema y medio, eminentemente dialécticas ya que los resultados del efecto retroactivo modifican el contenido de las salidas del Sistema y por tanto del medio: estas variaciones incidirán a través de las entradas sistémicas, sobre el propio sistema, el cual moviliza sus mecanismos de control para actuar nuevamente. (...) [Asimismo] los Mecanismos reguladores de los Sistemas Cibernéticos ajustan la acción sistémica al esquema comportamental que tienen determinados, toda acción en Cibernética estará encomendada a la regulación del sistema para que éste logre sus objetivos.» (p. 124 i 129)

Existeixen dos tipus de feedback en funció de les funcions que exerceix el circuit de retroalimentació: d'una banda, el feedback positiu o *feedbefore*, que actua com a mecanisme de desviació, facilitant el canvi o inestabilitat ja que la seva acció amplia les diferències i pot suposar la destrucció del sistema; i d'altra banda, el feedback negatiu que actua corregint les desviacions del sistema en relació als objectius fixats, afavorint l'estabilitat o equilibri —també anomenat homeòstasis.— (Colom, 1975; Aguado, 2004)

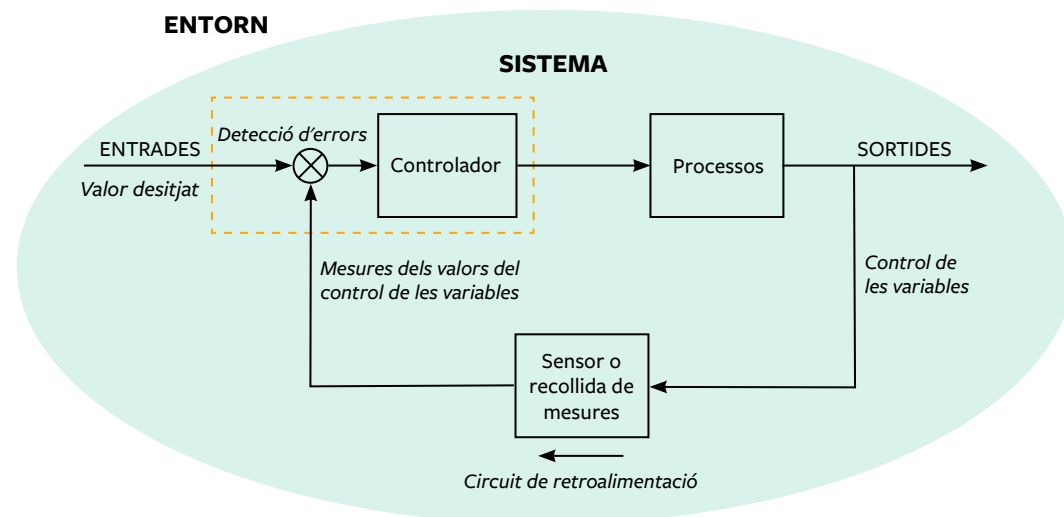


Figura 11. Funcionament d'un sistema cibernètic (Font: Elaboració pròpia, 2021. A partir de la Encyclopaedia Britannica³⁹, 1996; Acosta, 2000; Lollai, 2017).

De les consideracions anteriors s'infereix que es tracta d'un model amb causalitat circular doncs té la capacitat d'integrar en el seu funcionament el efectes produïts pel seu propi

39 Es remet a <https://www.britannica.com/technology/feedback-control-electronics>

funcionament. En aquests sistemes, el flux circular es fa en termes d'informació entre el sistema i el seu entorn; o dit d'una altra forma, la informació és l'objecte d'intercanvi amb l'entorn circumdant. És en aquest sentit que el sistema cibernètic es contempla com un sistema d'informació⁴⁰ en la mesura que posseeix entrades i sortides d'informació (en Colom, 1975). Així mateix, les dades i/o informació introduïda (entrada) són transformades a partir d'un gran número de combinacions a fi d'obtenir un efecte (sortida) sobre el món exterior; és a dir, les dades d'entrada són transformades en altres de sortida. Aquesta transformació es realitza a partir de les dades incorporades en aquell moment i també dels fets enregistrats en el passat (memòria). És important subratllar dos aspectes: en primer lloc, que la informació es concep com una mesura d'organització —contràriament a l'entropia— ja que a més informació s'augmenta el coneixement i es redueix la varietat de possibilitats; i en segon lloc, que la informació de l'exterior no s'importa en brut sinó que s'incorpora al sistema a través de mecanismes de transformació que posseeix el mateix sistema. (Colom, 1975; Wiener, 1988³) Aquest últim punt s'articula amb l'apartat 1.1.2 d'aquesta investigació, en concret, amb els postulats de Geoffrey Bowker (2013) i Devon Mordell (2019), els quals consideren que és

un oxímoron concebre les dades com a matèria en brut (*raw data*) ja que són la representació de fets prèviament existents i el resultat d'actes interpretatius. D'una banda, aquestes premisses es vinculen a l'existència de relacions de poder, el que genera que les dades no siguin neutrals; i d'altra banda, es relacionen amb la idea de que l'individu no observa la realitat *per se*, sinó només imatges o concepcions de la realitat, doncs «*toda mirada sobre la realidad es un acto de selección, de construcción y de interpretación que se hace desde un sujeto en un contexto.*» (Brunet & Morell, 2001, 32). És a dir, tota mirada cap a la realitat és una construcció biològica —determinada per les característiques fisiològiques, tal com el sistema nerviós—, així com social i lingüística; i, per tant, el món s'experimenta, es concep i s'interpreta per mitjà d'aquests processos i/o condicionants⁴¹.

1. 3. 2. Ecosistema de dades obertes, qualitat i cibernètica

Segons el Glossari d'agricultura orgànica de la *Food and Agriculture Organization* - FAO (2009), el terme ecosistema es defineix com una «*entidad (o sistema) natural con estructuras y relaciones diferenciadas que vinculan*

40 Segons la norma ISO 9000:2015 un sistema d'informació és una «*red de canales de comunicación utilizados dentro de una organización.*» (p. 24) Més específicament, la ISO/IEC 25012:2008 defineix sistema d'informació com «*one or more computer systems and communication systems, together with associated organizational resources such as human, technical, and financial resources, that provide and distribute information.*» (p.3)

41 En relació amb aquest àmbit, es segueix la tesi defensada per Carlos París (2000) en la que es sosté que l'ésser humà és un animal cultural, ja que la cultura s'ha d'entendre en relació amb la infraestructura biològica i el context ecològic, però, paral·lelament, la cultura s'ha de concebre com una realitat estructurada i estructurant.

comunidades bióticas (de plantas y animales) entre sí y con su entorno abiótico. El estudio de un ecosistema ofrece una base metodológica para sintetizar las interrelaciones complejas entre los organismos y su entorno. Un complejo de ecosistemas está formado por muchos ecosistemas y se caracteriza por tener un origen común o procesos dinámicos comunes (...)» (2009, 54) Tal com s'infereix d'aquesta descripció, així com de les que per exemple trobem a la Gran enciclopèdia catalana o al *Diccionario de la Real Academia Española*⁴², aquest mot se sol aplicar a sistemes naturals i s'associa amb l'ecologia; tanmateix, la revisió de la literatura sobre dades obertes ha permès constatar que l'ecosistema s'usa com a metàfora per a definir i caracteritzar les relacions i activitats que conformen el context *open data*, raó per la qual en la present investigació també s'emprarà d'aquesta forma (Davies, 2011; Pollock, 2011; Harrison, Pardo & Cook, 2012; Zuiderwijk, Janssen & Davis, 2014; Heimstädt, Saunderson & Heath, 2014; Van Schalkwyk, Willmers & McNaughton, 2016; McLeod & McNaughton, 2016). Segons McLeod & McNaughton (2016), des d'un punt de vista conceptual un ecosistema es pot concebre com un conjunt de components interconnectats que s'originen i funcionen entorn al propòsit de l'ecosistema; així mateix per a Harrison, Pardo & Cook (2012) la metàfora de l'ecosistema s'utilitza «*to convey a sense of the interdependent social systems of*

actors, organizations, material infrastructures, and symbolic resources that can be created in technology enabled, information intensive social systems.» (p.1). De la revisió de la metàfora d'ecosistema en la literatura sobre govern obert, Harrison, Pardo & Cook (2012) identifiquen que els elements essencials que caracteritzen un ecosistema són la interacció i interdependències entre els diferents components i/o actors, el seu dinamisme basat en el flux i el moviment, l'estabilitat, i l'existència d'espècies clau (*keystone species*) que són crucials per al funcionament del sistema ja que realitzen alguna funció vital. Així doncs, tal com s'infereix d'aquests elements podem considerar que l'ús de l'ecosistema de dades obertes (*open data ecosystem*) com a model conceptual possibilita plantejar un sistema complex conformat per múltiples interrelacions entre diversos actors, recursos, valors i sistemes d'informació, en substitució de models simples de causalitat lineal. Altrament, és important subratllar que es tracta d'un model teòric ja que com bé indica Pollock (2011) a l'actualitat el model funciona en un sol sentit (“*one way street*”) ja que no hi ha circuits de retroalimentació ni es comparteixen dades amb els editors ni entre intermediaris. Tanmateix, el model de futur ha de dirigir-se cap a un ecosistema *open data* caracteritzat per cicles de dades, fluxos de retroalimentació i interaccions entre els diferents actors.

42 La Gran enciclopèdia catalana concep ecosistema com a «*unitat funcional constituïda per un biòtop i els organismes que hi habiten (biocenosi)*». En termes similars és definida aquesta paraula al *Diccionario de la Real Academia Española* (2020), doncs es designa com una «*comunidad de los seres vivos cuyos procesos vitales se relacionan entre sí y se desarrollan en función de los factores físicos de un mismo ambiente.*»

De l'anàlisi de la literatura sobre ecosistemes de dades obertes, s'ha realitzat la **Taula 5** en la qual s'identifiquen les principals propietats d'aquests sistemes dividides en cinc categories: configuració, context, components, estructura i funcionament. A continuació es detalla què engloba cada categoria:

- (1) **Configuració:** s'inclouen totes aquelles propietats relacionades amb la forma determinada que té l'ecosistema.
- (2) **Context:** s'inclouen aquelles característiques relacionades amb l'entorn i sense les quals no es pot entendre el funcionament de l'ecosistema.
- (3) **Components:** s'inclouen aquelles característiques relacionades amb els elements que configuren el sistema, ja siguin agents, sistemes, processos o recursos.

(4) **Estructura:** s'inclouen les propietats que permeten comprendre com s'organitzen els components de l'ecosistema, així com les relacions que tenen lloc entre les parts.

(5) **Funcionament:** s'inclouen les característiques vinculades a la forma de funcionar de l'ecosistema.

Convé destacar que hi ha característiques que s'interrelacionen entre elles, independentment de la categoria a la qual s'adscriuin, la qual cosa ha quedat degudament reflectida a la taula.

Categories	Característiques	Fonts
(1) Configuració	(1.1) L'ecosistema de dades obertes està influenciat i posseeix característiques compartides amb un ecosistema de negoci (<i>business ecosystem</i>), un ecosistema d'innovació (<i>innovation ecosystem</i>), un ecosistema d'informació (<i>information ecosystem</i>) i/o un ecosistema digital (<i>digital ecosystem</i>).	Zuiderwijk, Janssen & Davis (2014) Heimstädt, Saunderson & Heath (2014)
	(1.2) És una unitat funcional, tots els elements actuen com un tot integrat. Es relaciona amb les propietats (4.1)	Zuiderwijk, Janssen & Davis (2014)
	(1.3) És una entitat multinivell i multidimensional on la matèria prima són les dades obertes. A més, els ecosistemes de dades obertes s'han de concebre en diferents nivells: en un nivell micro, com ecosistemes municipals i regionals; un nivell meso, com ecosistemes nacionals; i un nivell macro, com un ecosistema global. Es relaciona amb la propietat (3.5)	Zuiderwijk, Janssen & Davis (2014) Heimstädt, Saunderson & Heath (2014) McLeod & McNaughton (2016)
	(1.4) L'ecosistema de dades obertes és dinàmic. Així mateix, hi ha tres processos que configuren la dinàmica del funcionament d'aquests sistemes: la intencionalitat, la creació de valor i la sostenibilitat. Es relaciona amb les propietats (4.1) i (4.2)	Harrison, Pardo & Cook (2012)
	(1.5) Es combina ecosistema amb infraestructura. El primer es fonamenta en components autònoms i autoorganitzats que s'interrelacionen entre si, i que es basen en un o més elements de la infraestructura, també inclou els circuits de retroalimentació i desenvolupament d'acord a les especificacions de cada ecosistema, en són un exemple les plataformes de retroalimentació que permeten la recopilació i l'actuació de retroacció. En canvi, la infraestructura la integren els components tècnics i els processos que faciliten les estructures i instal·lacions físiques i organitzatives necessàries per al funcionament de l'organització, com a exemples destaquen els processos de control de la qualitat de les dades o el subministrament de metadades. Es relaciona amb les propietats (5.3) i (5.5)	Davies (2011)

Categories	Característiques	Fonts
(2) Context	(2.1) L'ecosistema consta de tres condicions contextuais sota les quals funcionen els agents del sistema: a) condicions regulatòries, que inclouen lleis, polítiques i estàndards; b) condicions o context institucional on operen els actors, que inclouen valors, regles i normes que impulsen o restringeixen el comportament dels actors que conformen l'ecosistema; i c) condicions relacionades amb les tecnologies de la informació i la comunicació (TIC), que engloba elements de xarxa, operadors de xarxa i protocols de comunicació.	Van Schalkwyk, Willmers & McNaughton (2016)
(3) Components	(3.1) S'identifiquen tres actors/agents humans: a) productors o proveïdors de dades; b) intermediaris de dades; i c) usuaris o consumidors de dades. Els productors s'ubiquen en el nivell de producció (<i>data producer and contextual level</i>); mentre que els usuaris es situen en el nivell d'ús (<i>data user level</i>). Els intermediaris es poden trobar en un nivell o en l'altre. Aquests agents —ja siguin organitzacions i/o individus— generen, comparteixen i processen conjunts de dades principalment dins els seus límits naturals. Es relaciona amb la propietat (4.1)	Zuiderwijk, Janssen & Davis (2014) Heimstädt, Saunderson & Heath (2014) Van Schalkwyk, Willmers & McNaughton (2016)
	(3.2) Existència d'espècies (agents) clau que són útils per al funcionament de l'ecosistema ja que realitzen alguna funció vital. És important destacar que poden ser facilitadors, no necessàriament impulsors. Es relaciona amb la propietat (3.3)	Harrison, Pardo & Cook (2012) Van Schalkwyk, Willmers & McNaughton (2016)
	(3.3) Identificació d'actors influents dins l'ecosistema, és a dir, d'actors centrals que poden actuar de manera positiva o negativa i influir en l'eficàcia i els resultats de la xarxa. Es relaciona amb la propietat (3.2)	McLeod & McNaughton (2016)

Categories	Característiques	Fonts
	<p>(3.4) L'ecosistema està conformat per una xarxa d'actors constituïda per humans, màquines, organitzacions i idees. Així doncs, els humans i no humans són actors per igual.</p> <p>En aquesta xarxa d'actors les relacions de xarxa representen dades subministrades lliurement per al seu ús i reutilització, així com la seva utilització per a diverses activitats. Consegüentment, el coneixement es construeix a través de la recepció de dades i informació que es comparteix a través d'una xarxa.</p> <p>És a dir, els actors de l'ecosistema no només són proveïdors, intermediaris i consumidors de dades; sinó que també s'han d'incloure, sense caràcter limitatiu, recursos i fonts.</p> <p>Es relaciona amb la propietat (4.1)</p>	<p>McLeod & McNaughton (2016) Van Schalkwyk, Willmers & McNaughton (2016)</p>
	<p>(3.5) El recurs central de l'ecosistema de dades obertes són les dades obertes.</p> <p>Es relaciona amb la propietat (1.3)</p>	<p>Heimstädt, Saunderson & Heath (2014) Zuiderwijk, Janssen & Davis (2014) McLeod & McNaughton (2016)</p>
(4) Estructura	<p>(4.1) Es conformen xarxes d'interacció i dependències entre els diferents actors. Tanmateix, algunes veus sostenen que el model actual no mostra una sòlida interdependència mútua, sinó més bé una dependència unilateral. (Pollock, 2011; Heimstädt, Saunderson & Heath, 2014)</p> <p>Es relaciona amb les propietats (1.2), (3.1) i (3.4)</p>	<p>Pollock (2011) Zuiderwijk, Janssen & Davis (2014) Heimstädt, Saunderson & Heath (2014) McLeod & McNaughton (2016)</p>
	<p>(4.2) Les interaccions i tensions entre els processos d'intencionalitat, de creació de valor i de sostenibilitat defineixen les dinàmiques de l'ecosistema.</p> <p>Es relaciona amb la propietat (1.4)</p>	<p>Harrison, Pardo & Cook (2012)</p>
	<p>(4.3) Dins de l'ecosistema de dades obertes interactuen diversos elements de dades i agents per a la consecució d'objectius específics.</p> <p>Es relaciona amb les propietats (3.1) i (3.4)</p>	<p>McLeod & McNaughton (2016)</p>

Categories	Característiques	Fonts
(5) Funcionament	(5.1) L'ecosistema de dades obertes funciona mitjançant cicles de retroalimentació que, a vegades, condueix a etapes posteriors de processament. Així mateix, el sistema està obert doncs hi ha molts actors involucrats; a més, és un sistema complex on no existeix un procés lineal de processos o un únic procés lineal. Es relaciona amb la propietat (5.2)	Pollock (2011) Zuiderwijk, Janssen & Davis (2014) Van Schalkwyk, Willmers & McNaughton (2016)
	(5.2) L'ecosistema es desenvolupa a través de l'adaptació de l'usuari, dels cicles de retroalimentació i de les interaccions dinàmiques entre proveïdors i usuaris, així com altres tipus d'interrelacions. Es relaciona amb les propietats (4.1) i (5.1)	Zuiderwijk, Janssen & Davis (2014)
	(5.3) Són elements essencials de l'ecosistema els fluxos de treball de dades i d'informació, així com la gestió del cicle de vida de les dades que inclou la creació, l'obertura, la publicació, l'exportació, la importació, l'ús, la reutilització, la transformació i la valoració dels <i>datasets</i> . Aquests aspectes permeten identificar processos i activitats que poden desenvolupar-se en un escenari de dades obertes. Així doncs, a partir del cicle de vida de les dades Zuiderwijk, Janssen & Davis (2014) han identificat que hi ha quatre components/processos clau que l'ecosistema de dades obertes ha de contenir: a) publicar dades; b) buscar, avaluar, trobar i veure dades i les seves llicències relacionades; c) netejar, analitzar, enriquir, vincular, visualitzar i analitzar dades; d) interpretar i proporcionar retroalimentació al proveïdor de dades i altres parts interessades. Addicionalment s'han d'afegir tres aspectes més que faciliten la integració dels elements anteriors: e) rutes d'usuari que facilitin l'ús de les dades; f) diferents tipus de metadades per a garantir la interoperabilitat, el processament i la vinculació entre elements; i g) un sistema de gestió de la qualitat que permeti avaluar la qualitat de les dades. Es relaciona amb la propietat (1.5)	Zuiderwijk, Janssen & Davis (2014) Van Schalkwyk, Willmers & McNaughton (2016)
	(5.4) Qualsevol dada oberta té el potencial de ser processada cíclicament, ja que retroalimentarà al sistema/agent que el va originar.	Heimstädt, Saunderson & Heath (2014)

Categories	Característiques	Fonts
	(5.5) Les relacions d'intercanvi de dades s'estableixen a través de mecanismes de xarxa. Es relaciona amb la propietat (1.5)	McLeod & McNaughton (2016)
	(5.6) Hi ha dos aspectes essencials que repercuteixen en el funcionament del sistema: d'una banda, la innovació que és un element clau en el circuit existent entre producció de dades, subministrament de dades i consum de dades; i d'altra banda, la sostenibilitat ja que un sistema ha de ser sostenible i, per tant, necessita finançament.	Van Schalkwyk, Willmers & McNaughton (2016)

Taula 5. Característiques de l'ecosistema de dades obertes. (Font: Elaboració pròpia, 2021)

A partir de les propietats identificades a la taula anterior, en aquesta investigació es defineix l'ecosistema de dades obertes de la manera següent:

Conjunt d'interaccions i interrelacions que s'estableixen entre els diferents actors —humans i no humans— que conformen l'ecosistema, per tal d'assolir els objectius genèrics i específics del propi sistema, tal com l'estabilitat, la sostenibilitat, la innovació o la creació de valor. El sistema funciona a través de fluxos de dades i d'informació, de cicles de retroalimentació i de les interaccions dinàmiques entre proveïdors i usuaris, així com altres tipus d'interrelacions. Finalment, per a que existeixi un ecosistema de dades obertes és necessari la provisió de dades obertes i la gestió del cicle de vida de les mateixes, doncs els processos i activitats que s'hi desenvolupen, així com les relacions entre

proveïdors i usuaris, es relacionen amb aquest cicle de les dades —disseny, planificació, creació, recollida, descripció, processament, emmagatzemament, selecció, preservació, publicació, importació, accés, ús, reutilització i redistribució—.

Basant-nos en el model conceptual que es planteja a la literatura *open data* (Davies, 2011; Pollock, 2011; Harrison, Pardo & Cook, 2012; Zuiderwijk, Janssen & Davis, 2014; Heimstädt, Saunderson & Heath, 2014; Van Schalkwyk, Willmers & McNaughton, 2016; McLeod & McNaughton, 2016), es considera que el sistema cibernètic és aplicable a l'ecosistema de dades obertes, ja que el comportament i funcionament de l'ecosistema es fonamenta en fluxos de dades i d'informació, en interaccions entre els diferents agents del sistema, en *inputs* i *outputs*, en la gestió del cicle de vida de les dades, i en circuits de retroalimentació on, segons Pollock (2011), els errors i les correccions

—per exemple, les aportades pels usuaris— retornen als productors de les dades per a que la qualitat de les mateixes millori en la font. Així doncs, d'aquests aspectes s'infereix que el model descrit està obert a l'entorn, a la vegada que presenta mecanismes homeostàtics de retroalimentació i una causalitat circular, la qual cosa suposa que l'ecosistema s'autoregula. Altrament, es pot concebre l'ecosistema de dades obertes com teleològic ja que el seu funcionament i les interrelacions que s'hi desenvolupen responen a la consecució dels objectius de l'ecosistema. Una d'aquestes finalitats pot ésser la qualitat dels conjunts de dades publicats, de manera que el propòsit seria que les dades obertes fossin de bona qualitat segons uns paràmetres prèviament fixats. Els *datasets* publicats en els portals de dades obertes serien la sortida del sistema. Consegüentment, per a poder avaluar les dimensions de qualitat de les dades obertes, s'ha de mesurar l'error o, dit d'una altra manera, s'ha de calcular la diferència existent entre el valor 1 que són els paràmetres fixats, i el valor 2 que seria la sortida del sistema. Així mateix, l'objectiu és que l'error sigui zero. En cas que la diferència sigui zero, el sistema prosseguirà sense canvis; no obstant, en cas

d'error s'hauran d'introduir els reajustaments necessaris fins que l'error es faci zero. Per a un millor enteniment de la lògica descrita es remet a la **Figura 11**.

Dins d'aquest model proposat, determinar i utilitzar mètriques per avaluar les dimensions de qualitat dels *datasets* implica que aquestes mètriques constituïran la informació dels sistemes de retroalimentació, els quals són clau per al funcionament de l'ecosistema. (Harrison, Pardo & Cook, 2012) Per tant, les mesures i avaluacions que s'obtinguin de les sortides del sistema —els conjunts de dades obertes— en relació amb els indicadors fixats, retornaran als proveïdors de les dades i serviran, en cas d'existir error, per a realitzar els canvis necessaris en la mateixa font o durant el processament de les dades.

Per tot això, a la vista de les consideracions anteriors, es pot concloure que l'ecosistema de dades obertes funciona i es comporta com un sistema cibernètic ja que disposa de mecanismes cibernètics elementals, tal com els cicles de retroalimentació; on a més la informació i les dades esdevenen els eixos fonamentals de l'ecosistema.

1.4. Marc teòric i metodològic de la gestió de les dades i de la qualitat de les mateixes (*data management & data quality management - DQM*)

1.4.1. Consideracions generals

La present secció s'adscriu dins el marc teòric de la gestió de les dades (*data management*), tot i que també contempla aspectes relacionats amb la gestió de la qualitat (*quality management*), concretament aquelles qüestions relacionades amb referències conceptuais tal com el concepte mateix de qualitat o els termes relacionats amb la gestió de la qualitat, en particular el control, seguiment i mesurament de la qualitat.

1.4.2. Conceptes de qualitat

En la literatura consultada sobre gestió de la qualitat es concep el terme qualitat com a multidimensional (Torres & Vásquez, 2010; Sanabria, Romero & Flórez; 2014; García, Piattini & García, 2018; Pineda, 2020), dinàmic i complex ja que depèn de diverses variables i interaccions (Camisón, Cruz & González, 2006; Sanabria, Romero & Flórez; 2014; Pineda, 2020), i sobre el que no existeix consens entorn a una definició específica (Hoyer & Hoyer, 2001;

Moreno-Luzón, Peris & González, 2001; Camisón, Cruz & González, 2006; Torres & Vásquez, 2010; Pineda, 2020). En aquest sentit, existeixen diverses definicions i teories de la qualitat⁴³ que s'agrupen i classifiquen en categories conceptuais que varien segons alguns treballs revisats (Hoyer & Hoyer, 2001; Moreno-Luzón, Peris & González, 2001; Camisón, Cruz & González, 2006). De manera genèrica, els diferents conceptes de la qualitat es poden sintetitzar en tres perspectives (Moreno-Luzón, Peris & González, 2001; Camisón, Cruz & González, 2006), tal com es mostra a la figura següent:



Figura 12. Perspectives conceptuals de la qualitat (Font: Elaboració pròpia, 2021. Adaptació realitzada a partir de Moreno-Luzón, Peris & González, 2001).

⁴³ Per a una revisió de les teories dels anomenats filòsofs o gurus de la qualitat (Crosby, Deming, Feigenbaum, Ishikawa, Juran, Pirsig, Shewhart i Tagushi) es remet als treballs de Badia (1998), Hoyer & Hoyer (2001), Chacón & Rugel (2018), i Pineda (2020).

La imatge anterior representa les relacions que s'estableixen entre la perspectiva global, entesa com a excel·lència, i les perspectives interna i externa. La primera parteix de la consideració que la millora de l'eficiència interna és el mitjà per aconseguir la conformitat amb les especificacions i la reducció de costos de la no qualitat (Camisón, Cruz & González, 2006). En paraules de Crosby (1990), «*la calidad no cuesta. (...) Lo que cuesta dinero son las cosas que no tienen calidad —todas las acciones que resultan de no hacer bien las cosas a la primera vez.*» (p.9) La perspectiva externa o de mercat és la que emfatitza l'eficàcia i la satisfacció de les expectatives del client, n'és un exponent d'aquesta visió Joseph Juran. De la unió d'ambdues sorgeix la perspectiva global, també anomenada gestió de la qualitat total, que introdueix el concepte d'excel·lència i està orientada a aconseguir l'èxit sostingut dins l'organització. Una bona mostra d'aquesta tercera perspectiva la trobem en el model europeu d'excel·lència EFQM i també en la norma UNE-EN ISO 9004:2018, que proporciona una guia per a aquelles organitzacions que vulguin aconseguir l'èxit sostingut a partir de l'aplicació de tots els principis de l'estàndard ISO 9000:2015.

Malgrat que l'objecte de la present investigació no és establir un anàlisi detallat de les diferents perspectives

conceptuals de la qualitat, és important tenir una definició precisa de la mateixa, a efectes de consensuar el concepte per a la investigació. En l'àmbit de les organitzacions públiques, la qualitat es concep com un valor en la relació entre ciutadania i administracions públiques. En particular, es tracta d'assegurar que els usuaris dels serveis públics tinguin el que necessiten (Övretveit, en Orte, 2018). Partint d'aquesta premissa, Orte (2018) indica que la qualitat en els serveis i productes públics s'orienta, d'una banda, en complir i satisfer les necessitats de l'usuari i, d'altra banda, en produir un producte o servei d'acord amb les normes i estàndards previstos. D'acord amb aquests elements, en el marc d'aquest projecte es segueix el criteri proposat a la norma ISO 9000:2015, on s'estableix que la qualitat es el «*grado en el que un conjunto de características inherentes de un objeto cumple con los requisitos*» (p.19). És a dir, en el context de la present investigació la qualitat es concep com el grau o nivell en que les característiques intrínseques⁴⁴ d'un producte o servei compleixen amb les necessitats o expectatives establertes tant per la pròpia organització com per les parts interessades, així com amb els estàndards i requisits legals existents. Així mateix, la qualitat es vincula a la millora contínua, la perspectiva sistèmica, l'enfocament a processos⁴⁵ i l'orientació a les persones destinatàries dels serveis i/o productes.

⁴⁴ A la norma ISO 9000:2015 s'indica que les característiques de qualitat són inherents, és a dir, que existeixen en l'objecte, per contraposició a les característiques assignades (per exemple, el preu) que no formen part de les característiques de qualitat (p. 28).

⁴⁵ Segons la norma ISO 9000:2015 un procés és el «*conjunto de actividades mutuamente relacionadas que utilizan las entradas para proporcionar un resultado previsto.*» (p.15) Aquest resultat previst és la sortida del sistema, ja sigui un servei o un producte.

1. 4. 3. Dimensions de qualitat de les dades (*data quality dimensions*)

De la revisió de la literatura consultada sobre qualitat de dades⁴⁶ (Wang, Storey & Firth, 1995; Wand & Wang, 1996; Wang & Strong, 1996; Strong, Lee & Wang, 1997; Kovac, Lee & Pipino, 1997; Jarke, Jeusfeld, Quix & Vassiliadis, 1999; Lee, Strong, Kahn & Wang, 2002; Pipino, Lee & Wang, 2002; Kahn, Strong & Wang, 2002; Olson, 2003; Bovee, Srivastava & Mak, 2003; Kulikowski, 2005; Chengalur-Smith, Neely & Tribunella, 2005; DAMA International, 2009; Open Data Support, 2014; Cai & Zhu, 2015; Batinì & Scannapieco, 2016; APORTA, 2017; Eurostat, 2017; Mahanti, 2018 i 2019) es constata que no hi ha una definició uniforme de *data quality* ni tampoc de les dimensions que la conformen. Una d'aquestes definicions és la que proposa la norma ISO/IEC 25012:2008⁴⁷ que defineix la qualitat de les dades (*data quality*) com «*degree to which the characteristics of data satisfy stated and implied needs when used under specified conditions.*» (p.3) Així mateix, l'estàndard citat concep aquestes característiques de qualitat (*data quality characteristic*, també anomenat en la literatura com a *data quality dimensions*) com a «*category of data quality attributes that bears on data quality*» (p.3). D'altra

banda, destaca també la definició de Kulikowski (2005), segons el qual la qualitat de les dades és «*a set of data properties (features, parameters, etc.) describing their ability to satisfy the user's expectations or requirements concerning data using for information acquiring in a given area of interest, learning, decision making, etc.*» (p.120). Malgrat la disparitat de propostes, de l'anàlisi de la literatura citada es comprova que hi ha un conjunt d'idees que es repeteixen en les investigacions i que són les que a continuació s'exposen:

- La qualitat de dades és un concepte multidimensional i polifacètic ja que està conformat per diverses dimensions o característiques de qualitat.
- Cada dimensió captura un aspecte mesurable i particular de la qualitat de les dades.
- La producció i emmagatzematge de dades es concep com un sistema de producció de dades (*data manufacturing system*) on, mitjançant el processament de les mateixes, les entrades del sistema es transformen en sortides, en concret, en productes de dades per a ser

⁴⁶ A part de l'anàlisi de la literatura realitzada en el marc d'aquest projecte, també es remet a la revisió portada a terme per altres investigadors i investigadores, en concret, per Wand & Wang (1996); Lee, Strong, Kahn & Wang (2002); Chengalur-Smith, Neely & Tribunella (2005); i Mahanti (2018).

⁴⁷ La norma ISO/IEC 25012:2008 estableix un model de qualitat de dades per als productes de software. En el marc d'aquest projecte, les dades obertes es conceben com a productes de software a partir de la proposta de software que es presenta a la ISO 9000:2015. Segons aquesta norma, un producte és la «*salida de una organización que puede producirse sin que se lleve a cabo ninguna transacción entre la organización y el cliente.*» (p.22). Altrament els productes es classifiquen en hardware i en software. Aquest últim és defineix en termes d'informació i inclou, sense caràcter limitatiu, un programa informàtic, un manual d'instruccions, el contingut d'un diccionari, etc. Així doncs, en aquesta investigació es parteix del concepte genèric de software que es planteja a la norma ISO 9000:2015, raó per la qual es consideren les dades obertes un producte de software.

utilitzats pels consumidors. Dins d'aquest sistema de producció existeixen tres rols: els productors de dades, els custodis de dades i els consumidors de dades.

- Les dades són de qualitat si satisfan els requeriments de l'ús previst. Segons Cai & Zhu (2015), la qualitat de les dades no només depèn de les seves característiques sinó també del context de negoci que utilitza les dades, el que inclou processos i usuaris. D'aquesta afirmació s'infereix que no es poden separar les dades dels seus usos, raó per la qual en les investigacions consultades s'indica que la qualitat de les dades s'ha d'entendre en el context de l'adequació a l'ús, és a dir, les dades han de ser adequades per al seu fi (*"fitness for use"*). Per tant, la qualitat de les dades depèn del context i de les necessitats dels usuaris.
- En relació amb l'asserció anterior, els estàndards de qualitat de dades no solament han de desenvolupar la perspectiva dels productors de dades, sinó també han d'incorporar la perspectiva dels consumidors. En conjunt, s'ha de considerar tant el punt de vista intern com l'extern.
- Per a Kulikowski (2015) les dades d'alta qualitat es poden concebre com aquelles que tenen un format apropiat i contenen informació rellevant. D'aquesta noció s'infereixen dos aspectes: en primer lloc, la necessitat de mecanismes i d'una infraestructura tècnica per al

processament de dades i, en segon lloc, la utilitat de la informació subministrada per les dades en el camp de l'educació, en la ciència, en la presa de decisions, etc.

- Els termes dades de qualitat (*data quality - DQ*) i informació de qualitat (*information quality - IQ*) s'usen com a sinònims. En el cas particular de Batini & Scannapieco (2016) concreten que amb el vocable DQ es refereixen a dades estructurades en bases de dades relacionals, també inclouen Big Data, Web data i linked open data; en canvi, el terme IQ es vincula a la resta de tipus d'informació, en concret a informació semiestructurada i no estructurada com per exemple documentació jurídica.

En connexió amb les afirmacions anteriors, des del *U.S National Institute of Statistical Sciences - NISS* (2001) plantejen que hi ha tres principis que regeixen la qualitat de les dades, i que són els que a continuació es detallen (en Cai & Zhu, 2015):

1. Les dades són un producte adreçat a clients i posseeixen un cost i valor.
2. Com a producte, les dades tenen qualitat, resultat del procés pel qual s'han generat.
3. La qualitat de les dades depèn de múltiples factors, incloent els propòsits pels qual són utilitzades, els usuaris, el moment, etc.

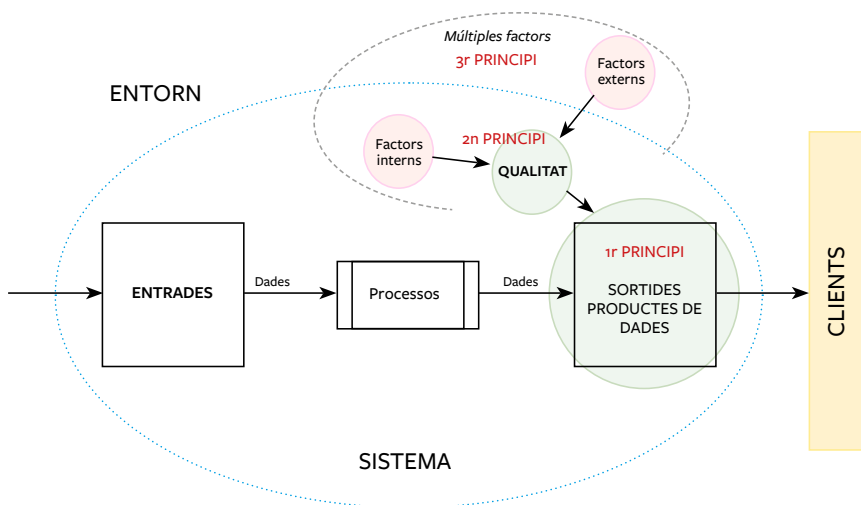


Figura 13. Principis de la qualitat de les dades amb perspectiva sistèmica

(Font: Elaboració pròpia, 2021)

Com ja s'ha comentat, a partir de la comparativa dels estudis consultats s'ha identificat l'existència d'una gran varietat d'aproximacions a les dimensions de qualitat de les dades. Wang & Strong (1996) elaboren un marc conceptual de la qualitat de les dades on identifiquen quatre categories de qualitat (*intrinsic data quality*, *contextual data quality*, *representational data quality* i *accessibility data quality*) i cadascuna d'aquestes categories està conformada per dimensions concretes de qualitat, fins arribar a un total de

15 dimensions. En concret, la categoria “qualitat intrínseca de les dades” inclou la fiabilitat/confiabilitat (*believability*), l'exactitud (*accuracy*), l'objectivitat (*objectivity*) i la reputació (*reputation*); la categoria “qualitat contextual de les dades” incorpora el valor afegit (*value-added*), la rellevància (*relevancy*), la pertinència temporal (*timeliness*), la completesa (*completeness*) i el volum/quantitat de dades (*appropriate amount of data*); la categoria “qualitat representativa de les dades” captura la llegibilitat/interpretabilitat (*interpretability*), la comprensibilitat (*ease of understanding*), la consistència (*representational consistency*) i la precisió (*concise representation*); i la quarta categoria inclou l'accessibilitat (*accessibility*) i la seguretat/privacitat (*access security*).

Posteriorment, Pipino, Lee & Wang (2002) i Kahn, Strong & Wang (2002), partint de les dimensions de qualitat de Wang & Strong (1996) n'afegeixen dues noves, la correccesa (*free-of-error*) i la facilitat de manipulació (*ease of manipulation*), però treuen l'exactitud (*accuracy*). D'altra banda, Jarke, Jeusfeld, Quix & Vassiliadis (1999) en el seu treball sobre arquitectura i qualitat en magatzems de dades (*data warehouses*) presenten quatre nivells de qualitat⁴⁸: la qualitat del disseny i administració, que inclou dades de qualitat i esquema; la qualitat en la implementació del software; la qualitat de l'ús de les dades i, finalment, la qualitat de les dades que inclou cinc dimensions: completesa

⁴⁸ Convé remarcar que per a l'elaboració de la **Taula 8** s'han tingut en compte tots els nivells, a excepció de la qualitat en la implementació del software.

(*completeness*), credibilitat (*credibility*), exactitud (*accuracy*), consistència (*consistency*) i llegibilitat/interpretabilitat (*data interpretability*). Convé destacar que aquest últim nivell no fa referència als processos que tenen lloc en els *data warehouses*, sinó que es refereix directament a les propietats de les dades emmagatzemades; tot i que com indiquen els autors la qualitat de les dades emmagatzemades està influenciada pels processos que es desenvolupen a l'entorn del *warehouse* (1999, 241). Per a DAMA International (2009), en la seva obra DAMA-DMBOK: Data Management Body of Knowledge (1a versió), es distingeixen 11 dimensions de qualitat de les dades, en concret: exactitud (*accuracy*), completesa (*completeness*), consistència (*consistency*), actualitat (*currency*), precisió (*precision*), privacitat/seguretat (*privacy*), raonabilitat (*reasonableness*), integritat (*referential integrity*), pertinència temporal (*timeliness*), unicitat (*uniqueness*) i validesa (*validity*). En canvi, Batini & Scannapieco (2016) identifiquen les següents 11 dimensions: exactitud (*accuracy*), completesa (*completeness*), redundància (*redundancy*), llegibilitat/interpretabilitat (*readability*), accessibilitat (*accessibility*), consistència (*consistency*), usabilitat (*usefulness*), fiabilitat/confiabilitat (*trust*), actualitat (*currency*), pertinència temporal (*timeliness*) i volatilitat (*volatility*). Posteriorment, Mahanti (2018 i 2019) estableix una taula amb 30 dimensions de la qualitat i les seves corresponents definicions: accessibilitat (*accessibility*), exactitud

(*accuracy*), fiabilitat/confiabilitat (*believability*), credibilitat (*credibility*), fidedigne (*trustworthiness*), reputació (*reputation*), pertinència temporal (*timeliness*), actualitat (*currency*), volatilitat (*volatility*), correctesa (*correctness*), precisió (*precision*), fiabilitat (*reliability*), consistència (*consistency*), integritat (*integrity*), completesa (*completeness*), conformitat (*conformance/validity*), llegibilitat/interpretabilitat (*interpretability*), seguretat/privacitat (*security*), concisió (*conciseness*), unicitat (*uniqueness*), duplicació (*duplication*), cardinalitat (*cardinality*), cobertura de dades (*data coverage*), rellevància (*relevance*), facilitat de manipulació (*ease of manipulation*), objectivitat (*objectivity*), traçabilitat (*traceability/lineage*), definició/documentació (*data specification*), granularitat (*granularity*) i redundància (*redundancy*).

En el cas de la norma ISO/IEC 25012:2008 s'estableix un model de qualitat de dades⁴⁹ integrat per 15 dimensions, algunes de les quals formen part de les propietats inherents de la qualitat de les dades (*inherent data quality*), i altres característiques són dependents del sistema (*system dependent data quality*). En el primer grup s'inclou l'exactitud (*accuracy*), la completesa (*completeness*), la consistència (*consistency*), la credibilitat (*credibility*) i l'actualitat (*currentness*); el segon grup engloba la disponibilitat (*availability*), la portabilitat (*portability*) i la recuperabilitat (*recoverability*) i, per últim, hi ha un conjunt

49 En la ISO/IEC 25012:2008 el model de qualitat de dades (*data quality model*) es concep com un «*defined set of characteristics which provides a framework for specifying data quality requirements and evaluating data quality.*» (p.3)

de característiques que formen part d'ambdós grups, en concret són l'accessibilitat (*accessibility*), la conformitat (*compliance*), la privacitat/seguretat (*confidentiality*), l'eficiència (*efficiency*), la precisió (*precision*), la traçabilitat (*traceability*) i la comprensibilitat (*understandability*).

En quant als estudis que se centren en la qualitat de les dades obertes, convé destacar el treball realitzat per la Iniciativa *Open Data Support* de la Comissió Europea (2014) que identifica 9 dimensions de la qualitat de les dades obertes, en particular l'exactitud (*accuracy*), la consistència (*consistency*), la disponibilitat (*availability*), la completesa (*completeness*), la conformitat (*conformance*), la credibilitat (*credibility*), la llegibilitat/interpretabilitat (*processability*), la rellevància (*relevance*) i la pertinència temporal (*timeliness*). Pel que fa als productes de dades estadístiques, des de l'Oficina d'Estadística de la Unió Europea, més coneguda com a Eurostat (2017), es fixen 9 components de la qualitat que són la rellevància (*relevance*), l'exactitud (*accuracy*), la fiabilitat/confiabilitat (*reliability*), la pertinència temporal (*timeliness*), l'actualitat (*punctuality*⁵⁰), la consistència (*coherence*), la comparabilitat (*comparability*), l'accessibilitat (*accessibility*) i la llegibilitat/interpretabilitat (*clarity*⁵¹).

A Espanya, hi ha la Iniciativa APORTA (2017) que està promoguda pel *Ministerio de Asuntos Económicos y Transformación Digital* i l'entitat pública empresarial Red.es. En el seu “Manual práctico para mejorar la calidad de los datos abiertos” s'estableixen 11 dimensions de la qualitat de les dades obertes a partir d'una revisió de la definició dels principis originals de les dades obertes governamentals definits a la reunió de Sebastopol, dels principis definits a la Carta Internacional de Dades Obertes, de les dimensions de qualitat identificades a la Iniciativa *Open Data Support*, dels atributs inherents de la qualitat establerts a la norma ISO/IEC 25012:2008, i de la definició d'obertura (*open definition*) de la *Open Knowledge Foundation*. En conjunt, les característiques de qualitat que s'identifiquen són les següents: obertura, accessibilitat, reutilització, exactitud, consistència, completesa, conformitat, credibilitat, precisió, actualitat i comprensibilitat.

En un altre ordre de coses, la revisió de les investigacions ha permès identificar cinc problemàtiques concretes: primerament, l'existència d'una gran pluralitat de propostes en relació amb les dimensions que conformen la qualitat de les dades. Segonament, la utilització de termes diferents amb un significat similar, la qual cosa fa

⁵⁰ El terme *punctuality* s'ha traduït com actualitat, i, per tant, s'engloba dins la propietat *currency* degut a que ambdós presenten un significat molt semblant.

⁵¹ En la *Conference on Data Quality for International Organizations* (Roma, 7-8 de juliol de 2008), en particular a la sessió 3 realitzada per Steven Vale (UNECE) s'indica que el terme claredat se sol reemplaçar per interpretabilitat, ja que el significat és similar. Aquesta és la raó per la qual *clarity* s'ha traduït com llegibilitat/interpretabilitat.

necessari realitzar un exercici comparatiu entre termes i definicions a fi d'agrupar-los en una mateixa dimensió. Aquest exercici es materialitza en la **Taula 7** de l'apartat 2.2.2. Tercerament, s'ha descobert que en alguns estudis s'usen els mateixos termes però amb significat diferent⁵²; en destaca, per exemple, el concepte *validity* que per a Mahanti (2018 i 2019) s'associa al compliment d'estàndards o guies, mentre que DAMA International (2009 i 2017) ho vincula a si els valors de les dades són consistents dins d'un domini de valors⁵³ prèviament definit —pot incloure el tipus de dada, el format, la precisió dels valors, entre altres—. Quart, s'ha trobat que hi ha certa confusió entre les dimensions de disponibilitat i accessibilitat, ja que en algunes investigacions la disponibilitat es defineix en termes d'accés a les dades (Open Data Support, 2014; APORTA, 2017); mentre que en altres estudis, com per exemple a la norma ISO/IEC 25012:2018, la disponibilitat es vincula a la recuperabilitat i ús dels conjunts de dades. En aquest estàndard l'accessibilitat es defineix en termes d'accés real en un context d'ús específic, com ara en el cas de les persones amb diversitat funcional que necessiten suport tecnològic o una configuració especial. I, en darrer terme, hi ha dificultats en

classificar algunes dimensions, n'és un exemple la completesa, ja que a la norma abans citada s'inclou dins les característiques inherents, mentre que en altres estudis (Wang & Strong, 1996; Strong, Lee & Wang, 1997) forma part de les característiques contextuals.

Finalment, per a més informació es remet a la **Taula 8** de l'apartat 2.2.2 on es presenta un estudi de les investigacions i estàndards revisats en el que s'han identificat un total de 50 dimensions de qualitat.

1. 4. 4. Aproximació a la gestió de la qualitat de les dades (*data quality management*)

L'organització professional DAMA International (2009) defineix la gestió de la qualitat de les dades (*data quality management - DQM*) com totes aquelles «*planning, implementation, and control activities that apply quality management techniques to measure, assess, improve, and ensure the fitness of data for use*» (p.292). Més concretament, la gestió de la qualitat de les dades és una de les 11 àrees de coneixement de la gestió de les dades descrites en el DMBOK2, tal com es desprèn de la Roda DAMA:

⁵² Per a més informació es remet a l'obra de Mahanti (2018), on a l'apèndix A es presenta una comparativa de les diferents definicions utilitzades en la literatura en relació amb les dimensions de completesa, conformitat, unicitat, consistència, exactitud, integritat, pertinència temporal, actualitat i volatilitat.

⁵³ Per a DAMA International (2017) un domini de valors pot ser un conjunt de valors vàlids (per exemple, una taula de referència), un rang de valors, o un valor que pot ser determinat mitjançant regles.



Figura 14. El marc de referència de gestió de dades DAMA DMBOK2.

La Roda DAMA (Font: DAMA International, 2017).

Així mateix, segons DAMA International (2017) la gestió de la qualitat de les dades ha de guiar-se per un conjunt de principis rectors, alguns dels quals es detallen tot seguit:

1. **Criticitat.** Un programa de qualitat de dades ha de focalitzar-se en les dades més crítiques per a l'organització i els seus usuaris.
2. **Gestió del cicle de vida.** La qualitat de les dades ha de gestionar-se durant tot el cicle de vida de les dades⁵⁴, des de la seva creació o captura fins a la seva eliminació. També inclou la gestió de dades durant els processos de transferència intra i intersistemes.
3. **Prevenió.** La finalitat de la qualitat de les dades és la prevenció dels errors en les mateixes, així com les condicions que perjudiquen la seva usabilitat. Per tant, la DQM ha de ser proactiva, no reactiva.
4. **Anàlisi i solució de la causa arrel.** Millorar la qualitat de les dades va més enllà de corregir errors. En aquest sentit, és important l'anàlisi de la causa arrel que, sovint, sol estar relacionada amb el disseny dels processos i sistemes. Consegüentment, el desenvolupament de solucions passa per transformar i millorar els processos i sistemes que donen suport a les dades.

⁵⁴ El cicle de vida de les dades inclou, sense caràcter limitatiu, la creació, la captura, la transformació, l'emmagatzematge, l'exportació, la importació, l'actualització, la neteja, la millora, l'ús i l'eliminació. No obstant, tal com senyala DAMA International (2009 i 2017), el cicle de vida comença abans de l'adquisició de les dades, en concret amb la planificació empresarial de dades, l'especificació de dades i l'habilitació de la captura de les mateixes. Així doncs, els processos que es realitzen per a la gestió del cicle de les dades són els següents: planificar – especificar – habilitar – crear i capturar/adquirir – mantenir i utilitzar – arxivar i recuperar – eliminar. En tot aquest cicle, la creació i l'ús són els punts més crítics, per tant, és important comprendre com es produeixen i/o s'obtenen les dades, i també com s'utilitzen.

5. **Govern de dades.** Les activitats del govern de dades⁵⁵ han de recolzar el desenvolupament de dades d'alta qualitat. Així mateix, les activitats de la gestió de la qualitat de les dades han d'assegurar i mantenir un entorn de dades governat.
6. **Ús d'estàndards.** Els requisits de qualitat de les dades han de definir-se en forma d'estàndards i han de ser mesurables, a fi de poder mesurar la qualitat de les dades.
7. **Mesurament objectiu i transparent.** Els nivells de qualitat de les dades s'han de poder mesurar de forma objectiva i coherent. Altrament, tant el mesurament com la metodologia de mesura emprada s'han de compartir amb les parts interessades, ja que són els àrbitres de la qualitat.
8. **Aplicació sistemàtica.** S'ha de complir sistemàticament amb els requisits de qualitat de les dades. A més, els processos i activitats per a la gestió de la qualitat de les dades s'han d'aplicar de forma proactiva, planificada i sistemàtica en l'organització.

En alguns estudis consultats s'observa l'existència d'un paradigma que es fonamenta en l'analogia entre la fabricació de productes físics i la generació de productes de dades (Wang, Storey & Firth, 1995; Wang, 1998; Kahn, Strong & Wang, 2002; DAMA International, 2017). Dins d'aquest marc de referència les dades es conceben com el producte d'un conjunt de processos, que transformen les entrades del sistema en sortides; raó per la qual en la DQM s'apliquen conceptes i metodologies provinents de la gestió de la qualitat. Aquesta perspectiva de producte és la que porta a desenvolupar la gestió de la qualitat de les dades total (*Total Data Quality Management - TDQM*), com anàleg de l'estratègia de gestió de la qualitat total (*Total Quality Management - TQM*). La metodologia TDQM es basa en el cicle TDQM que és una variació del cicle de Deming - PDCA per a la millora contínua, que consisteix en quatre passos: planificar (*plan*), fer (*do*), verificar (*check*) i actuar (*act*). Així doncs, el cicle TDQM també es divideix en quatre nivells (Wang, 1998):

1. **Definir o especificar.** Consisteix en definir les dimensions de la qualitat de les dades que seran avaluades en el segon nivell.

⁵⁵ Segons DAMA International (2009), el Govern de dades és l'àrea de coneixement encarregada de «*the exercise of authority and control (planning, monitoring, and enforcement) over the management of data sets. Data Governance is high-level and control over data management*» (p.19). Dins la roda DAMA, el govern de dades és situa en el centre ja que és l'àrea que proporciona direcció i supervisió a tot el conjunt d'àrees que conformen la gestió de dades.

2. **Mesurar.** Consisteix en el desenvolupament de les mètriques i mesurament de cada una de les dimensions identificades.
3. **Analitzar.** Consisteix en analitzar els resultats dels mesuraments a fi d'identificar problemes de qualitat.
4. **Millorar.** Consisteix en establir accions de millorar per a solucionar els problemes de qualitat identificats prèviament.

D'altra banda, la norma ISO 8000-61:2016 estableix un model de referència per a processos de la gestió de la qualitat de les dades, que es fonamenta en tres principis essencials: l'enfocament a processos, la millora contínua i la participació de les persones. Segons la norma citada la gestió de la qualitat de les dades inclou els següents macro processos:

1. **El procés d'implementació**, que inclou aquells sub-processos relacionats amb la identificació dels requisits de les dades segons les necessitats i expectatives de les parts interessades. També comprèn l'establiment d'objectius i la creació dels plans d'implementació per al compliment dels requisits establerts.

Per aconseguir la millora contínua de la qualitat de les dades, el procés d'implementació s'ha d'executar contínuament seguint el cicle PDCA, que es divideix en quatre passos:

- a. **Planificació de la qualitat de les dades (plan).** Estableix els requisits, els objectius, l'estratègia i els plans per assolir resultats conformes amb els requeriments de dades. A la vegada, es subdivideix en gestió de requisits; gestió d'estratègies de la qualitat de les dades; gestió de polítiques/estàndards/procediments de qualitat de les dades; i planificació de la implementació de la qualitat de les dades.

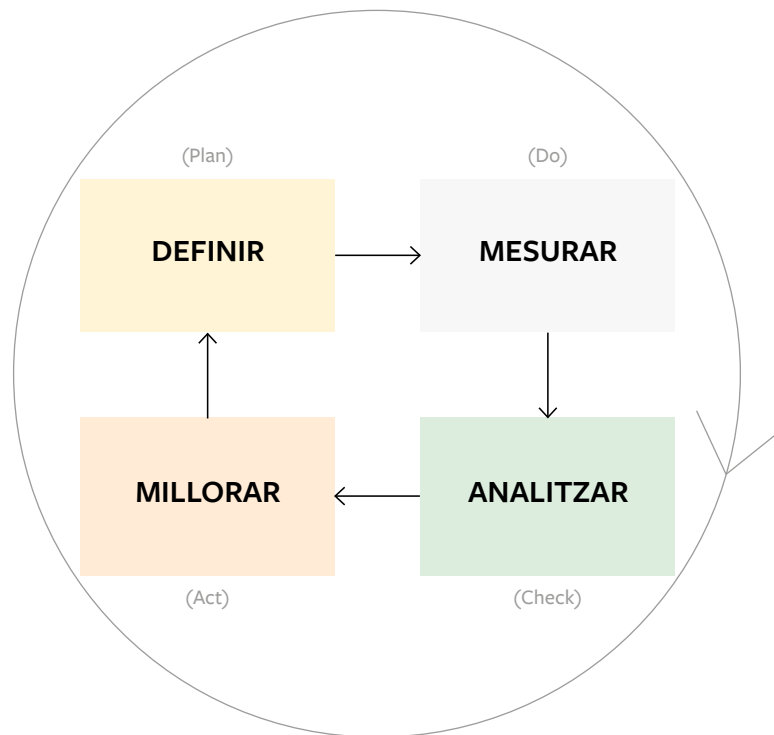


Figura 15. Relació entre el cicle TDQM i el cicle PDCA (Font: Elaboració pròpia, 2021)

b. Control de la qualitat de les dades (do). Es realitza segons el pla d'implementació establert en el nivell anterior. Consisteix en la definició i gestió dels riscos associats al cicle de vida de les dades, així com en el monitoratge i control dels processos i de les dades. Aquest grup es subdivideix en subministrament d'especificacions de dades i instruccions de treball; processament de dades; i seguiment i control de la qualitat de les dades.

c. Assegurament de la qualitat de les dades (check). Desenvolupa les mètriques, el mesurament dels nivells de qualitat de les dades i del rendiment del processos relacionats amb les no conformitats o altres problemes que hagin sorgit en els nivells anteriors, així com l'anàlisi i avaluació dels resultats obtinguts. Es subdivideix en els següents processos: revisió de problemes de la qualitat de les dades, provisió de criteris de mesurament; mesurament de la qualitat de les dades i el rendiment del procés; i l'avaluació dels resultats del mesurament.

d. Millora de la qualitat de les dades (act). Aquest grup de processos inclou l'anàlisi de la causa arrel (*root cause analysis – RCA*) de la no conformitat així com el desenvolupament de solucions; també la neteja de dades i la millora de processos per a la prevenció de no conformitats de la qualitat de les dades.

2. **El procés de suport relacionat amb les dades**, que habilita el procés d'implementació proporcionant informació i tecnologia relacionada amb la gestió de les dades.
3. **El procés de provisió de recursos** que proporciona efectivitat i eficiència als processos d'implementació i suport relacionat amb les dades, mitjançant l'aprovisionament de recursos i formació en el nivell organitzacional.

A continuació, es visualitza l'estructura i les relacions que s'estableixen entre els processos i sub-processos de la gestió de la qualitat de les dades descrits amb anterioritat.

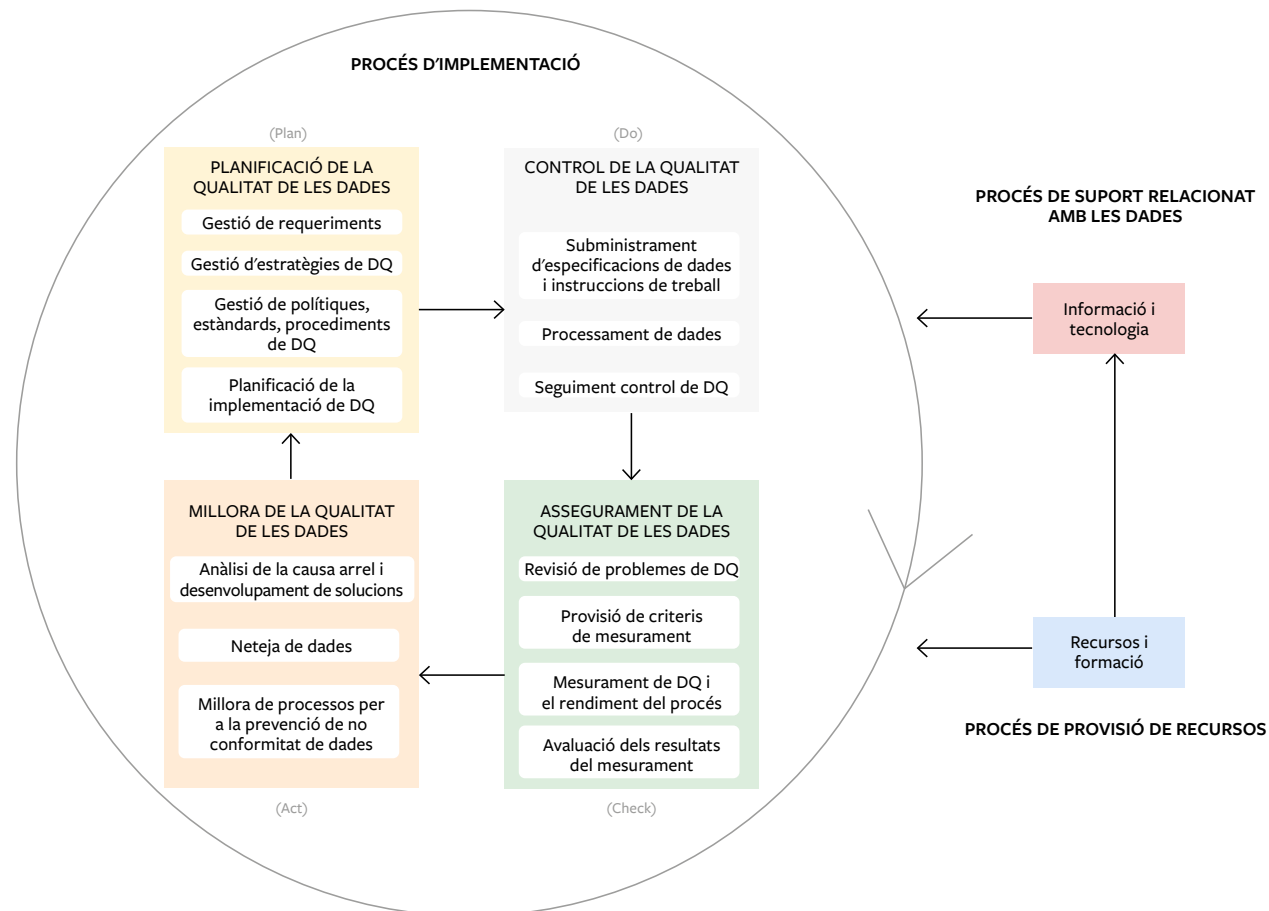


Figura 16. Estructura dels processos i sub-processos de la gestió de la qualitat de les dades (Font: Adaptació a partir de la norma ISO 8000-61:2016)

A grans trets, existeixen diferències entre el cicle TDQM i el cicle PDCA de la norma ISO 8000-61:2016 que es poden resumir de la següent manera: el cicle TDQM tal com està plantejat per Wang (1998) no implica realment un control total de la qualitat, ja que es limita a la identificació de no conformitats en relació amb la qualitat de les dades i a la correcció de les mateixes. A més es focalitza en les sortides del sistema, és a dir, en els productes de dades. Per contra, el cicle PDCA de l'estàndard està orientat no només a la detecció de defectes

sinó també a la prevenció dels mateixos i a l'anàlisi i solució de la causa arrel, entenent que les causes poden estar relacionades amb el disseny de processos o sistemes i que, per tant, per a millorar la qualitat de les dades pot ser necessari transformar i millorar els processos i sistemes que els donen suport. En aquest sentit, la norma ISO 8000-61:2016 estableix un conjunt de processos i activitats planificades i sistemàtiques centrades tant en les dades com en els processos que les creen, les gestionen, les actualitzen, etc. D'aquesta

manera, s'implementa una gestió proactiva de la qualitat de les dades que a més té en consideració els recursos, la capacitat de les persones, la informació i la tecnologia com a elements que possibiliten la correcta implantació del cicle PDCA per a la millora continua de la qualitat de les dades.

En un altre ordre de coses, es parteix de la idea de què la perspectiva de la norma ISO 8000-61:2016 es fonamenta en l'anomenada "trilogia de Juran". Aquest enfocament, basat en el model de gestió de la qualitat de Joseph Juran (2001⁵), estableix tres grans processos de la gestió de la qualitat: la planificació de la qualitat, el control de la qualitat i la millora de la qualitat. Si bé no és objecte del present treball un revisió exhaustiva de dita estratègia, convé especificar dos aspectes: en primer lloc, la trilogia no contempla l'assegurament de la qualitat que té com a finalitat verificar que s'està mantenint el control (Juran, Blanton, Hoogstoel & Schilling, 2001⁵, 4.3). I, en segon lloc, la metodologia de control de la qualitat es basa en el circuit de retroalimentació la implantació del qual es divideix en quatre fases, en aplicació del cicle PDCA o de Deming. En la primera fase (*plan*) es realitza el disseny del circuit: elecció dels objectes de control, identificació dels punts de control, fixació de les normes, establiment de les mesures, designació de responsabilitats, etc.; en la segona fase (*do*) es realitza el mesurament; en la tercera fase (*check*) s'analitzen els resultats obtinguts i es comparen amb els estàndards i requisits i, en la quarta fase (*act*) s'actua sobre la diferència mitjançant mesures correctores. Aquest circuit és el que s'ha representat a la **Figura 11** sobre funcionament d'un sistema

cibernètic; tot i que a diferència de la imatge es poden establir diversos punts de control i realitzar les mesures en diferents moments del procés, no només en la sortida.

Fins ara s'ha tractat tant la metodologia com els processos de la gestió de la qualitat de les dades, però és important remarcar que l'àrea de coneixement també està conformada per objectius, entrades, sortides, *stakeholders*, eines, etc. Aquesta perspectiva sistèmica de la DQM és la que s'infereix del diagrama de context elaborat per l'organització professional DAMA International en la seva obra DAMA DMBOK1 (2009), i que a continuació es reproduïu:

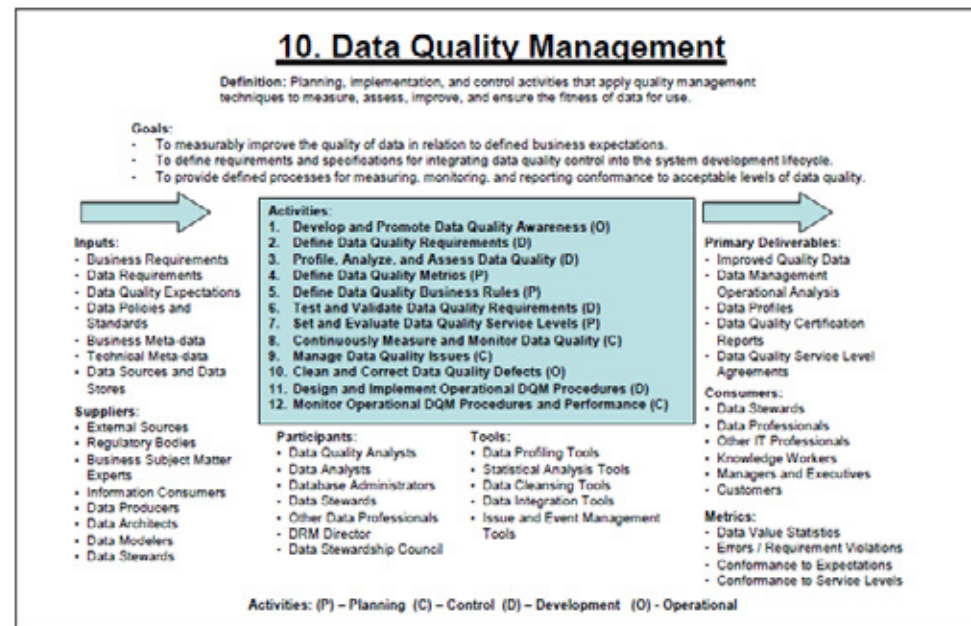


Figura 17. Diagrama de context de la gestió de la qualitat de les dades (Font: DAMA International, 2009).

En el quadre central de la figura anterior s'hi concreten les 12 activitats que es desenvolupen en el marc de la gestió de la qualitat de les dades, en concret són les següents:

1. Desenvolupar i promoure el coneixement de la qualitat de les dades.
2. Definir els requisits de qualitat de les dades.
3. Perfilar, analitzar i avaluar la qualitat de les dades.
4. Definir les mètriques de qualitat de les dades.
5. Definir les regles de negoci de qualitat de les dades.
6. Provar i validar els requisits de qualitat de les dades.
7. Establir i avaluar els nivells de servei de qualitat de les dades.
8. Mesurar i monitoritzar contínuament la qualitat de les dades.
9. Gestionar els problemes de qualitat de les dades.
10. Netejar i corregir els defectes de qualitat de les dades.
11. Dissenyar i implementar procediments operatius de gestió de la qualitat de les dades.

12. Supervisar els procediments i el rendiment operatiu de gestió de la qualitat de les dades.

Aquest llistat d'activitats es pot vincular al procés d'implementació i als quatre sub-processos del cicle PDCA de la norma ISO 8000-61:2016, és a dir, a la planificació DQ, al control DQ, a l'assegurament DQ i a la millora DQ.

Un altre punt important és la relació entre la qualitat de les dades i les metadades, ja que tal com indica DAMA International (2017) les metadades són crítiques per a gestionar la qualitat de les dades. Per entendre aquesta criticitat, convé recordar que les dades són una forma de representació i a la vegada una interpretació dels objectes que representen, però també són un objecte que s'ha d'interpretar, tal com es mostra a la **Figura 18** (Camps, 2013; DAMA International, 2017). Per a dotar de significat aquestes dades es necessita context, és a dir, un sistema de representació de les dades que inclogui un vocabulari comú i un conjunt de relacions entre entitats, atributs, valors i temps. Les convencions d'aquest sistema es documenten en metadades, les quals permeten interpretar les dades dins del mateix sistema (DAMA International, 2017). Les metadades descriuen el conjunt de dades, el contingut, els processos, les condicions, la disponibilitat, la història, la qualitat —per exemple, l'origen de les dades, el procés d'elaboració o la conformitat de requisits de qualitat—, entre altres aspectes. Així doncs, una correcta documentació i gestió de les metadades és fonamental per a mantenir el context, significat i estructura

de les dades, cosa que facilita la gestió, anàlisi i ús de les mateixes. Més concretament, DAMA International (2017) destaca dues aportacions de les metadades a la qualitat de les dades: d'una banda, disposar d'un procés sòlid mitjançant el qual es defineixen les dades, recolza la capacitat d'una organització per a formalitzar i documentar els estàndards i requisits a partir dels quals es mesura la qualitat de les dades. I d'altra banda, la correcta gestió i administració de les metadades facilita la DQM al proporcionar, per exemple, un repositori centralitzat de metadades amb els resultats dels mesuraments de qualitat per a que pugui ser compartit en tota l'organització. Per a PowerData Solutions (2016)⁵⁶, la gestió de metadades en un repositori centralitzat permet tenir una visió més completa del cycle de vida de les dades, des de la seva creació fins al seu consum i/o eliminació; a més facilita l'estandardització de les mateixes a partir de la correcció d'errors i inconsistències i, per tant, millora la qualitat de les dades al llarg del seu cycle de vida. Amb tot plegat, les metadades posseeixen un rol important en la gestió de les dades en general, i en la qualitat de les mateixes en particular.

En darrer terme, no es pot obviar que les metadades són una forma de dades i que les organitzacions depenen d'elles per a gestionar altres dades, raó per la qual és important gestionar també la qualitat de les metadades durant tot el seu cycle de vida, talment que altres tipus de dades (DAMA International, 2017).

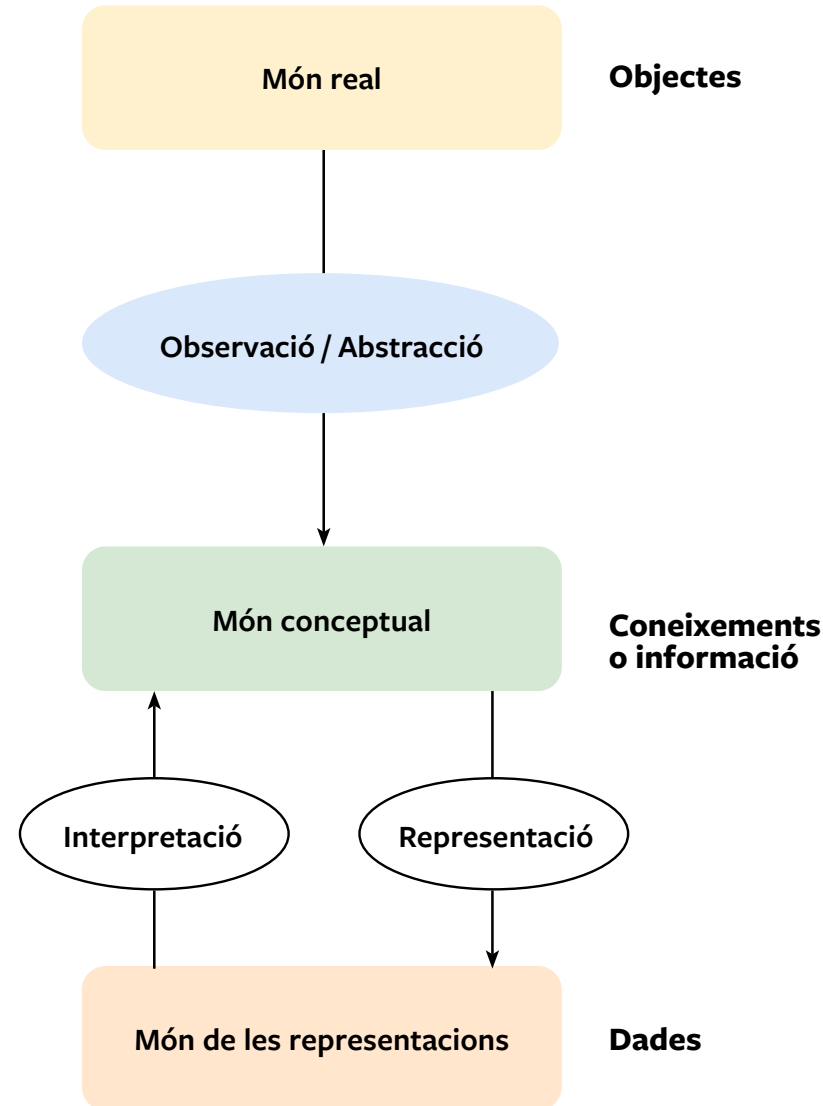


Figura 18. Els tres mons: el real, el conceptual i el de les representacions
(Font: Rafael Camps, 2013).

⁵⁶ Per a més informació es remet a <https://blog.powerdata.es/el-valor-de-la-gestion-de-datos/que-son-los-metadatos-y-cual-es-su-utilidad>

1. 4. 5. Mesurament i avaluació de la qualitat de les dades

En aquest apartat s'indiquen els principals conceptes vinculats al mesurament que s'utilitzen en el projecte, la definició dels quals prové de les normes UNE-ISO/IEC 14598-1:2004⁵⁷ i ISO/IEC 25012:2008. Seguidament es resumeix l'estat de l'art pel que fa a l'avaluació de les dimensions de qualitat de les dades vistes a l'apartat 1.4.3, amb especial èmfasis als indicadors emprats per avaluar les iniciatives de dades obertes, concretament aquells indicadors relacionats amb la qualitat.

1. 4. 5. 1. Conceptes bàsics

En relació amb la terminologia vinculada al mesurament és important establir la definició d'alguns dels aspectes més rellevants, amb la finalitat d'alinejar-se amb el vocabulari més comunament emprat. En concret, els conceptes que s'utilitzen en el present projecte són els que a continuació es detallen:

- **Escala:** conjunt de valors amb propietats definides. Així mateix hi ha quatre tipus d'escala (UNE-ISO/IEC 14598-1:2004):

- » **Nominal:** es correspon a un conjunt de categories.
- » **Ordinal:** es correspon a un conjunt ordenat de punts d'escala.
- » **Interval:** es correspon a una escala ordenada amb punts d'escala equidistants.
- » **Ràtio:** no només té punts d'escala equidistants sinó també posseeix un zero absolut.

- **Indicador:** mesura que pot ser utilitzada per estimar o predir una altra mesura (UNE-ISO/IEC 14598-1:2004).
- **Mesurar:** realitzar un mesurament (UNE-ISO/IEC 14598-1:2004).
- **Mesura:** el número o categoria assignat a un atribut⁵⁸ d'una entitat mitjançant la realització d'un mesurament (UNE-ISO/IEC 14598-1:2004). Dit d'una altra forma, es tracta del resultat obtingut del procés de mesurament. No obstant, en el marc d'aquest projecte el terme mesura també s'utilitza com a acció i efecte de mesurar. Segons la norma ISO citada, hi ha dos tipus de mesures:
 - » **Mesura directa:** mesura d'un atribut que no depèn d'una mesura d'un altre atribut.
 - » **Mesura indirecta:** mesura d'un atribut que es deriva de mesures d'altres atributs.

⁵⁷ La norma UNE-ISO/IEC 14598-1 no és d'aplicació per a l'avaluació de les dimensions i elements de qualitats de les dades obertes. Tanmateix, hi ha aspectes a tenir en consideració tal com els termes i definicions que s'utilitzen, i les fases del procés d'avaluació les quals s'assimilen al cicle PDCA.

⁵⁸ En el marc de la present investigació amb el terme atribut es fa referència als elements *open data quality (ODQ)*.

- **Mesurament:** ús d'una mètrica per assignar un valor d'una escala a un atribut d'una entitat (UNE-ISO/IEC 14598-1:2004).
- **Mesurament de la qualitat de les dades:** variable a la qual s'assigna un valor com a resultat d'un mesurament de la característica de la qualitat de les dades (ISO/IEC 25012:2008).
- **Mètrica:** és el mètode de mesurament i l'escala de mesurament (UNE-ISO/IEC 14598-1:2004).
- **Nivell de puntuació:** un punt de l'escala en una escala ordinal que s'utilitza per a categoritzar una escala de mesurament (UNE-ISO/IEC 14598-1:2004). No obstant, en el cas del present projecte el nivell de puntuació (també anomenat puntuació) s'empra de forma similar al terme resultat obtingut.

1. 4. 5. 2. Mètriques i indicadors per avaluar les dimensions de qualitat de les dades

De la revisió de la literatura sobre dimensions de qualitat de les dades (*vid.* apartat 1.4.3 i **Taula 8**) es constata que hi ha una multiplicitat de mètriques per a mesurar els diferents elements DQ, per exemple l'escala de cinc estrelles per a mesurar el grau d'obertura (Berners-Lee, 2010) o la

mètrica MELODA que avalua el nivell de reutilització de les dades (Abella, Ortiz-de-Urbina-Criado & De-Pablos-Heredero, 2014 i 2019); altrament s'han localitzat mètriques diferents per a una mateixa característica, tal és el cas de la traçabilitat (Mahecha, López & Velandia, 2017; Mahanti, 2018; ISO/IEC 25012:2018) o la pertinència temporal (Ballou, Wang, Pazer & Tayi, 1998; Mahanti, 2018). Tanmateix, en aquest escenari de variabilitat, l'estàndard ISO/IEC 25012:2018 defineix un model de qualitat de dades per a productes de software en el qual s'identifiquen les característiques DQ i també les mètriques per avaluar aquestes propietats, algunes de les mesures són inherents i altres depenen del sistema. D'altra banda, destaca l'obra de Mahanti (2018) on en el capítol 4 s'estableix una sèrie de mètriques, tant objectives com subjectives⁵⁹, per avaluar les següents dimensions DQ: la completesa, la unicitat, la validesa, l'exactitud, la consistència, la integritat, la volatilitat, l'actualitat, la pertinència temporal, la rellevància, la traçabilitat, la cobertura de dades, l'accessibilitat, la seguretat, la fiabilitat, la facilitat de manipulació, la concisió, l'objectivitat, la interpretabilitat, la credibilitat i la confiabilitat. Convé ressaltar també l'obra de Batini & Scannapieco (2016) en la qual s'estableixen mètriques per a les dimensions relacionades amb el temps, en particular la pertinència temporal, la volatilitat i l'actualitat.

Pel que fa a l'àmbit concret de les dades obertes, a la guia estratègica de la *Federación Española de Municipios y Provincias*

⁵⁹ Les mètriques objectives són aquelles que poden ser quantificades i el seu mesurament es realitza mitjançant fórmules, tal com la completesa. En canvi, les mètriques subjectives són aquelles que es fonamenten en una avaluació qualitativa, atès que no poden ser quantificades i el seu mesurament es realitza mitjançant enquestes d'usuari (Mahanti, 2018).

(FEMP) (2017) es descriuen les propostes de sistemes de mesurament per avaluar les iniciatives de dades obertes, en les quals es contemplen mètriques per a mesurar la qualitat de les dades obertes. Una de les iniciatives és l'*Open Data Maturity in Europe*⁶⁰ que és un projecte del Portal Europeu de Dades Obertes (*European Data Portal*, en anglès) que mesura anualment la qualitat de les metadades i dades obertes a partir de quatre àmbits: la integritat i completesa de les (meta)dades, el compliment al vocabulari DCAT-AP⁶¹, l'existència de mecanismes per al seguiment i avaluació de les (meta)dades i la disponibilitat de les dades (tipus de formats, de llicències, dades enllaçades, etc.) (FEMP, 2017; Comissió Europea, 2020). Un altre projecte és l'*Open Data Barometer*, promogut per la *World Wide Web Foundation*, on la recopilació de les dades per a l'anàlisi posterior es realitza a través d'enquestes d'experts i d'autoavaluació, en les quals —pel que fa a l'àmbit de la qualitat de les dades— es pregunten aspectes relacionats amb les llicències utilitzades, l'existència de formats processables per màquina, l'actualització dels conjunts de dades, etc. La finalitat d'aquesta iniciativa és esdevenir una metodologia global per al mesurament de les iniciatives de dades obertes (en *World Wide Web Foundation*, 2017⁶²).

En el context estatal destaca la norma UNE 178301:2015 sobre dades obertes en ciutats intel·ligents, elaborada per

AENOR, en la que es proporcionen directrius per avaluar la publicació de dades obertes, a través d'un conjunt de mètriques i un indicador, a fi d'obtenir el grau de maduresa de les iniciatives de dades obertes públiques. D'entre aquestes mètriques convé subratllar les vinculades a la dimensió de qualitat de les dades, en què es mesura el nivell assolit de completesa, documentació, correctesa, georeferenciació, primacia i ús de dades enllaçades per part de les organitzacions. Així mateix, la finalitat de l'estàndard és proporcionar «(...) a las Administraciones Locales herramientas metodológicas para que puedan evaluar el grado de madurez de su proyecto de datos abiertos, facilitando la puesta y la mejora continua, teniendo en cuenta todos aquellos aspectos que repercuten en la sostenibilidad, calidad, eficiencia y eficacia del proyecto.» (APORTA, 2018, 4).

Finalment, per a un major aprofundiment sobre mètriques de qualitat de les dades obertes es remet a l'estudi de Slibar, Oreski & Klicek (2018) en el que es realitza una revisió de la literatura, on s'identifiquen 10 marcs de qualitat de dades que contenen mètriques relacionades amb la consistència, la completesa, l'exactitud, la unicitat, l'accessibilitat, la usabilitat i comprensibilitat, la pertinència temporal, la utilitat i la granularitat.

60 Per a més informació sobre el projecte es remet a l'informe de l'any 2020 de la iniciativa Open Data Maturity: https://data.europa.eu/sites/default/files/edp_landscaping_insight_report_n6_2020.pdf

61 Per a més informació sobre el vocabulari DCAT-AP es remet a l'apartat 2.3.

62 Per a més informació sobre el projecte es remet a la pàgina web de l'Open Data Barometer: https://opendatabarometer.org/?_year=2017&indicator=ODB

2. Proposta teòrica i metodològica per avaluar la qualitat de les dades obertes

Aquest capítol, en el qual es presenta la proposta teòrica i metodològica per avaluar la qualitat de les dades obertes, s'estructura en quatre grans apartats que són els que a continuació es detallen: en un primer apartat s'exposen les característiques bàsiques del model les quals han de servir per comprendre l'abast i les limitacions del mateix. Seguidament es desenvolupa el marc referencial del model, és a dir, s'identifiquen i detallen els diferents nivells que conformen la qualitat de les dades obertes. En el tercer apartat, que està dedicat al vocabulari de metadades per a la descripció de les dades obertes, s'identifiquen aquells vocabularis aplicables en el marc de projectes *open data*, més concretament DCAT, DCAT-AP i la Guia tècnica de la Generalitat de Catalunya. Finalment, en el quart i últim apartat, es desenvolupen les mètriques i indicadors per avaluar cada un dels elements identificats en el segon apartat, així com la forma de calcular els valors finals i totals de les mètriques.

2. 1. Característiques bàsiques del model de qualitat de les dades obertes

En la present proposta s'estableix un model de qualitat de les dades obertes on s'identifiquen i defineixen les dimensions i elements *open data quality* (d'ara en endavant, ODQ) (model conceptual), les interrelacions entre els diferents nivells que

conformen el marc de referència (model lògic), i les mètriques i indicadors per avaluar cada un dels elements ODQ a fi d'obtenir, en última instància, el valor total de la qualitat dels datasets i de les seves metadades en el context de projectes de dades obertes (model metodològic). Així doncs, la proposta es desenvolupa a través de tres models específics l'articulació dels quals permet avaluar les dimensions de qualitat de les dades obertes, tal com es desprèn de la **Figura 19**.

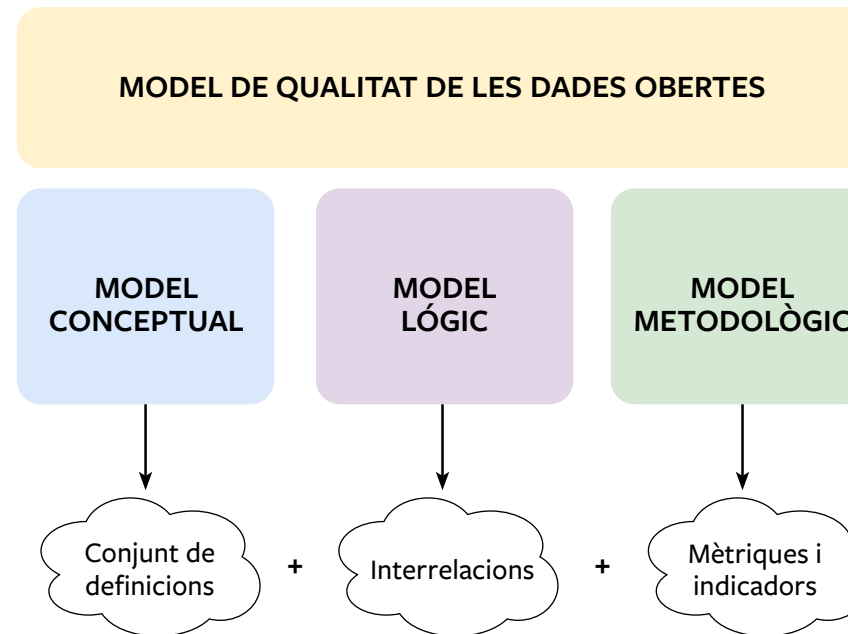


Figura 19. Configuració del model ODQ (Font: Elaboració pròpia, 2021).

Altrament, aquest model s'ha concebut particularment per l'avaluació de dades estructurades, típiques de les bases de dades relacionals. Per tant, la proposta se centra en l'avaluació de models relacionals que són aquells que es caracteritzen per proporcionar una estructura de les dades consistent en un conjunt de relacions, la qual es pot visualitzar com una representació tabular formada per files i columnes (Costal, 2013). Com a nota terminològica, en aquest treball s'empra el terme tupla, registre o fila de forma sinònima; també s'utilitzen de forma equivalent el mots atribut i columna; i amb el terme valor es fa referència a l'element dada que s'informa en una cel·la concreta.

En un altre ordre de coses, el model representa una proposta d'agregació i ampliació en la que, d'una banda, es desenvolupa un model conceptual i lògic a partir de l'anàlisi de les dimensions i elements més citats a la literatura consultada sobre qualitat de dades en general, i dades obertes en particular; i també tenint en consideració la perspectiva arxivística i de gestió documental a partir dels estàndards d'aplicació en aquest àmbit. I, d'altra banda, pel que fa al model metodològic s'ha efectuat una primera versió unificada de mètriques concebudes per altres investigadors i investigadores, o emprades en normes nacionals i internacionals. No obstant, per aquells elements ODQ en què les mètriques existents no s'adeqüen a la descripció realitzada o, directament, no hi ha mètriques, s'ha realitzat una proposta amb indicació de la forma de càlcul, la puntuació màxima i observacions.

En darrer terme, convé destacar que el model no només pot esdevenir una eina interna de diagnosi del nivell de qualitat de les dades publicades per part dels responsables dels projectes *open data* de les organitzacions, sinó també pot ser utilitzat per terceres parts independents i externes a les organitzacions a fi d'avaluar el nivell de qualitat de les dades obertes.

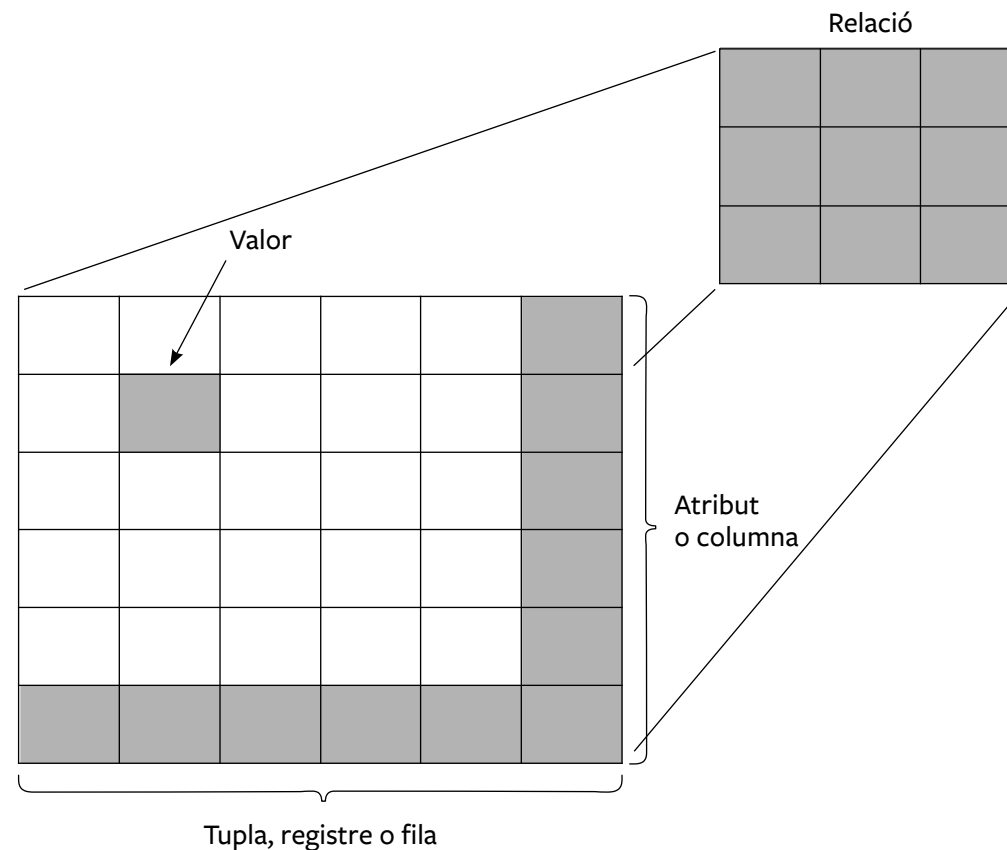


Figura 20. Elements que conformen una base de dades relacional

(Font: Adaptació a partir de Batini & Scannapieco, 2016).

2.2. Marc de referència de les dimensions de qualitat de les dades obertes

Tal com s'ha vist en el capítol 1.4, la qualitat de les dades és un concepte multidimensional, jeràrquic i complex. El marc de referència proposat per a la qualitat de les dades obertes presenta quatre nivells jeràrquics que són els que a continuació es detallen:

- 1. Qualitat de les dades:** es tracta del primer nivell del model i constitueix la totalitat de les diferents dimensions de la qualitat de les dades.
- 2. Categories de la qualitat de les dades:** és el segon nivell del model i conforma cada un dels grups o classes d'alt nivell en els que s'agrupen les dimensions i elements ODQ.
- 3. Dimensions de la qualitat de les dades:** es tracta del tercer nivell del model i captura cada un dels aspectes particulars que conformen el context general de la qualitat de les dades obertes.
- 4. Elements de la qualitat de les dades:** és el quart nivell del model i el formen cada un dels components o atributs mesurables que configuren una dimensió específica de la qualitat de les dades obertes.

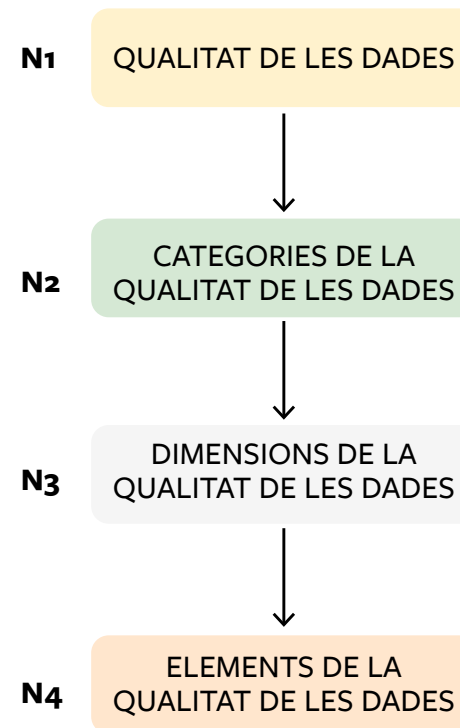


Figura 21. Marc de referència de la qualitat de les dades obertes
(Font: Elaboració pròpia, 2021).

Realitzant un paral·lelisme amb la ciència arxivística, el marc de referència proposat s'assimilaria a un quadre de classificació (QdC) ja que ambdós instruments presenten una estructura jeràrquica i lògica de conceptes en la que, en el cas del model de qualitat de les dades obertes, s'identifiquen i agrupen les característiques i propietats específiques que configuren la qualitat de les dades. També s'evidencien les relacions jeràrquiques que s'estableixen entre els diferents nivells del model, així com les correlacions i interconnexions existents. Continuant amb l'analogia del QdC, el primer nivell del model es

correspondria al fons; el segon nivell a les funcions o seccions; i el tercer i quart nivell a les activitats o sèries i subsèries. Similarmet al desenvolupament d'un QdC, en els primers nivells es defineixen els aspectes més genèrics fins arribar a l'últim nivell, en el que es concreten els components més particulars, atenent els nivells jeràrquics prèviament identificats.

A continuació es presenten les categories (subapartat 2.2.1) així com les dimensions i els elements (subapartat 2.2.2) que conformen el model de qualitat de les dades obertes, la representació del qual es reflecteix en un diagrama ontològic (subapartat 2.2.3).

2. 2. 1. Categories de la qualitat de les dades obertes

En el present apartat s'identifiquen les categories de la qualitat de les dades obertes a partir de la revisió de les categories que s'estableixen en la literatura sobre qualitat de les dades, però també dels components que configuren els documents. Aquesta revisió es representa a la **Taula 6**, en la qual s'identifiquen els investigadors/ investigadores i projectes consultats, tal com es mostra a continuació:

Redman (1996, 2001) *	English (1999) *	Loshin (2010) *	Wang & Strong (1996)	ISO/IEC 25012: 2018	Cruz Mundet (2011, 2012)	Guia NTI document electrònic (2016)	Wilson (2007), InSPECT Project, TNA i CeRch	The InterPARES 2 Project (s.a.)
Data values	Content characteristics	Intrinsic	Intrinsic DQ	Inherent DQ	Contingut	Informació	Content	Content
Data model					Estructura	Estructura	Structure	Intellectual Form
Data representation	Presentation characteristics		Representational DQ	System dependent DQ	Presentació		Appearance	Physical Form Medium
		Contextual	Contextual DQ		Context	Context	Context	Context
Data commitment		Qualitative						
Data accessibility			Accessibility DQ					
Data privacy								
Data improvement								
						Identificació		
							Behaviour	Archival Bond
								Acts
								Persons

(*) Extret de Mahanti, 2018.

Taula 6. Comparativa de les característiques de qualitat de les dades i dels components del document (Font: Elaboració pròpia, 2021)

De la taula anterior s'infereix que hi ha un conjunt de categories que es repeteixen en la literatura, malgrat presentin denominacions diferents. En concret, les categories més citades són el contingut, l'estructura, la representació i el context. Tot seguit es defineixen aquestes categories ODQ juntament amb el comportament que, malgrat només es menciona en el projecte InSPECT realitzat per *The National Archives* (TNA) i *The Centre for e-Research, King's College London* (CeRch), s'inclou dins el conjunt de categories que configuren el segon nivell del model ja que es considera que pot ser d'especial rellevància en el cas de *linked open data* (LOD). Així doncs, a partir de la literatura identificada es defineixen les categories de la següent manera:

1. Contingut: comprèn totes aquelles característiques intrínseques de les dades que són independents del procés d'ús de les dades, així com del domini tecnològic en el que les dades són utilitzades. Particularment s'inclouen aquells aspectes relacionats amb l'expressió de la informació, tal com els següents:

- a. Els valors de dades i les relacions entre aquests valors.

- b. Els valors de dominis de dades i les regles de negoci i possibles restriccions.

2. Estructura: és la forma particular en la que les dades s'organitzen amb l'objectiu de facilitar la seva manipulació. En particular, s'engloben els següents elements:

- a. L'organització de les dades.
- b. Les interrelacions entre els elements que conformen l'estructura de dades, amb especial èmfasi a les connexions d'un tipus de contingut amb un dataset concret o un altre tipus de contingut. Similarmet al vincle arxivístic, interessa conèixer i tenir les dades relacionades entre tipus de continguts o entre tipus de contingut i dataset, a fi de facilitar la recuperació de la informació⁶³.

3. Representació: és la forma en la que el contingut es visualitza i s'interpreta; més concretament, fa referència als següents aspectes:

- a. Els formats de les dades.

⁶³ Tal com s'esmenta al Portal de dades obertes de la Diputació de Barcelona, el tipus de contingut es defineix a partir d'un nombre arbitrari de camps, grups i relacions. Així mateix, un camp es defineix com els diferents valors que pot tenir un tipus de contingut, i a més posseeixen diferents propietats (multivaluat, tipus, etc.); un grup es concep com un conjunt o agrupació de camps; i les relacions són les connexions que hi ha entre un tipus de contingut amb un dataset concret o un altre tipus de contingut. Finalment, es defineix el dataset com un conjunt de dades d'un tipus de contingut concret, és a dir, és un subconjunt d'un tipus de contingut.

Per a més informació es remet al Portal de dades obertes de la Diputació de Barcelona, en concret, a l'àrea de [documentació tècnica](#).

- b. El significat que se'n deriva de les dades.
- c. L'ús específic de les mateixes.

Aquesta categoria depèn del sistema o domini tecnològic en el que les dades s'utilitzen i també s'associa a les metadades vinculades als datasets (Wang & Strong, 1996).

- 4. Context:** és tota aquella informació que permet comprendre la procedència, l'entorn i la xarxa de relacions on les dades han sigut creades/capturades i utilitzades (Cruz Mundet, 2011 i 2012). Aquesta última categoria s'avalua a partir de les metadades associades als datasets.
- 5. Comportament:** fa referència a les funcionalitats inherents dels conjunts de dades obertes, n'és un exemple l'establiment d'hipervincles (Wilson, 2007).

Finalment convé especificar que hi ha categories de la **Taula 6** que no s'han incorporat ja que s'han integrat dins d'altres, una bona mostra són l'accessibilitat i la privacitat les quals s'han agregat dins la categoria representació, que engloba tant la presentació de les dades com aspectes relacionats amb l'ús de

les mateixes. Altres, com per exemple el compromís, la millora, els agents o les accions, no s'han tingut en compte degut a que no es conceben com a grups que inclouen dimensions i elements ODQ. En aquest sentit, el compromís i la millora serien aspectes vinculats a la gestió de les dades, mentre que els agents i les accions serien les entitats (agents) i els atributs i valors (accions) que expressen les dades⁶⁴.

2. 2. 2. Dimensions i elements de la qualitat de les dades obertes

En aquest apartat s'identifiquen i defineixen el tercer i quart nivell del model de qualitat de les dades obertes. Per a la seva particularització s'ha tingut en compte la revisió de la literatura sobre qualitat de les dades (*vid.* **Taula 8**) però també les propietats que es demana a un document per a que sigui fidedigne: l'autenticitat, la fiabilitat, la integritat i la usabilitat (UNE-ISO 15489-1:2016 i UNE-ISO 30300:2021). En aquest sentit, el treball parteix de la consideració ja plantejada per Laura Millar (2021) de que la professió ha de centrar-se en l'evidència, entesa com a qualsevol font d'informació que mostra una prova fefaent; i particularment, és important focalitzar-se en el valor evidencial i no tant en l'objecte. Raó per

⁶⁴ Segons Rafael Camps (2013), el terme entitat es correspondria amb el terme subjecte del camp de la lingüística, és a dir, es tractaria d'un objecte identificable. En canvi, els camps atribut i valor serien el predicat, concretament el camp atribut es correspondria amb el verb i el valor amb el complement. Aquests tres camps configuren els components de tota informació tal com es mostra al següent exemple: aquesta alumna (entitat) va néixer (atribut) al 1987 (valor).

L'autor indica que aplicant conceptes bàsics de la teoria de conjunts es pot definir l'atribut (A) com l'aplicació del conjunt d'entitats individuals (E) sobre un conjunt de valors (V):

$$E \rightarrow V$$

Per últim convé senyalar que una entitat pot ser multiatribut, és a dir, tenir més d'un atribut i un valor per cada atribut.

la qual es considera que les dades, en tant que evidències, també han de complir amb les propietats abans esmentades.

Tal com s'ha vist a l'apartat 1.4.3, una de les problemàtiques que s'ha trobat durant la revisió de la bibliografia sobre DQ és l'ús de termes diferents amb un significat similar, per la qual cosa ha sigut necessari realitzar prèviament a

la identificació una comparativa entre termes i definicions a fi d'agrupar-los en una mateixa dimensió i, a la vegada, efectuar un exercici de traducció d'aquests vocables al català, donat que majoritàriament la literatura consultada en aquest àmbit està en anglès. Tal com es mostra a continuació, a la **Taula 7** es materialitza aquesta comparativa i equiparació de termes:

Dimensió traduïda al català	Dimensió original en anglès
Exactitud	<i>Accuracy</i>
Completesa	<i>Completeness</i>
Consistència	<i>Consistency; Representational consistency; Coherence</i>
Credibilitat	<i>Credibility</i>
Pertinència temporal	<i>Timeliness</i>
Fiabilitat/Confiabilitat	<i>Believability; Reliability, Trusted; Trust</i>
Correctesa/Lliure d'error	<i>Correctness; Free-of-error</i>
Usabilitat	<i>Usefulness; Operability</i>
Validesa	<i>Validity</i>
Definició/Documentació	<i>Data Specification; Definition/ Documentation</i>

Dimensió traduïda al català	Dimensió original en anglès
Accessibilitat	<i>Accessibility</i>
Conformitat	<i>Compliance; Conformance/ Validity</i>
Qualitat de presentació	<i>Presentation Quality</i>
Eficiència	<i>Efficiency</i>
Actualitat	<i>Currentness; Currency; Actuality; Punctuality</i>
Precisió	<i>Precision</i>
Traçabilitat	<i>Traceability; Traceability/ Lineage;</i>
Comprensibilitat	<i>Understandability; Understood; Ease of understanding</i>
Disponibilitat	<i>Availability</i>
Portabilitat	<i>Portability</i>

Dimensió traduïda al català	Dimensió original en anglès
Recuperabilitat	<i>Recoverability</i>
Obertura	<i>[Només es menciona a la Iniciativa APORTA]</i>
Objectivitat	<i>Objectivity</i>
Reputació	<i>Reputation</i>
Valor afegit	<i>Value-added</i>
Rellevància	<i>Relevance</i>
Volum/Quantitat	<i>Appropriate amount of data/information</i>
Llegibilitat/ Interpretabilitat	<i>Interpretability; Legibility; Readability; Data interpretability; Processability; Clarity</i>
Seguretat/Privacitat	<i>Security; Access security; Privacy; Confidentiality</i>
Autorització/Llicència	<i>Authorization</i>
Integritat	<i>Integrity; Referential integrity</i>
Auditable/Verificable	<i>Auditability</i>
Adequació	<i>Fitness</i>
Estructura	<i>Structure</i>

Dimensió traduïda al català	Dimensió original en anglès
Metadades	<i>Metadata evolution; MetaData</i>
Reutilització	<i>[Només es menciona a la Iniciativa APORTA]</i>
Volatilitat	<i>Volatility</i>
Fidedigne	<i>Trustworthiness</i>
Concisió	<i>Conciseness; Concise representation</i>
Unicitat	<i>Uniqueness</i>
Duplicació	<i>Duplication</i>
Cardinalitat	<i>Cardinality</i>
Cobertura de dades	<i>Data coverage</i>
Facilitat manipulació	<i>Ease of manipulation</i>
Granularitat	<i>Granularity</i>
Redundància	<i>Redundancy; Minimality</i>
Raonabilitat	<i>Reasonableness</i>
Receptivitat/Grau resposta	<i>Responsiveness</i>
Existència	<i>Existence</i>
Comparabilitat	<i>Comparability</i>

Taula 7. Equiparació de dimensions de qualitat de l'anglès al català (Font: Elaboració pròpia, 2021)

Per a la identificació de les dimensions i elements que conformen el tercer i quart nivell del model de qualitat de les dades obertes, ha sigut necessari realitzar un estudi de les investigacions i estàndards consultats que es materialitza a la

Taula 8, en la qual s'han identificat un total de 50 dimensions de qualitat. Per a cada una d'aquestes dimensions s'ha indicat a quines investigacions apareixen, el que permet discernir el nombre de vegades que són citades en un estudi DQ.

Dimensions/ Elements de qualitat	Literatura analitzada en relació amb la qualitat de les dades (<i>data quality research</i>)																
	ISO/IEC 25012: 2018	Wand & Wang (1996)	Wang & Strong (1996)	Strong, Lee & Wang (1997)	Jarke, Jeusfeld, Quix & Vassilia dis (1999)	Pipino, Lee & Wang (2002)	Kahn, Strong & Wang (2002)	Olson (2003)	Bovee, Srivastava & Mak (2003)	Kulikowski (2005)	DAMA Internati- onal (2009)	Open Data Support (2014)	Cai & Zhu (2015)	Batini & Scannapi- eco (2016)	APORTA (2017)	Eurostat (2017)	Mahanti (2018, 2019)
Exactitud (15)	X	X	X	X	X		X	X	X		X	X	X	X	X	X	X
Completesa (15)	X	X	X	X	X	X	X	X			X	X	X	X	X		X
Consistència (15)	X	X	X	X	X	X		X			X	X	X	X	X	X	X
Pertinença temporal (13)		X	X	X	X	X	X				X	X	X			X	X
Accessibilitat (12)	X		X	X	X	X		X					X	X	X	X	X
Llegibilitat/ Interpretabi- lilitat (12)			X	X	X	X		X	X		X	X	X			X	X
Rellevància (11)			X	X		X	X	X	X	X		X	X			X	X
Fiabilitat/ Confiabilitat (10)		X	X	X		X	X	X					X	X		X	X
Actualitat (9)	X	X			X					X	X			X	X	X	X
Seguretat/ Privacitat (8)	X		X	X	X	X					X						X
Comprensi- bilitat (7)	X		X	X		X	X	X							X		
Credibilitat (7)	X				X					X		X	X		X		X
Precisió (6)	X	X								X	X				X		X
Objectivitat (5)			X	X		X	X										X

Dimensions/ Elements de qualitat	Literatura analitzada en relació amb la qualitat de les dades (<i>data quality research</i>)																
	ISO/IEC 25012: 2018	Wand & Wang (1996)	Wang & Strong (1996)	Strong, Lee & Wang (1997)	Jarke, Jeusfeld, Quix & Vassilia dis (1999)	Pipino, Lee & Wang (2002)	Kahn, Strong & Wang (2002)	Olson (2003)	Bovee, Srivastava & Mak (2003)	Kulikowski (2005)	DAMA Internat- ional (2009)	Open Data Support (2014)	Cai & Zhu (2015)	Batini & Scannapi- eco (2016)	APORTA (2017)	Eurostat (2017)	Mahanti (2018, 2019)
Reputació (5)			X	X		X	X										X
Concisió (5)			X	X		X	X										X
Conformitat (4)	X											X			X		X
Valor afegit (4)			X	X		X	X										
Volum/ Quantitat (4)			X	X		X	X										
Correctesa/ Lliure d'error (4)						X	X	X									X
Disponibili- tat (4)	X					X						X	X				
Usabilitat (4)						X				X			X	X			
Integritat (4)											X		X				X
Volatilitat (4)						X				X				X			X
Traçabilitat (3)	X					X											X
Facilitat manipulació (3)							X	X									X
Redundància (3)						X									X		X
Definició/ Documenta- ció (2)													X				X
Metadades (2)						X							X				
Unicitat (2)											X						X
Reutilització (1)															X		

Dimensions/ Elements de qualitat	Literatura analitzada en relació amb la qualitat de les dades (<i>data quality research</i>)																
	ISO/IEC 25012: 2018	Wand & Wang (1996)	Wang & Strong (1996)	Strong, Lee & Wang (1997)	Jarke, Jeusfeld, Quix & Vassilia dis (1999)	Pipino, Lee & Wang (2002)	Kahn, Strong & Wang (2002)	Olson (2003)	Bovee, Srivastava & Mak (2003)	Kulikowski (2005)	DAMA Internat- ional (2009)	Open Data Support (2014)	Cai & Zhu (2015)	Batini & Scannapi- eco (2016)	APORTA (2017)	Eurostat (2017)	Mahanti (2018, 2019)
Eficiència (1)	X																
Portabilitat (1)	X																
Recuperabili- tat (1)	X																
Obertura (1)															X		
Auditable/ Verificable (1)													X				
Adequació (1)													X				
Estructura (1)													X				
Fidedigne (1)																	X
Validesa (1)											X						
Duplicació (1)																	X
Cardinalitat (1)																	X
Cobertura de dades (1)																	X
Granularitat (1)																	X
Raonabilitat (1)											X						
Receptivitat/ Grau resposta (1)					X												
Existència (1)									X								
Comparabili- tat (1)															X		
Qualitat de presentació (1)													X				
Autorització/ Llicència (1)													X				

Taula 8. Comparativa de la literatura analitzada en relació amb les dimensions de qualitat de les dades (Font: Elaboració pròpia, 2021).

Abans d'analitzar els resultats de la taula anterior convé fer-ne les següents consideracions:

- La gran majoria d'investigacions, excepte els estudis de Bovee, Srivastava & Mak (2003)⁶⁵ i Cai & Zhu (2015), no diferencien entre dimensions i elements DQ, per la qual cosa a la pràctica les propietats identificades s'assemblarien als elements DQ dels quals deriven els indicadors per avaluar la qualitat de les dades.
- Les caselles marcades amb **X** representen les dimensions de qualitat en aquells estudis que sí distingeixen entre dimensions i elements DQ.
- Les caselles marcades amb **X** representen aquells elements de qualitat que es citen en estudis específics sobre qualitat de dades obertes. En el marc del present projecte, aquests estudis tenen més pes alhora d'identificar elements DQ per al model proposat.
- Les caselles marcades amb **X** representen aquells elements DQ que es citen en la bibliografia sobre qualitat de les dades.
- Les caselles marcades amb **X** representen aquells elements DQ que es citen en la norma ISO/IEC 25012:2008. En el marc del present projecte, els elements DQ

identificats a l'estàndard internacional tenen més pes alhora de construir el model de qualitat de les dades obertes, a fi de complir amb les normes ISO de referència.

Vistes aquestes observacions, primer s'identifiquen les dimensions de qualitat de les dades obertes que són les que conformen el tercer nivell del model. Per a la seva distinció s'ha tingut en consideració dos aspectes: d'una banda, les quatre propietats que s'identifiquen a les normes UNE-ISO 15489-1:2016 i UNE-ISO 30300:2021 ja que són aspectes rellevants per assegurar la qualitat de les dades obertes. I d'altra banda, les dimensions DQ que es troben marcades amb **X** a la **Taula 8**. En concret, les dimensions DQ que apareixen als estàndards i a les investigacions revisades són les següents:

Estàndards internacionals (ISO 15489 i ISO 30300)	
Autenticitat	Integritat
Fiabilitat	Usabilitat

Taula 9. Dimensions que es citen en les normes ISO 15489 i 30300 (Font: Elaboració pròpia, 2021).

⁶⁵ En l'estudi de Bovee, Srivastava & Mak (2003) les dimensions DQ reben el nom d'atributs DQ i els elements DQ s'anomenen subatributs DQ.

Estudis de Bovee, Srivastava & Mak (2003) i Cai & Zhu (2015)

Disponibilitat	Accessibilitat
Fiabilitat / Confiabilitat	Llegibilitat / Interpretabilitat
Integritat	Rellevància
Usabilitat	Qualitat de presentació

Taula 10. Dimensions que es citen en els estudis de Bovee, Srivastava & Mak (2003) i Cai & Zhu (2015) (Font: Elaboració pròpia, 2021).

En total hi ha nou dimensions ODQ de les quals s'han seleccionat cinc (autenticitat, fiabilitat, integritat, usabilitat i disponibilitat). Els motius que han portat a aquesta selecció són els següents: primerament, s'ha donat més pes a les propietats que s'identifiquen als estàndards citats; segonament, la fiabilitat, la integritat i la usabilitat també són anomenades en algun dels dos estudis esmentats i, en tercer lloc, s'ha incorporat la disponibilitat ja que aquesta dimensió es relaciona amb l'accés i reutilització de les dades obertes. Altrament, no s'han integrat les dimensions d'accessibilitat, llegibilitat/interpretabilitat i rellevància perquè es conceben com a propietats de quart nivell (elements ODQ) que s'engloben dins dimensions específiques. I pel que fa a la qualitat de presentació convé recordar que en aquest model la presentació (o representació) és una categoria de la qualitat i, per tant, es situa en el segon nivell. A continuació es defineixen les cinc

dimensions que conformen el tercer nivell del model de qualitat de les dades obertes:

1. **Autenticitat:** és la propietat de les dades que pot provar que són el que pretenen ser, que han sigut creades o enviades per l'agent del que s'afirma que les ha creades o enviades, i que han sigut creades o enviades en el moment en el qual s'afirma. Per assegurar l'autenticitat és important la implementació i documentació de regles, processos, polítiques i procediments que controlen la creació, la captura i la gestió de les dades; així mateix, també haurien d'estar identificats els creadors de les mateixes (UNE-ISO 15489-1:2016; UNE-ISO 30300:2021).
2. **Fiabilitat:** és la propietat que permet demostrar que les dades són completes i precises. Així doncs, les dades són confiables perquè el seu contingut és complet, exacte i són una fidel representació de les operacions, activitats o fets que registra. Altrament són fiables quan es pot dependre d'aquestes en el transcurs de les subsegüents operacions o activitats (UNE-ISO 15489-1:2016; UNE-ISO 30300:2021).
3. **Integritat:** és la propietat que permet demostrar que les dades estan completes i inalterades. Les dades, en tant que evidències, haurien d'estar protegides contra la modificació no autoritzada; a més, qualsevol modificació (adició, supressió, etc.) que es realitzés sobre les bases

de dades hauria d'indicar-se de forma explícita i deixar traça (UNE-ISO 15489-1:2016; UNE-ISO 30300:2021).

4. **Usabilitat:** és la propietat de les dades que permet la seva localització, recuperació, presentació i comprensió per les parts interessades. Els conjunts de dades haurien d'estar lligats als processos i operacions que els ha produït i, a més, s'haurien de mantenir els vincles amb altres tipus de continguts i datasets. Finalment, la usabilitat es garanteix mitjançant l'ús de metadades, les quals proporcionen la informació necessària per a la recuperació i presentació de les mateixes, tal com identificadors, formats o informació d'emmagatzement (UNE-ISO 15489-1:2016; UNE-ISO 30300:2021).
5. **Disponibilitat:** és la propietat que garanteix l'accés i ús de les dades per les parts interessades. Seguint la definició que apareix al Diccionario de la Real Academia Española (2020), el terme disponibilitat és la condició de disponible i, a la vegada, l'adjectiu disponible es concep de la següent manera: *«dicho de una cosa: Que se puede disponer libremente de ella o que está lista para usarse o utilizarse»*; raó per la qual, aquesta propietat centra l'atenció en els sistemes d'accés a les dades, en l'ús de les mateixes dins l'ecosistema de dades obertes i en el nivell d'obertura per a facilitar la seva reutilització i redistribució.

Pel que fa a la configuració del quart nivell del model, que és el corresponent als elements ODQ, s'han tingut en

consideració els següents aspectes: primerament, els elements de qualitat marcats amb una **X** a la **Taula 8** i que no formen part del tercer nivell; segonament els elements enumerats a la ISO/IEC 25012:2008 i que es troben marcats amb una **X**; tercerament les propietats més citades en la literatura revisada, concretament, d'una mostra de 17 estudis s'han comptat aquelles propietats que han sigut mencionades com a mínim 8 vegades. D'aquestes consideracions resulta un total de 20 elements ODQ.

Tanmateix, a aquest total inicial s'afegeixen sis elements més: en primer lloc, s'inclouen tres propietats identificades a la UNE 178301:2015. Segons aquesta norma, la dimensió qualitat de dades està conformada per dades primàries, dades completes, dades documentades, dades tècnicament correctes, dades georeferenciades i dades enllaçades. D'aquests elements, s'agreguen la definició/documentació, la georeferenciació i la primigènia, de les quals les dues últimes no es troben a la **Taula 8**. Per contra, no s'incorpora la completesa ja que està inclosa en el total inicial; ni les dades enllaçades atès que estan incloses dins la propietat obertura i aquesta es troba a la mostra inicial; ni tampoc la correctesa ja que és un element que coincideix amb l'exactitud semàntica i aquesta ja està en el total inicial. En segon lloc, s'incorpora la propietat localització que és un dels quatre principis FAIR (*findable, accessible, interoperable, reusable*) de les dades obertes de recerca. Tot i que aquests principis s'adrecen a les dades científiques, considerem que poden ser aplicables també

a les dades obertes del sector públic. Aquest element ODQ no es troba a la **Taula 8**; mentre que els altres principis restants (*accessible, interoperable, reusable*) ja es troben incorporats en la mostra inicial: l'accessibilitat, la llegibilitat/interpretabilitat i la comparabilitat (dins d'aquests elements s'inclou la interoperabilitat) i la reutilització. Finalment, de la **Taula 8** s'addicionen la granularitat ja que es considera que és un element rellevant dins la característica estructura (segon nivell), i a més és un dels aspectes que s'inclou en el principi 2 de la G8 Open Data Charter; i en darrer terme la volatilitat degut a que és una propietat important relacionada amb el temps, que convé tenir-la en consideració ja que impacta en l'element actualitat.

Així doncs, el sumatori final ascendeix a 26 elements ODQ que són els que a continuació s'enumeren:

Elements ODQ del Model de qualitat de les dades obertes	
Exactitud	Seguretat/Privacitat
Completesa	Traçabilitat
Consistència	Definició/Documentació
Pertinència temporal	Actualitat
Accessibilitat	Reutilització
Llegibilitat/ Interpretabilitat	Volatilitat

Elements ODQ del Model de qualitat de les dades obertes

Rellevància	Obertura
Comprensibilitat	Eficiència
Conformitat	Portabilitat
Credibilitat	Recuperabilitat
Precisió	Comparabilitat
Primigènia	Localització
Georeferenciació	Granularitat

Taula 11. Elements ODQ del Model de qualitat de les dades obertes (Font: Elaboració pròpia, 2021).

Aquests elements de qualitat s'han relacionat amb les cinc dimensions ODQ identificades anteriorment. Tot seguit, es presenta la relació entre el tercer i quart nivell del model de la qualitat de les dades obertes, així com la descripció de cada un dels elements mencionats, la definició dels quals procedeix de les investigacions consultades, tot i que algunes d'aquestes descripcions s'han modificat i adaptat en aquest model que es presenta:

1. Dimensió Autenticitat (inclou 4 elements ODQ):

- a. Definició/Documentació.** Aquest element consisteix en l'especificació de les dades (data specification), que inclou el nom de les dades, la definició, els intervals de valors vàlids, els formats estàndard, les regles de negoci, etc. (Cai & Zhu, 2015). És a dir, comprèn la documentació de les especificacions de les dades el que aporta coherència i claredat, i possibilita l'intercanvi d'informació a partir de l'estandardització de formats i de dades.

Seguint la norma UNE 178301:2015, aquesta propietat avalua si les dades estan documentades ja que en el catàleg de dades ha de publicar-se la documentació de les mateixes. La informació a contemplar comprèn, sense caràcter limitatiu, el significat de la dada, l'estructura (atributs, formats, etc.), i la referència a la dada completa en cas de tractar-se d'abreviatures.

- b. Conformitat.** Aquest element comprèn el grau en què les dades tenen atributs que s'adhereixen a normes, convencions o regulacions vigents i normes similars relatives a la qualitat de les dades en un context d'ús específic (ISO/IEC 25012:2008). S'ha de comprovar la mesura en què segueixen normes, explícites o no, per a la captura, publicació i descripció de les dades.

N'és un exemple la descripció dels conjunts de dades seguint el vocabulari DCAT.

- c. Credibilitat.** Aquest element comprèn el grau en què les dades es basen en fonts fiables o són lliurades per organitzacions de confiança (Open Data Support, 2014). Implica la veracitat dels orígens, de les atribucions i dels compromisos.
- d. Primigènia.** Aquest element comprèn el grau en què les dades publicades són dades primàries, és a dir, han sigut capturades de la font d'origen i publicades sense tractaments previs d'agregació, modificació, resum, etc. (UNE 178301:2015).

2. Dimensió Fiabilitat (inclou 4 elements ODQ):

- a. Exactitud.** Aquest element comprèn el grau en què les dades tenen atributs que representen correctament el valor real dels atributs previstos d'un concepte o esdeveniment en un context d'ús específic (ISO/IEC 25012:2008). És a dir, mesura la similitud entre un valor de dades v i un valor de dades v' , considerat com la correcta representació del fenomen de la vida real que el valor de dades v pretén representar. Per exemple, si el nom d'una persona és Sara, el valor $v' = Sara$ és correcte, mentre que el valor $v = Sra$ és incorrecte (Batini & Scannapieco, 2016).

Aquest element inclou dos aspectes a mesurar: l'exactitud sintàctica i l'exactitud semàntica.

- L'**exactitud sintàctica** (*syntactic accuracy*) és la proximitat d'un valor v a un conjunt de valors definits en un domini D — entès com un codi similar de representació — considerat sintàcticament correcte. En aquest cas, no es compara la similitud del valor v amb el valor real v' . Per exemple, si aquest codi similar de representació o domini D és l'alfabet llatí, el que s'avalua no és que $v = \text{Sara}$ sigui similar a $v' = \text{Júlia}$, sinó que v és sintàcticament correcte dins el Domini D establert (Batini & Scannapieco, 2016).
- Per contra, l'**exactitud semàntica** (*semantic accuracy*) és la proximitat del valor v al valor real v' dins un domini D definit. En aquest cas, sí s'avalua que v sigui el mateix valor que v' . Així doncs, si $v = \text{Sara}$ aleshores $v' = \text{Sara}$ o, en el seu defecte, una descripció precisa com $v' = \text{parella de Júlia}$. Però en cap cas serà Júlia , atès que es tracta de dos persones diferents i s'incorreria en un error d'exactitud semàntica, malgrat que sintàcticament ambdós valors són correctes. Conseqüentment, s'infereix que per a mesurar

l'exactitud sintàctica s'utilitza la funció distància⁶⁶, mentre que per avaluar l'exactitud semàntica és més adequat emprar $\langle \text{sí}, \text{no} \rangle$ o $\langle \text{correcte}, \text{incorrecte} \rangle$. D'això últim es dedueix que l'exactitud semàntica coincideix amb el concepte de correctesa (Batini & Scannapieco, 2016).

- Precisió.** Aquest element comprèn el grau de detall de la dada, per exemple, el nombre de decimals d'un valor. El nivell de detall de les dades depèn del context d'ús i de les regles de negoci, ja que, tornant a l'exemple abans mencionat, no permet les mateixes funcionalitats un grau de precisió de 5 decimals que un de 2 decimals. Així doncs, el grau de detall es troba vinculat a un context específic d'ús i a les necessitats de l'organització (ISO/IEC 25012:2008; Mahanti, 2018).
- Granularitat.** Aquest element comprèn el grau de detall en què es presenta la informació en una base de dades (Neoloteca - TERM CAT, 2021⁶⁷). És a dir, aquesta propietat mesura el nivell de detall en què es descomponen o subdivideixen les dades dins un sistema, sense perdre el significat de la informació. Una bona mostra és l'adreça postal, la qual pot presentar diferents nivells de granularitat: un primer

⁶⁶ La funció distància s'utilitza per expressar la semblança entre dos elements dins un conjunt, que generalment es normalitza entre 0 i 1 (IGI Global, s/d). Es remet a <https://www.igi-global.com/dictionary/distance-function/7998>

⁶⁷ Es remet a <https://www.termcat.cat/es/neoloteca/fitxa/MTI0NDMxOA%3D%3D>

nivell és que tota l'adreça postal es troba emmagatzemada en un únic camp; un segon nivell que representa més granularitat és que l'adreça postal es troba descomposta en diferents camps —direcció, codi postal, població, província—; i finalment el nivell de granularitat més fi és aquell en què es mantenen els camps anteriors, però addicionalment el camp direcció es troba subdividit en tipus de via, número, pis i porta. Consegüentment, en funció del nivell de granularitat en què les dades són capturades i emmagatzemades varien les possibilitats d'agregació, resum i manipulació dels conjunts de dades, ja que un nivell fi de granularitat facilita i maximitza les funcionalitats de les mateixes (Mahanti, 2018).

d. Rellevància. Aquest element mesura el grau en què el contingut i l'abast de les dades són pertinents per a satisfer la finalitat per a la qual s'utilitzen, i a més consideren les possibles necessitats futures (Mahanti, 2018). Al respecte, és important considerar dos aspectes: d'una banda, si l'abast de les dades és apropiat per a la consecució de la seva finalitat, i d'altra banda si les dades tenen el nivell de detall suficient per a satisfer els usos actuals i futurs. Tal com senyala Mahanti (2018), la rellevància és un element important ja que si les dades no són pertinents, el seu valor disminueix, malgrat les dades siguin exactes, precises, actuals, etc.

3. Dimensió Integritat (inclou 3 elements ODQ):

a. Traçabilitat. Aquest element mesura el grau en què es pot verificar l'origen, la captura, el moviment, l'ús i eventuais modificacions de les dades dins d'un sistema. La seva verificació es realitza a partir de les metadades, ja que capturen la informació relacionada amb l'origen, l'historial, la data i el temps de la dada (tant l'inicial com les de successives actualitzacions). Així mateix, en el cas de transferència de dades entre sistemes és important que hi hagi una metadada que capturi l'origen, el nom del sistema immediatament anterior, la data de captura i transferència, entre altres aspectes, a fi de rastrejar els sistemes pels quals han passat les dades fins arribar a la seva font d'origen. Convé subratllar que sense aquesta possibilitat de rastreig o seguiment es fa difícil diagnosticar problemes de qualitat de les dades (Mahanti, 2018).

Així doncs, i similarment al que succeeix amb els documents electrònics, la traçabilitat és una propietat que facilita el seguiment de la creació, incorporació, moviment, ús i eventual modificació de les dades dins un sistema de gestió concret.

b. Completesa. Aquest element mesura si les dades estan presents o no, que en el cas de bases de dades relacionals es tradueix en què els

campus de la taula no contenen valors en blanc o valors nuls (*NULL*) (Mahanti, 2018). A fi de caracteritzar la completesa és important conèixer el motiu pel qual el valor no hi és, ja que no totes les absències són motiu d'incompletesa. Davant una absència hi ha cinc possibles escenaris:

- **Escenari 1:** el valor existeix però no es coneix (Batini & Scannapieco, 2016; Mahanti, 2018). Per exemple, en el cas hipotètic d'una base de dades amb la relació d'estudiants de primer any d'un grau concret trobem que per a l'estudiant 1 el camp telèfon fix té un valor nul. Si aquesta absència és degut a que el valor no és coneix, però sí existeix ja que l'estudiant té telèfon fix, ens trobem davant un escenari d'incompletesa.
- **Escenari 2:** el valor no existeix (Batini & Scannapieco, 2016; Mahanti, 2018). En el mateix exemple anterior, l'estudiant 4 també té un valor nul en el camp telèfon fix, però en aquest cas és degut a que l'estudiant no disposa de telèfon fix, per la qual cosa aquest supòsit no representa un escenari d'incompletesa ja que el valor no existeix.
- **Escenari 3:** es desconeix si el valor existeix o no (Batini & Scannapieco, 2016; Mahanti, 2018).
- **Escenari 4:** l'atribut no és aplicable (Mahanti, 2018). Per exemple, en una base de dades amb la relació de clients trobem que s'informa de l'identificador del client, nom, cognom 1, cognom 2, gènere, etc. En el cas que el client fos una persona jurídica, els atributs cognom 1, cognom 2 i gènere no contindrien cap valor degut a que no són aplicables a organitzacions i empreses, per la qual cosa aquest supòsit no implica incompletesa. No obstant, sí suposaria incompletesa si aquests atributs no continuessin cap valor en el cas de persones físiques.
- **Escenari 5:** el valor només s'informa en condicions específiques (Mahanti, 2018). Una bona mostra la trobem en el Registre censal d'animals de companyia que conté els següents camps: nom propietari, cognom 1 propietari, nom animal, identificador animal, data naixement, adreça, data defunció, etc. En el cas de la data de defunció, aquest valor estaria informat només en cas de que es complís la condició; en dit supòsit si es compleix la

condició i el valor és nul representaria un escenari d'incompletesa.

La completesa és una propietat que es pot mesurar en diferents nivells de granularitat, particularment hi ha quatre tipus de completesa en funció del nivell de mesura (Batini & Scannapieco, 2016):

- **Completesa del valor:** captura la presència de valors nuls per alguns camps d'una tupla de dades.
- **Completesa de la tupla o registre:** mesura la completesa d'una tupla en relació als valors de tots els seus camps. En concret, s'avalua el percentatge de valors especificats en una tupla en relació amb el número total d'atributs del propi registre.
- **Completesa de l'atribut o columna:** mesura el nombre de valors nuls d'un atribut concret. És a dir, s'avalua el percentatge de valors informats a la columna corresponent a l'atribut (per exemple, l'atribut data de naixement) respecte al nombre total de valors que s'haurien d'haver especificat.

- **Completesa de la relació:** captura la presència de valors nuls en una relació. En concret, mesura la quantitat de dades informades en la relació (per exemple, la relació estudiant) pel que fa al màxim contingut possible que es pot representar.

c. **Consistència.** Aquest element mesura que les dades no contenen contradiccions i que són coherents amb altres dades en un context d'ús específic (ISO/IEC 25012:2008; Open Data Support, 2014). Dit d'una altra manera, aquesta propietat captura les transgressions de les regles semàntiques definides en un conjunt d'elements de dades. En el cas del model relacional, hi ha el concepte de restricció d'integritat⁶⁸ entès com la instanciació de les regles semàntiques, és a dir, es tracta del procés mitjançant el qual s'especifica la informació. Existeixen dos tipus de restriccions d'integritat (Batini & Scannapieco, 2016):

- D'una banda, les **restriccions intrarelacionals** que són aquelles que afecten a un atribut (també denominat restriccions de domini⁶⁹) o

68 Les restriccions d'integritat proporcionen un mitjà per assegurar que les modificacions fetes a les bases de dades per part d'usuaris autoritzats no provoquen la pèrdua de la consistència de les dades. Així doncs, les restriccions d'integritat protegeixen la base de dades contra danys accidentals (Silberschatz, Korth & Sudarshan, 2002, 141).

69 El domini de l'atribut és el conjunt de tots els valors vàlids, o legals, que pot arribar a tenir un atribut (Camps, 2013). Per tant, el concepte de restriccions de domini englobaria totes aquelles limitacions que afecten als valors vàlids d'un atribut.

a múltiples atributs d'una relació o classe. Per a il·lustrar-ho considerem que per a la classe Alumnat hi haurien els atributs nom, cognom 1, cognom 2, DNI, NIA, tipus estudi, estudi, codi estudi, centre, règim i any accés. Un exemple de restriccions de domini en una classe concreta és “El NIA està format per 7 caràcters numèrics”; mentre que un exemple de restriccions d'integritat sobre múltiples atributs és “Si el centre és Escola Superior d'Arxivística i Gestió de Documents, aleshores el tipus estudi és Màster, Postgrau, Especialització o Doctorat”.

- I d'altra banda, les **restriccions interrelacionals** afecten als atributs de més d'una relació o classe. Per a visualitzar-ho considerem la classe Alumnat vista anteriorment i també la classe Ensenyament on hi consta la relació de tots els ensenyaments de la universitat, i els atributs que s'especifiquen són tipus estudi, estudi, codi estudi, especialització, branca i centre. Un exemple d'aquest tipus de restricció és “El codi estudi de la classe Alumnat és igual al codi estudi de la classe Ensenyament”.

Finalment, convé destacar que la inclusió de regles semàntiques i de restriccions d'integritat permeten que els valors d'una taula siguin coherents i equivalents als valors i significats d'una altra⁷⁰ —ja sigui a nivell intraorganitzacional i/o interorganitzacional—, degut a l'aplicació d'estàndards prèviament definits.

4. Dimensió Usabilitat (inclou 8 elements ODQ):

- Llegibilitat/Interpretabilitat.** Aquest element comprèn el nivell de processament de les dades, és a dir, mesura el grau de comprensió i gestió de les dades mitjançant processos automatitzats (Open Data Support, 2014). A fi de possibilitar la interpretabilitat de les dades s'avaluen, sense caràcter limitatiu, els següents aspectes: primerament si els conjunts de dades contenen informació codificada basada en vocabularis controlats i llistes de codis; segonament si la representació de dates i temps segueixen estàndards com la norma ISO 8601; tercerament si les dades s'acompanyen de metadades adequades; i en darrer terme si els conjunts de dades estan estructurats en formats processables per

⁷⁰ Aquesta condició es denomina integritat referencial (Silberschatz, Korth & Sudarshan, 2002, 142).

màquina⁷¹, tal com l'XML o el CSV (Open Data Support, 2014; Eurostat, 2017). Per tant, la capacitat d'interpretar correctament el contingut de les dades depèn de l'ús d'estàndards, abreviatures, termes formals, codis, etc., coneguts i ben definits (Kulikowski, 2005).

L'ús de metadades per a descriure els recursos d'informació del sector públic és obligatori, tal com s'indica a l'apartat V.1 de la NTI-RISP. En aquesta mateixa NTI s'expliciten quines són les metadades mínimes obligatòries, concretament a l'annex III de la citada norma. A més de les instruccions relacionades amb metadades, la NTI-RISP inclou les següents directrius: l'esque-

ma d'URIs per a les dades publicades (annex II), la taxonomia dels sectors primaris a fi de classificar la informació en una mateixa categoria (annex IV); la relació d'URIs corresponents als recursos geogràfics d'Espanya (annex V); i un model de plantilla per a la descripció en RDF/XML i N3⁷² dels recursos d'informació publicats (annex VI).

És important destacar que la descripció de la informació reutilitzable es basa en el Vocabulari de Catàleg de Dades (*Data Catalog Vocabulari*, DCAT), desenvolupat pel *World Wide Web Consortium* (W3C)⁷³, que és un vocabulari RDF creat per a la descripció de catàlegs de dades basat en tres conceptes clau (APORTA, 2018):

71 A l'article 2 de la Directiva (UE) 2019/1024 del Parlament Europeu i del Consell de 20 de juny de 2019, relativa a les dades obertes i la reutilització de la informació del sector públic, es defineix el format llegible per màquina com un «*formato de archivo estructurado que permita a las aplicaciones informáticas identificar, reconocer y extraer con facilidad datos específicos, incluidas las declaraciones fácticas y su estructura interna.*»

72 La Infraestructura de Descripció de Recursos (*Resource Description Framework*, RDF) és un model de dades que serveix per a proporcionar informació descriptiva dels recursos d'informació que es troben en la Web. Aquest model, que possibilita l'intercanvi de la informació i la seva reutilització, es basa en la idea de que els recursos (subjecte) que es volen descriure tenen certes propietats o atributs (predicat) i que aquestes, a la seva vegada, tenen valors (objecte). Aquesta conceptualització, denominada tripleta, es presenta de manera gràfica de la següent forma:



Altrament, l'objectiu principal de RDF és facilitar l'intercanvi d'informació entre màquines, raó per la qual el model desenvolupa un sistema d'identificadors únics utilitzant Identificadors Uniformes de Recursos (URIs) que permet representar les relacions i identificar qualsevol tipus de recurs, sigui o no accessible a través de la Web. Finalment, a fi d'acomplir amb l'objectiu del RDF és important l'ús d'un llenguatge que permeti el processament de forma automàtica i la representació de les relacions. En aquest sentit, RDF és un model no un format, motiu pel qual la representació es realitza mitjançant llenguatges tal com XML, N3, Turtle, etc., sent la notació més emprada la serialització RDF/XML (Govern Basc, 2010).

73 El *World Wide Web Consortium* (W3C) és una comunitat internacional —liderada per l'inventor de la Web, Tim Berners-Lee— on les organitzacions membre, el personal a temps complet i el públic en general treballen conjuntament per al desenvolupament d'estàndards web, d'entre aquests estàndards està el Vocabulari DCAT. L'objectiu principal del W3C és guiar la Web cap al seu màxim potencial a partir de l'elaboració de pautes i protocols que assegurin el creixement de la Web a llarg termini (W3C, s.d). Per a més informació es remet a la seva pàgina web: <https://www.w3c.es/>

- Catàleg: representa una col·lecció de conjunts de dades.
- Conjunt de dades (dataset): representa un conjunt de dades publicat com a part d'un catàleg.
- Distribució: representa una forma concreta d'accedir a un dataset específic.

La utilització del Vocabulari DCAT facilita la llegibilitat de la informació i fomenta la interoperabilitat semàntica entre els catàlegs de dades publicats per diferents fonts. Així mateix, aquest estàndard estableix la possibilitat d'ampliar mitjançant perfils DCAT, que són especificacions personalitzades per afegir restriccions a les ja establertes pel vocabulari, com per exemple requerir un conjunt mínim de metadades, definir els valors acceptats, nivell d'obligatorietat, etc. Sobre aquest vocabulari, la Comissió Europea ha desenvolupat el perfil d'aplicació de DCAT per a portals de dades europeus (DCAT-AP) que té com a finalitat estandarditzar les descripcions dels catàlegs i datasets dels portals de dades europeus del sector públic (APORTA, 2018).

En l'àmbit català, la Generalitat de Catalunya ha desenvolupat i publicat al novembre de 2020 una guia tècnica en la qual s'estableixen criteris i

un vocabulari de metadades, a fi de que els organismes de Catalunya segueixin uns estàndards homogenis pel que fa a la publicació dels seus datasets en el Portal de dades obertes de la Generalitat de Catalunya.

En darrer terme, cal remarcar que l'anàlisi de les metadades esdevé un aspecte important per avaluar, entre altres consideracions, el grau de llegibilitat/interpretabilitat dels conjunts de dades. En aquest sentit, la interpretabilitat de les dades es relaciona amb el desenvolupament i ús de vocabularis controlats, d'estàndards i de criteris homogenis coneguts i adoptats per totes les parts; o dit d'una altra forma, la interoperabilitat semàntica afavoreix la interpretabilitat i la compartició de dades entre organitzacions, i entre aquestes i les persones usuàries.

Per a més informació, es remet a l'apartat 2.3 on es defineix què és la interoperabilitat semàntica i es detallen les metadades a informar, així com el nivell d'obligatorietat i aplicabilitat de les mateixes, segons el Vocabulari DCAT de la NTI-RISP i el Vocabulari estàndard de la Generalitat de Catalunya.

- b. Comprensibilitat.** Aquest element comprèn el grau en què les dades tenen atributs que poden ser llegits i interpretats pels usuaris i s'expressen

en llenguatges, símbols i unitats adequats en un context d'ús específic. És important ressaltar que les metadades proporcionen informació sobre la comprensió de les dades (ISO/IEC 25012:2008).

c. Georeferenciació. Aquest element se centra fonamentalment en les dades geogràfiques i se centra en la seva associació a una georeferenciació basada en coordenades. Hi ha dos tipus de vinculació: d'una banda, l'associació explícita que és aquella en que les dades estan georeferenciades directament mitjançant coordenades en un Sistema de Referència de Coordenades (SRC); i d'altra banda, l'associació implícita que és quan s'utilitza una georeferenciació indirecta basada en un sistema de referència que es fonamenta en dades geogràfiques ben definides, com carrer, número, districte postal i localitat (UNE 178301:2015).

d. Obertura. Aquest element mesura el grau d'obertura de les dades, ja que per a que els conjunts de dades siguin realment oberts no és suficient únicament amb la seva publicació. En concret, s'avaluen els següents aspectes (en 5stardata⁷⁴):

- Ús de formats processables per màquina. D'aquest element s'infereix si les dades són estructurades o no ho són.
- Ús de formats propietaris/no propietaris.
- Ús de llicències obertes.
- Ús d'Identificadors Uniformes de Recursos (URIs).
- Ús de dades enllaçades i integrades a la Web.

Consegüentment, a partir de la valoració dels ítems anteriors resulta el nivell d'obertura dels conjunts de dades publicats.

e. Recuperabilitat. Aquest element comprèn el grau en què les dades tenen atributs que permeten mantenir i preservar un nivell d'operacions i qualitat especificat, fins i tot en cas de fallada, en un context d'ús específic. És a dir, aquesta propietat, que és dependent del sistema, avalua l'existència de mesures que permeten la recuperació de les dades en cas d'error del sistema, tal com mecanismes de restabliment de les còpies de

⁷⁴ Per a més informació es remet a <https://5stardata.info/es/>

seguretat, sincronització o retrocés (capacitat de tolerància a fallades) (ISO/IEC 25012:2008).

- f. Localització.** A l'àmbit de les dades obertes de recerca (*open data science*) es parla dels principis FAIR (*Findable, Accessible, Interoperable, Reusable*) que proporcionen una guia de bones pràctiques per als productors i editors de les dades científiques (Wilkinson *et al.*, 2016). Malgrat que aquests principis rectoros s'adrecen a la publicació de les dades de recerca a fi de que siguin fàcils de localitzar, accessibles, interoperables i reutilitzables, considerem que la seva aplicabilitat és extensible a la publicació de dades obertes del sector públic. A partir d'aquestes consideracions, l'element localització avalua si les dades i metadades poden ser fàcilment trobades després de la seva publicació, mitjançant eines de recerca. A fi de mesurar el grau de localització es tenen en compte diferents aspectes, tal com si les dades disposen d'Identificadors Uniformes de Recursos (URIs) o si la descripció dels recursos d'informació mitjançant metadades i llenguatges controlats permet la seva indexació i localització en la Web.
- g. Eficiència.** Per eficiència s'entén la relació entre el resultat obtingut i els recursos emprats (ISO 9000:2015). Així doncs, amb aquest element es

mesura el grau en què les dades tenen atributs que poden ser processats i proporcionar nivells esperats de rendiment mitjançant l'ús de quantitats i tipus de recursos adequats en un context d'ús específic.

D'una banda, aquesta propietat es relaciona amb el processament i la gestió de les dades i, d'altra banda, es troba vinculada a la sostenibilitat ecològica i la necessitat de l'avaluació arxivística dels recursos d'informació. En aquest sentit, a curt i mitjà termini es preveu que no es conservarà tot el que es generi digitalment, ja sigui degut a limitacions en la potència informàtica, la capacitat d'emmagatzematge, els recursos de gestió o la salvaguarda de drets fonamentals com la protecció de dades personals (Yeo, 2020). En un context caracteritzat pel creixement exponencial de les dades i per un abaratiment dels costos d'emmagatzematge, convé preguntar-se si és factible la conservació de totes les dades que es capturen i generen. Malgrat que la resposta és objecte de discrepàncies, es sosté la tesi defensada per Geoffrey Yeo (2020) de que les pràctiques d'avaluació no desapareixeran, però sí que es modificaran al focalitzar l'atenció en determinar quines evidències s'han de crear que en determinar quines s'han de seleccionar per a la seva preservació. També l'avaluació se centrarà en identificar quines evidències

s'han de transferir des dels sistemes operatius a plataformes d'emmagatzematge a llarg termini o quines precisen de seguretat addicional. Amb tot, el procés d'avaluació es relaciona amb la gestió eficient i sostenible dels recursos d'informació, al determinar des del disseny quines són les dades necessàries a capturar, el que repercuteix en no utilitzar més espai del necessari per emmagatzemar dades i, consegüentment, prevenir pèrdues d'emmagatzematge, memòria i temps.

- h. Comparabilitat.** Aquest element avalua si les dades són fàcils de comparar dins i entre sectors, a través de localitzacions geogràfiques i de referències temporals (Carta Internacional de Dades Obertes, 2015). Per a portar a terme aquesta comparativa és important que els datasets siguin compatibles amb altres, és a dir, que hi hagi una estandardització i contextualització dels conjunts de dades a fi de possibilitar la seva interoperabilitat, i també el seu anàlisi per establir similituds i diferències entre datasets.

5. Dimensió Disponibilitat (inclou 7 elements ODQ):

- a. Pertinència temporal⁷⁵.** Aquest element, que és una de les propietats relacionades amb el

temps, fa referència a què les dades estan disponibles quan s'esperen i es necessiten (Mahanti, 2018). És a dir, aquesta propietat avalua l'actualitat de les dades en relació a la seva funció o l'operació a la que serveixen. Per tant, és possible tenir dades actualitzades que no són útils perquè arriben tard per a un ús específic o, a la inversa, disposar de dades que poden no estar sempre actualitzades, però poden ser útils per a l'ús al que serveixen. Una bona mostra és disposar de dades actualitzades en relació al pla d'estudis i les guies docents de les assignatures del curs, però no són pertinents i oportunes si només estan disponibles després de l'inici de les classes (Batini & Scannapieco, 2016). Així doncs, aquest element reflecteix el temps que transcorre entre l'esdeveniment que registren les dades i la disponibilitat de les mateixes en relació a un context d'ús (Eurostat, 2017; Mahanti, 2018).

Finalment, de les consideracions anteriors s'inferix que la pertinència temporal implica, no només que les dades són actuals, sinó que també són a temps per a un ús específic. Raó per la qual la mesura valora les següents dues variables (Batini & Scannapieco, 2016; Mahanti, 2018):

⁷⁵ Joan Soler (2009, 2013) denomina a aquesta propietat freqüència d'utilització.

- L'actualitat de les dades.
- La disponibilitat de les dades abans del temps d'ús previst.

b. Actualitat⁷⁶. Aquest element, que és una de les propietats relacionades amb el temps, determina el nivell d'actualització d'un conjunt de dades. Concretament, es mesura l'actualitat de les dades en relació amb els esdeveniments que representa. Per a fer-ho, es valoren dos aspectes (DAMA International, 2009; Mahanti, 2018):

- La freqüència d'actualització esperada.
- La data d'actualització de les dades.

Per tant, per a verificar el nivell d'actualització es mesura el desfasament de temps entre la data de publicació de les dades i la data en la que s'haurien d'haver publicat (Eurostat, 2017⁷⁷). És a dir, la propietat avalua les dates de publicació dels conjunts de dades en relació amb la indicació expressa de la data prevista de la propera actualització o del termini màxim d'actualització dels datasets, o en relació

amb les dates establertes per reglament o acordades prèviament. Generalment, aquesta informació es pot extreure de la metadada “data d'actualització” (NTI-RISP) o la metadada “freqüència d'actualització” (Guia tècnica de dades obertes de la Generalitat de Catalunya). Per als datasets que canvien amb una freqüència fixa, per exemple mensualment o anualment, la metadada “freqüència d'actualització” permet calcular el grau d'actualització de les dades. En canvi, per als conjunts de dades la freqüència dels quals sigui variable, una possibilitat és calcular una freqüència de canvi mitjana i realitzar el càlcul en relació amb aquesta mitjana, admetent un marge d'error (Batini & Scannapieco, 2016).

c. Volatilitat. Aquest element, que és una de les propietats relacionades amb el temps, comprèn la freqüència en què les dades varien en un temps determinat (Batini & Scannapieco, 2016). Aquesta propietat no és igual per a tots els atributs, ja que alguns canvien amb més freqüència que altres (Batini & Scannapieco, 2016; Mahanti, 2018). Un exemple d'atribut de baixa volatilitat o amb un grau de volatilitat 0 és la data de naixement d'una persona; en canvi, una bona mostra de dades

⁷⁶ Joan Soler (2009, 2013) denomina a aquesta propietat freqüència d'actualització. Tanmateix, en l'àmbit d'aquest projecte s'ha seguit la denominació utilitzada en la Iniciativa APORTA (2017).

⁷⁷ Eurostat (2017) anomena a aquesta propietat *punctuality*, però com el significat és molt similar al de la propietat *currency*, s'ha decidit emprar-los com a sinònims.

altament volàtils són les dades meteorològiques registrades a totes les estacions de la Xarxa d'Estacions Meteorològiques Automàtiques (XEMA) del Servei Meteorològic de Catalunya, ja que l'interval de validesa d'aquest tipus de dades és molt curt.

Finalment, convé destacar la relació existent entre actualitat i volatilitat ja que l'actualitat tindrà un major impacte per aquelles dades altament volàtils, que per a les dades amb una baixa volatilitat, ja que com més volàtils siguin major freqüència d'actualització (Batini & Scannapieco, 2016; Mahanti, 2018). N'és un exemple les dades relacionades amb incidències viàries en temps real a Catalunya —provenen del Servei Català de Trànsit—, la freqüència d'actualització de les quals és contínua i, per tant, són dades altament volàtils.

d. Accessibilitat. Aquest element comprèn el grau en què les dades són accessibles en un context d'ús específic, i mesura la capacitat de l'usuari d'accedir a les dades des de la seva pròpia cultura, estat físic (en aquest projecte també incloem l'estat cognitiu d'un individu) i tecnologies disponibles (Batini & Scannapieco, 2016), on l'accés a les dades ha de ser independent de la combinació

de sistema operatiu/navegador que utilitzi cada usuari. Cal fer esment específic a les persones amb diversitat funcional les quals, degut a diferències funcionals (intel·lectuals, sensorials, físiques, etc.) necessiten suport tecnològic o algun tipus de configuració especial, a fi d'aconseguir una plena accessibilitat (ISO/IEC 25012:2008). En relació amb aquest aspecte, des del W3C *Web Accessibility Initiative* (WAI) s'han definit un conjunt d'estàndards destinats a facilitar l'accés a persones amb diversitat funcional. Aquestes recomanacions es plasmen en les següents guies:

- *Web Content Accessibility Guidelines* (WCAG)⁷⁸, que ofereix una sèrie de pautes destinades a avaluar i mesurar el nivell d'accessibilitat del contingut web. Les recomanacions es fonamenten en quatre principis: perceptibilitat, operativitat, comprensibilitat i robustesa; i en tres nivells d'accessibilitat (A, AA i AAA). Aquestes recomanacions s'han adoptat a la norma ISO 40500 i també a la norma europea d'accessibilitat digital EN 301 549.
- *Authoring Tool Accessibility Guidelines* (ATAG), que defineix els requeriments del sistema de

⁷⁸ La versió actual és la WCAG 2.1, publicada al juny de 2018. Tanmateix s'està treballant en la versió 2.2 que es preveu la seva publicació per a l'any 2021. Per a la consulta de la guia es remet a la pàgina web: <https://www.w3.org/WAI/standards-guidelines/wcag/>

gestió del contingut, editors de codi i altres programes.

- *User Agent Accessibility Guidelines (UAAG)*, que defineix els requeriments per a navegadors web i reproductors multimèdia.

Respecte a l'àmbit legislatiu destaca, pel que fa a l'accessibilitat web, la Directiva (UE) 2016/2102 del Parlament Europeu i del Consell, de 26 d'octubre de 2016, sobre l'accessibilitat dels llocs web i aplicacions per a dispositius mòbils dels organismes del sector públic, amb la seva transposició a l'ordenament jurídic espanyol mitjançant el Reial Decret 1112/2018, de 7 de setembre, sobre accessibilitat dels llocs webs i aplicacions per a dispositius mòbils del sector públic. Finalment, convé destacar que aquestes normes també es basen en els quatre principis d'accessibilitat⁷⁹ establerts a la guia WCAG.

e. Reutilització. La reutilització de la informació del sector públic⁸⁰ és la conseqüència i la finalitat de l'obertura de dades, a fi de que qualsevol persona —física o jurídica— utilitzi els recursos públics de les administracions públiques per a qualsevol propòsit, inclosos lucratis com per exemple les empreses infomediàries (Álvarez, 2014). Dit això, aquest element avalua el grau de reutilització dels conjunts de dades publicats, concretament es mesura la capacitat de reutilització dels datasets a partir de les següents variables (Abella, Ortiz-de-Urbina & De-Pablos-Heredero, 2014, 2019):

- Llicències legals.
- Accés a la informació.
- Estàndards tècnics.
- Estandardització (model de dades).

⁷⁹ Tant la Directiva (UE) 2016/2102 (considerant 37) com el Reial Decret 1112/2018 (article 4) defineixen la perceptibilitat com el principi que exigeix que la informació i els components de la interfície d'usuari es presentin a les persones usuàries de tal forma que es puguin percebre; l'operativitat és el principi que exigeix que els components i la navegació de la interfície d'usuari puguin ser utilitzats per a qualsevol persona usuària; la comprensibilitat és el principi que exigeix que la informació i el funcionament de la interfície d'usuari siguin comprensibles per a qualsevol persona usuària; i en darrer terme la robustesa, que és el principi que exigeix que els continguts siguin suficientment sòlids per a poder ser interpretats de forma fiable per una gran diversitat d'agents d'usuari, incloses les tecnologies d'assistència.

⁸⁰ La llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic defineix la reutilització com «l'ús de documents que estan en poder de les administracions i els organismes del sector públic, de persones físiques o jurídiques, amb fins comercials o no comercials, sempre que aquest ús no constitueixi una activitat administrativa pública (...)» (article 3.1)

- Contingut de geolocalització.
- Freqüència d'actualització.
- Difusió dels datasets publicats.
- Reputació dels recursos de dades.

Així doncs, a partir dels aspectes anteriors s'avalua el grau de reutilització dels conjunts de dades publicats, més enllà de les enquestes d'ús a persones usuàries.

- f. Seguretat/Privacitat.** Aquest element comprèn el grau en què les dades tenen atributs que garanteixen que només siguin accessibles i interpretables pels usuaris autoritzats en un context d'ús específic (ISO/IEC 25012:2008). En el cas concret de les dades obertes, es tracta de dades públiques que no han d'estar subjectes a cap tipus de privacitat, seguretat o qualsevol altre tipus de restricció, excepte les que, per llei, estiguin subjectes a restriccions (Consorti AOC, s.d⁸¹). Així doncs, alguns elements de dades requereixen límits d'ús o accés, per a il·lustrar-ho destaquem com en el Portal de dades obertes

dels Mossos d'Esquadra s'indica que no es publiquen totes aquelles dades que poden vulnerar la privacitat o la seguretat.

En aquest sentit, aquesta propietat avalua si existeixen mecanismes per a identificar i no publicar tota aquella informació que estigui subjecta a restriccions de privacitat, propietat, seguretat i protecció de dades personals. Així mateix, també s'avalua el nivell de seguretat en relació als sistemes d'emmagatzemament i també respecte a l'accés als conjunts de dades publicats; pel que fa a aquest últim aspecte s'examina si els datasets publicats no vulnereu les restriccions d'accés a la informació pública establertes tant a la normativa en matèria de transparència i bon govern com a la normativa sobre protecció de dades.

En última instància, per a la seva avaluació és important tenir en consideració els principis i les mesures de seguretat establertes al Reial Decret 3/2010, de 8 de gener, pel qual es regula l'Esquema Nacional de Seguretat en l'àmbit de l'Administració electrònica.

81 Per a més informació es remet a <https://suport-governobert.aoc.cat/hc/ca/articles/4412214503825-Dades-Obertes-i-reutilitzaci%C3%B3-de-la-informaci%C3%B3>

g. Portabilitat. En enginyeria de software, la portabilitat es defineix com la capacitat d'un producte de software⁸² de ser transferit d'un entorn concret de hardware, software, operacional o d'utilització a un altre (McCall & Cavano, 1978; ISO/IEC 25010:2011). El component portabilitat es relaciona amb la reutilització i també amb la interoperabilitat semàntica, tècnica⁸³ i organitzativa⁸⁴. [Pel que fa a la interoperabilitat semàntica es remet a l'apartat 2.3]. Així doncs, aquest element comprèn el grau en què les dades tenen atributs que permeten la seva substitució o migració d'un sistema a un altre preservant la qualitat existent en un context d'ús específic (ISO/IEC 25012:2008)⁸⁵. És a dir, el que es mesura és el grau en què les dades poden ser transferides, interpretades i utilitzades a una altra aplicació o sistema operatiu, sense canvis de qualitat en les mateixes. Amb tot, si les dades són

fàcilment migrades d'un ambient a un altre, i a més posseeixen totes les seves característiques, significa que les dades són 100% portables.

Un cop vistes les dimensions i els elements ODQ, falta vincular les dimensions identificades a cada una de les categories de segon nivell (contingut, estructura, representació, context i comportament). Convé destacar que la correlació no és una categoria igual a una dimensió, atès que hi ha categories que s'interrelacionen amb diverses dimensions, tal com es mostra a continuació:

- La categoria contingut es vincla a les dimensions d'autenticitat, fiabilitat i integritat. La raó rau en què dita categoria comprèn totes aquelles característiques intrínseques de les dades (valors de dades, dominis d'atributs, regles de negoci, restriccions, etc.), que són aspectes que es localitzen en les dimensions citades ja que es tracta de dimensions internes de les dades, a diferència de la

82 Convé recordar que en el marc d'aquest projecte es concep un producte de software com a informació, independentment del mitjà d'entrega (ISO 9000:2015). Per tant, en base a aquesta definició serien productes de software un manual d'instruccions, el contingut d'un diccionari, els drets d'autor d'una composició musical o el contingut dels datasets publicats en un Portal de dades obertes, conjuntament amb les metadades i altres aspectes que atorguen significat a aquests conjunts de dades.

83 A l'Esquema Nacional d'Interoperabilitat (ENI) es defineix la interoperabilitat tècnica com «la dimensió de la interoperabilitat relativa a la relació entre sistemes i serveis de tecnologies de la informació, incloent-hi aspectes com ara les interfícies, la interconnexió, la integració de dades i serveis, la presentació de la informació, l'accessibilitat i la seguretat, o altres de naturalesa anàloga» (Reial Decret 4/2010. Annex. Glossari de termes, p.17).

84 A l'Esquema Nacional d'Interoperabilitat (ENI) es defineix la interoperabilitat organitzativa com «la dimensió de la interoperabilitat relativa a la capacitat de les entitats i dels processos a través dels quals porten a terme les seves activitats per col·laborar amb l'objecte d'assolir èxits mútuament acordats relatiu als serveis que presten.» (Reial Decret 4/2010. Annex. Glossari de termes, p.17).

85 La ISO/IEC 25012:2008 també parla d'instal·lació, però pel cas concret de les dades aquest aspecte no s'ha tingut en consideració.

usabilitat i la disponibilitat, les quals són externes a les dades ja que depenen del sistema i també dels usuaris.

- La categoria estructura es relaciona amb les dimensions autenticitat i fiabilitat. El motiu resideix en què dites dimensions contenen elements que defineixen i representen l'organització de les dades i les seves interrelacions, cas de la definició/documentació (dins de la dimensió autenticitat) i la granularitat (s'ubica dins la dimensió fiabilitat).
- La categoria representació es vincula a les dimensions usabilitat i disponibilitat. Aquesta categoria engloba tots aquells aspectes (formats, metadades, significats, etc.) que permeten la visualització, interpretació i ús dels datasets. A partir d'això, s'infereix que aquesta categoria s'articula amb la usabilitat, l'àmbit de la qual és la localització, recuperació, presentació i comprensió de les dades; i també amb la disponibilitat, que inclou tots aquells elements adreçats a facilitar l'accés i ús dels conjunts de dades.
- La categoria context es relaciona amb les dimensions autenticitat, integritat, usabilitat i disponibilitat. Dita categoria inclou tota aquella informació que permet entendre la procedència, l'entorn i les relacions on les dades han sigut creades i utilitzades, així com el seu històric. Tots aquests aspectes es localitzen en les dimensions citades ja que l'autenticitat és la propietat que té com a finalitat provar que les dades han sigut creades en el moment i per l'agent que s'afirma, etc.,

és a dir, corroborar el context de les dades; la integritat està conformada per la traçabilitat que es caracteritza per contenir les metadades necessàries per a verificar l'origen i l'històric de les dades; la usabilitat conté un conjunt d'elements relacionats amb les metadades (la llegibilitat/interpretabilitat, la comprensibilitat, la localització, la georeferenciació o la comparabilitat) que ajuden a entendre el context i el significat de les dades; i finalment la disponibilitat posseeix una sèrie d'elements (per exemple, la pertinença temporal, l'actualitat i la reutilització) que inclouen informació sobre el context de les dades, tal com la freqüència d'actualització o la data d'actualització.

- En darrer terme, la categoria comportament es vincula a les dimensions usabilitat i disponibilitat. Aquesta categoria es relaciona amb les funcionalitats inherents de les dades, com per exemple l'existència d'hipervincles. Dit això, es considera que el comportament es connecta amb la usabilitat ja que aquesta dimensió conté aquella informació per a facilitar la localització i presentació de les dades, per exemple, mitjançant URIs; també es vincula a la disponibilitat atès que l'existència de funcionalitats de les dades pot contribuir a fomentar o dificultar l'accessibilitat o la reutilització de les mateixes.

Amb la finalitat de sintetitzar de forma visual el contingut d'aquesta secció, a l'apartat 2.2.3 es presenta una gràfica

de l'ontologia de la qualitat de les dades obertes, on es representen les relacions existents entre els quatre nivells del model ODQ presentat.

2. 2. 2. 1. Consideracions de futur

En el marc d'aquest projecte no s'ha contemplat la dimensió unicitat, tot i que considerem que degut a la creixent importància d'aquesta propietat en grans conjunts de dades es tracta d'una dimensió a incorporar en el futur. Altrament, en el Manual del portal de dades obertes i recursos pels ens locals del Consorci d'Administració Oberta de Catalunya (Consorci AOC) (2019) s'indica que les principals problemàtiques amb les que es poden trobar els ens locals a l'hora de detectar les dades de que disposa i que pot publicar són, entre altres consideracions, la dispersió de les dades i les dades desagregades. Aquestes qüestions es relacionen amb la duplicitat i contradiccions en les dades i amb la no disponibilitat d'una estructura de dades única. Degut a aquests aspectes, des del Consorci AOC es remarca que un dels requisits que han de complir les dades és la unicitat, juntament amb la completesa i l'homogeneïtzació.

Per unicitat s'entén aquella propietat que integra dues característiques: d'una banda, que un valor clau es refereix

únicament a una entitat específica dins del conjunt de dades (DAMA International, 2009); i d'altra banda, que no existeix cap registre duplicat per a una organització o esdeveniment en un mateix dataset o taula (Mahanti, 2018). Dit d'una altra manera, les dades no han d'estar duplicades en diferents sistemes d'informació i, a més, només s'han de generar una única vegada (Consorci AOC, 2019). Finalment, convé destacar que alguns elements ODQ que permeten mesurar i avaluar aquesta dimensió són la cardinalitat⁸⁶ i la redundància de les dades⁸⁷.

⁸⁶ La cardinalitat és aquell element que comprèn el grau d'unicitat o singularitat dels valors de dades que es contenen en una columna particular (també coneguda com a camp o atribut) d'una taula de base de dades (Mahanti, 2018).

⁸⁷ La redundància de dades és aquell element que mesura el grau en què les dades es reproduïxen i es capturen en dos sistemes d'informació diferents i en ubicacions d'emmagatzematge diferents (Mahanti, 2018).

2. 2. 3. Ontologia de la qualitat de les dades obertes (ODQ)

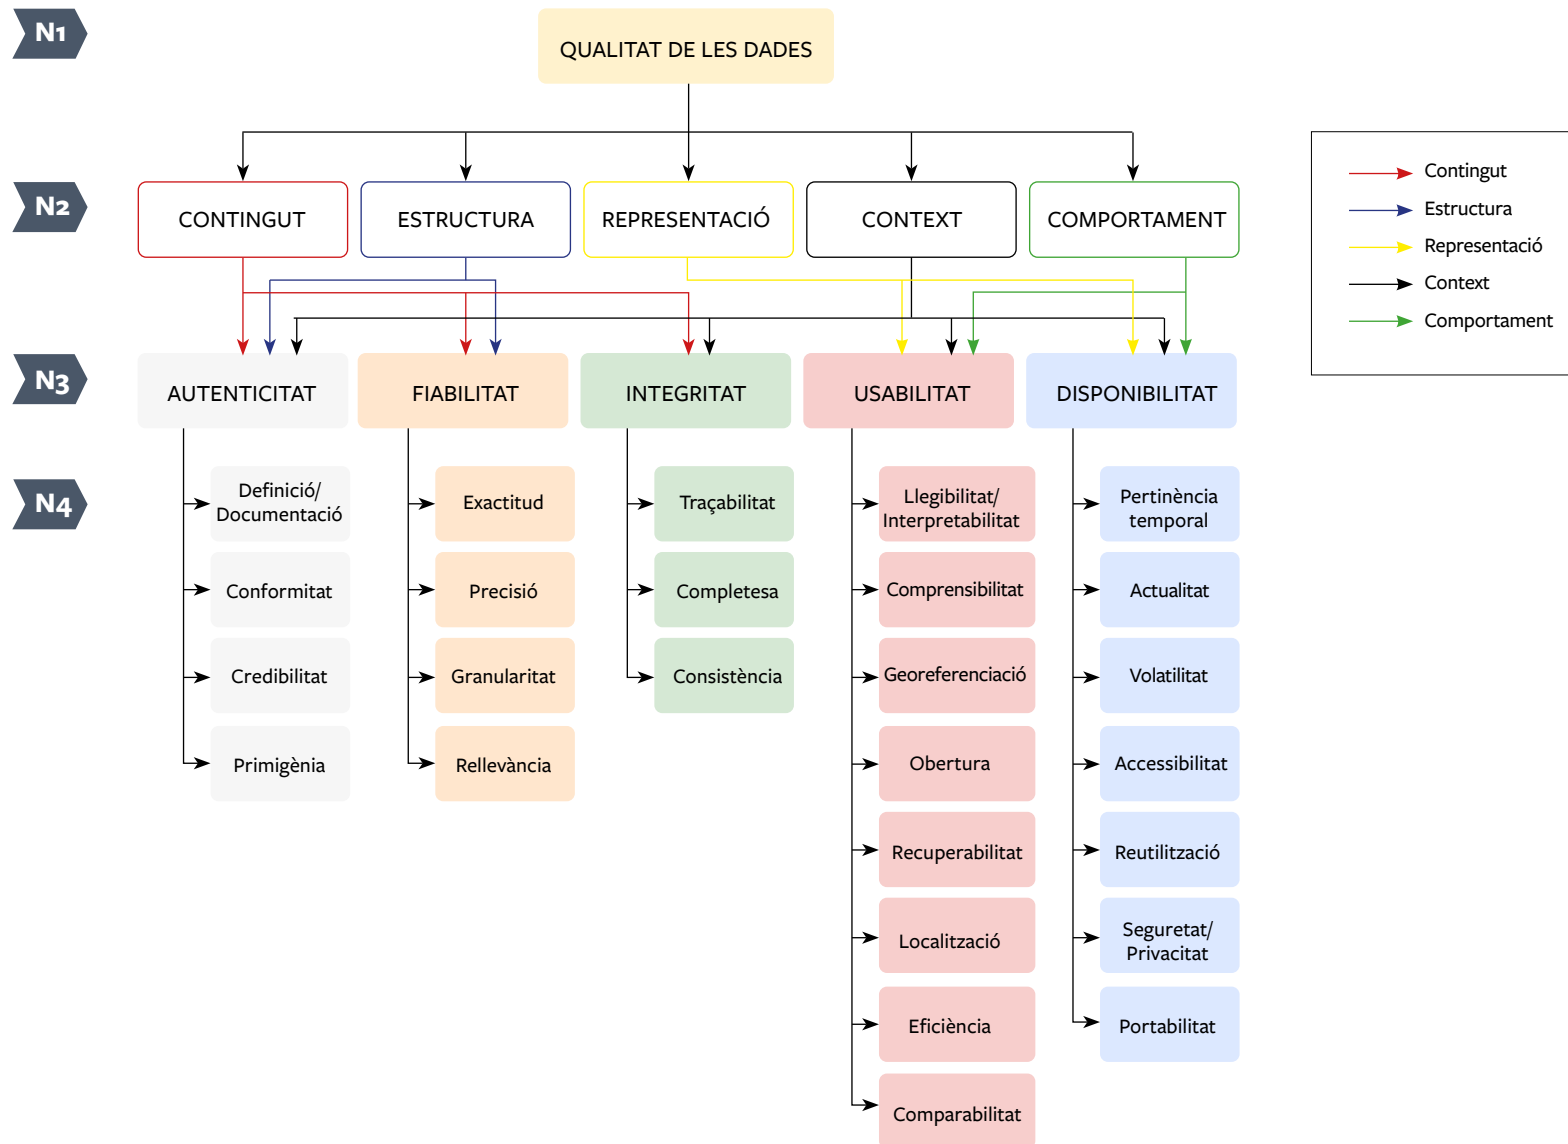


Figura 22. Ontologia de la qualitat de les dades obertes (ODQ) (Font: Elaboració pròpia, 2021).

2.3. Vocabulari de metadades per a la descripció de les dades obertes

Segons el Reial decret 4/2010, de 8 de gener, pel qual es regula l'Esquema Nacional d'Interoperabilitat en l'àmbit de l'Administració electrònica, la interoperabilitat és la «capacitat dels sistemes d'informació, i, per tant, dels procediments als quals aquests donen suport, de compartir dades i possibilitar l'intercanvi d'informació i coneixement entre aquests» (Annex. Glossari de termes, p.17). Així doncs, la interoperabilitat és un aspecte rellevant ja que possibilita l'intercanvi d'informació entre administracions públiques, i també entre aquestes i les persones físiques i jurídiques, de forma comprensible per a totes les parts.

Dins del marc nacional d'interoperabilitat⁸⁸ s'identifiquen quatre capes d'interoperabilitat: la interoperabilitat organitzativa, la interoperabilitat semàntica, la interoperabilitat tècnica i la interoperabilitat en el temps. Així mateix, en el marc europeu d'interoperabilitat⁸⁹ (*European Interoperability Framework* – EIF) també s'identifiquen quatre capes, tot i que en lloc de la interoperabilitat en el temps, es distingeix la interoperabilitat jurídica. De totes les capes enumerades, la que interessa per aquest apartat és la

interoperabilitat semàntica atès que és la dimensió de la interoperabilitat relacionada amb l'elaboració de models i estàndards. Concretament, la interoperabilitat semàntica es defineix com aquella «*dimensió de la interoperabilitat relativa a que la informació intercanviada pugui ser interpretable de forma automàtica i reutilitzable per aplicacions que no van intervenir en la seva creació*» (Reial Decret 4/2010. Annex. Glossari de termes, p.17). És a dir, aquesta capa garanteix que el format (aspecte sintàctic) i el significat exacte (aspecte semàntic) de la informació intercanviada sigui comprensible per a totes les parts. A fi d'aconseguir la interoperabilitat semàntica és necessari l'estandardització de taxonomies, vocabularis controlats, tesaurus, llistes de codis i estructures i models de dades reutilitzables (Comissió Europea, 2017).

Per al cas particular del model de qualitat de les dades obertes vist a l'apartat anterior, la interoperabilitat semàntica es troba integrada dins l'element ODQ llegibilitat/interpretabilitat i a més es relaciona amb les propietats comparabilitat i portabilitat de les dades. Així doncs, la capacitat d'interpretar i també de compartir correctament el contingut de les dades depèn de l'ús d'estàndards i vocabularis controlats, definits i coneguts per totes les parts.

⁸⁸ El marc nacional d'interoperabilitat es troba regulat pel Reial decret 4/2010, de 8 de gener, pel qual es regula l'Esquema Nacional d'Interoperabilitat en l'àmbit de l'Administració electrònica; i també les normes tècniques d'interoperabilitat (NTIs).

⁸⁹ El marc europeu d'interoperabilitat es troba regulat, sense caràcter limitatiu, per la Comunicació de la Comissió al Parlament Europeu, al Consell, al Comitè Econòmic i Social Europeu i al Comitè de les regions – COM/2017/0134 final; la Declaració ministerial d'administració electrònica de Tallin (2017); i el Reglament (UE) 2021/694 del Parlament Europeu i del Consell de 29 d'abril de 2021 pel qual s'estableix el Programa Europa Digital i pel qual es deroga la Decisió (UE) 2015/2240.

En aquest sentit, en el cas de les dades obertes —i en general de la reutilització de recursos d'informació del sector públic— és obligatori l'ús d'unes metadades mínimes associades al catàleg, als datasets i a les distribucions. En el context nacional, s'ha adoptat el Vocabulari de Catàleg de Dades (*Data Catalog Vocabulary*, DCAT), que és un vocabulari RDF desenvolupat pel W3C, la finalitat del qual és facilitar la interoperabilitat entre els catàlegs de dades publicats en la Web per diferents fonts (APORTA, 2018). En la Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la qual s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos de la informació (NTI-RISP), es descriu en l'annex III les metadades d'aquest vocabulari estàndard a nivell de catàleg, dataset i distribució, amb especificació del nivell d'obligatorietat i de si la metadada és repetible. En concret, per al nivell catàleg es descriuen 13 metadades, de les quals 10 són obligatòries; pel que fa als conjunts de dades s'indiquen un total de 17 metadades, 5 de les quals són obligatòries; i finalment per a les distribucions hi ha 6 metadades, de les quals 2 són obligatòries.

A continuació, s'incorpora la **Taula 12** en la qual s'han identificat les metadades a informar segons el Vocabulari DCAT, amb indicació de la categoria d'aplicació, la denominació de la metadada, l'obligatorietat i si és repetible. Tanmateix, per a més informació en relació amb el vocabulari es remet a l'annex III de la [NTI-RISP](#).

Categoria	Denominació	Obligatòria	Repetible
Catàleg (domini dcat:Catalog)	Nom	X	X
	Descripció	X	X
	Òrgan publicador	X	-
	Mida del catàleg	-	-
	Identificador	-	-
	Data de creació	X	-
	Data d'actualització	X	-
	Idioma	X	X
	Cobertura geogràfica	-	X
	Temàtiques	X	X
	Pàgina web	X	-
	Termes d'ús	X	-
	Document(s) i recurs(os) d'informació	X	X

Categoria	Denominació	Obligatòria	Repetible
Conjunts de dades⁹⁰ (domini dcat:Dataset)	Nom	X	X
	Descripció	X	X
	Temàtiques	X	X
	Etiquetes	-	X
	Identificador	-	-
	Data creació	-	-
	Data última actualització	-	-
	Freqüència d'actualització	-	-
	Idioma	-	X
	Organisme que exposa i publica les dades	X	-
	Condicions d'ús	-	-
	Cobertura geogràfica	-	X
	Cobertura temporal	-	X
	Vigència del recurs	-	-
	Recurs(os) relacionat(s)	-	X
	Normativa	-	X
	Distribució(ns)	X	X

Categoria	Denominació	Obligatòria	Repetible
Distribució (domini dcat:Distribution)	Identificador	-	-
	Nom	-	X
	URL accés	X	-
	Format	X	-
	Mida	-	-
	Informació adicional sobre el format	-	X

Taula 12. Vocabulari DCAT aplicat a recursos d'informació (Font: Elaboració pròpia, 2021. A partir de la NTI-RISP, 2013).

De l'anàlisi de les metadades de la taula anterior s'infereixen els següents aspectes:

- D'una banda, hi ha metadades a nivell de catàleg, dataset i distribució que no són obligatòries però es considera que sí ho haurien de ser, en concret es tracta de les següents:
 - » La metadada identificador que és la referencia (URI) per a identificar la categoria es recomana que sigui obligatòria, a fi de facilitar la localització i identificació del recurs en la Web. Així mateix, a l'apartat IV de la NTI-RISP s'indica que «los

⁹⁰ A la NTI-RISP aquesta categoria es denomina Document i recurs d'informació.

documentos y recursos de información reutilizables estarán identificados mediante referencias únicas y unívocas, basadas en identificadores de recursos uniformes (...)». Aquesta mateixa idea es remarca en el punt 42 de la Guia de aplicació de la NTI-RISP (2016) al indicar que «*cualquier recurso publicado en la Web debe disponer de un URI que lo identifique unívocamente entre el resto de los recursos*», raó per la qual es considera que la citada metadada ha de ser un element a requerir.

- » Les metadades relacionades amb les dates del dataset (data de creació, data última actualització i freqüència d'actualització) també es recomana que siguin obligatòries ja que es tracta d'elements que és important que coneguin les persones usuàries. A més, a partir d'aquestes metadades es pot verificar si els datasets estan actualitzats i quan serà la pròxima actualització.
- » La metadada condicions d'ús del dataset no és obligatòria. Al respecte, es recomana que sí ho sigui a efecte de que les persones usuàries i reutilitzadores coneguin quina és la llicència d'ús aplicable al dataset. Es considera que informar d'aquesta metadada ofereix certesa i seguretat a l'hora de reutilitzar els conjunts de dades, atès que permet conèixer sota quines condicions es poden utilitzar i redistribuir. Altrament, trobem que la metadada termes d'ús del

catàleg sí és obligatòria; per tant, una opció és que aquesta metadada s'hereti al conjunt de dades.

- D'altra banda, les metadades identificades a la NTI-RISP informen sobre aspectes relacionats amb la descripció, context, característiques tècniques i entitat publicadora. Tanmateix, es troba a faltar metadades vinculades a la gestió de la informació (tal com responsable de les dades o el tipus d'actualització), i també a la traçabilitat (per exemple, històric d'actualitzacions, migracions de sistema, etc.) a fi de mantenir una pista d'auditoria de les accions realitzades sobre el catàleg i el conjunt de dades.

En l'àmbit europeu, s'ha desenvolupat un perfil d'aplicació de DCAT per a portals de dades europeus (DCAT-AP), la finalitat del qual és descriure mitjançant metadades els catàlegs i els datasets publicats en portals europeus de dades obertes del sector públic (APORTA, 2018). A grans trets es tracta d'una especificació concreta, impulsada des de la Comissió Europea, en la qual, si es compara el perfil d'aplicació DCAT-AP amb el vocabulari DCAT de la NTI-RISP, es modifiquen certes restriccions com per exemple s'afegeixen noves categories d'aplicació o s'amplia el conjunt mínim de metadades que es requereixen. Aquest perfil no és objecte d'anàlisi en aquest projecte, ja que tant els catàlegs com els datasets d'estudi procedeixen del sistema de dades obertes de la Generalitat de Catalunya, que posseeix el seu propi vocabulari estàndard. No obstant, per a més informació en relació amb el perfil

d'aplicació DCAT-AP es remet a la pàgina de [Joinup](#)⁹¹, des de la qual es pot descarregar la versió actual (v2.0.1).

Pel que fa a Catalunya, des de la Generalitat de Catalunya s'ha elaborat i publicat al novembre de 2020 la “Guia d'emplenament de les metadades del conjunt de dades per a la tramesa de dades obertes al Portal de dades obertes de la Generalitat de Catalunya”, que estableix els criteris i estàndards a seguir per part dels organismes que posen a disposició de la ciutadania els seus datasets a través del citat Portal. Tal com s'indica a la guia, l'objectiu de la mateixa és que departaments, organismes i institucions de Catalunya segueixin uns criteris homogenis en la publicació de dades obertes. En dita guia es descriuen 27 metadades associades als datasets, de les quals 21 són obligatòries, a més de 2 metadades per a les columnes que també són obligatòries. Tot seguit, a la **Taula 13** es presenten les metadades de la guia, amb indicació de la categoria a la que apliquen (dataset o columna), a quin grup pertanyen, la denominació de les mateixes i, finalment, si són obligatòries. Tanmateix, no s'indica si són repetibles ja que aquest camp no està informat per la Generalitat. Per a més informació d'aquest vocabulari estàndard es remet a la citada [guia](#).

Categoria	Grup	Denominació	Obligatòria
Conjunt de dades	Taxonomia	Títol	X
		Descripció	X
		Categoria	X
		Paraules clau	-
		Cobertura temporal	X
		Llicències	X
		Etiqueta de la filera	-
	Fitxers adjunts	-	
	Entitat publicadora	Productor	X
		Enllaç font	X
		Tipus actor	X
		Departament	-
		Organisme o institució	-
		Altre organisme o institució	-

91 Joinup és una plataforma col·laborativa creada per la Comissió Europea i finançada per la Unió Europea, a través del Programa sobre Solucions d'Interoperabilitat per a les Administracions Públiques (*Interoperability solutions for public administrations, businesses and citizens - ISA²*), amb l'objectiu de ser un punt de trobada i també oferir serveis als professionals de l'Administració electrònica (APORTA, 2018).

Categoria	Grup	Denominació	Obligatòria
	Informacions tècniques	Freqüència actualització	X
		Àmbit geogràfic	X
		Informació geogràfica	X
		Perspectiva de gènere	X
		Idioma	X
		Nombre del conjunto de datos	X
		Dataset name	X
	Gestió de la informació	Responsable de les dades (RD)	X
		Mecanisme actualització	X
		Tipus actualització	X
	Continguts destacats	Títol	X
		Descripció	X
		Enllaç al recurs	X
	Columnes del conjunt de dades	Columnes	Nom
Descripció			X

Convé recordar que la NTI-RISP marca el mínim que s'ha de complir per part de les administracions públiques. Si es compara el vocabulari DCAT en relació amb el vocabulari establert per la Generalitat, s'evidencia que aquesta última no compleix amb l'ENI pels punts que a continuació s'exposen:

- En primer lloc, en la guia tècnica de la Generalitat no més es detallen metadades del conjunt de dades i de les columnes dels datasets, però en cap cas del catàleg i de la distribució. No obstant, hi ha metadades obligatòries d'alguna de les categories no identificades que es troben identificades a nivell de dataset. Una bona mostra és la URL accés que en la NTI-RISP és obligatòria per a la distribució, en canvi, en la guia tècnica es correlacionaria amb la metadada enllaç font, la qual també és obligatòria però en aquest cas en la categoria conjunt de dades.
- En segon lloc, si bé el nombre mínim de metadades a informar del dataset s'amplia, tant amb metadades noves (per exemple, perspectiva de gènere) com amb metadades que abans eren opcionals (per exemple, freqüència actualització); es constata que hi ha metadades obligatòries segons la NTI-RISP que no apareixen en el vocabulari de la Generalitat, tal com la data de creació, la data d'actualització (ambdues de la categoria catàleg), la distribució (de la categoria dataset) o el format (de la categoria distribució).

Taula 13. Vocabulari estàndard de dades obertes de la Generalitat de Catalunya

(Font: Elaboració pròpia, 2021. A partir de la Generalitat de Catalunya, 2020).

- I en darrer lloc, s'observa que en l'estàndard de la Generalitat no hi ha metadades relacionades amb recursos relacionats ni amb l'identificador mitjançant URI; tot i que ambdues metadades són opcionals en la NTI-RISP. Altrament, convé destacar que l'ús d'elements de dades enllaçades tal com URIs es valora com una bona pràctica a adoptar per part de les organitzacions (Abella, Ortiz-de-Urbina-Criado, De-Pablos-Heredero, Vidal & Ferrer, 2019).

Tanmateix és important senyalar que la guia de la Generalitat inclou metadades relacionades amb la gestió de la informació, element no inclòs a la NTI-RISP; però no incorpora metadades vinculades a la traçabilitat, tal com l'historial del canvi. No obstant, tal com s'ha vist anteriorment, a la NTI-RISP tampoc hi ha metadades d'aquest àmbit.

Finament, cal subratllar que els datasets objecte d'estudi són del sistema de dades obertes de la Generalitat de Catalunya, raó per la qual l'avaluació a nivell de metadades es realitza a partir de la verificació amb l'estàndard de la Generalitat o, si s'escau, amb altres vocabularis propis que descriuen aquells conjunts de dades que es localitzen en portals que conviuen amb el Portal de dades obertes de Catalunya. En cap cas, però, s'obvia el vocabulari DCAT

de la NTI-RISP ja que la citada norma, que forma part del context més ampli de l'Esquema Nacional d'Interoperabilitat⁹², recull les pautes mínimes per a garantir l'adequat nivell d'interoperabilitat semàntica per part de les Administracions públiques.

2.4. Mesurament i avaluació de les dimensions de qualitat de les dades obertes

En aquest apartat es presenta el conjunt de mètriques i indicadors dels elements ODQ que serveixen per avaluar les cinc dimensions de qualitat de les dades obertes. Convé destacar que tant les mètriques com els indicadors s'han obtingut de la revisió dels treballs realitzats per altres investigadors i investigadores que incorporen mesures objectives (Ballou, Wang, Pazer & Tayi, 1998; Pipino, Lee & Wang, 2002; Berners-Lee, 2010; Abella, Ortiz-de-Urbina & De-Pablos-Heredero, 2014, 2019; Cai & Zhu, 2015; Batini & Scannapieco, 2016; Kubler *et al.*, 2017; Mahanti, 2018), així com dels estàndards d'aplicació, concretament la norma ISO/IEC 25012:2008 i la UNE 178301:2015. No obstant, per aquells elements ODQ en què les mètriques no s'adeqüen a la definició proporcionada, o directament són inexistents, es desenvolupa una proposta per avaluar la propietat.

92 Tal com s'estableix a l'article 156 de la Llei 40/2015, d'1 d'octubre, de règim jurídic del sector públic, l'Esquema Nacional d'Interoperabilitat «comprèn el conjunt de criteris i recomanacions en matèria de seguretat, conservació i normalització de la informació, dels formats i de les aplicacions que han de tenir en compte les administracions públiques per prendre decisions tecnològiques que garanteixin la interoperabilitat.»

Altrament convé remarcar que les mètriques i indicadors que s'han agregat no són comparables entre elles, ja que posseeixen diferents formes i escales de mesura, la qual cosa suposa que el procés de mesura és diferent. No obstant això, els resultats s'han harmonitzat dins de cada dimensió ODQ incorporant per a cada element ODQ un pes concret que varia segons la propietat, en funció del seu major o menor impacte. Així mateix, aquest pes s'ha establert en termes percentuals, on la suma dels percentatges de cada un dels elements que s'agrupen sota una dimensió específica ascendeix a un total de 100%, tal com es pot veure a l'apartat 2.4.2. Finalment, a l'apartat 2.4.3 es presenta la forma de càlcul del valor final de cada mètrica i del valor total del conjunt de mètriques, així com una taula de correspondència entre els valors totals i el nivell de qualitat de les dades obertes.

2. 4. 1. Mètriques i indicadors per avaluar les dimensions de qualitat de les dades obertes

A continuació s'estableixen les mètriques i indicadors per a cada un dels elements ODQ identificats a l'apartat 2.2.2. En particular, s'especifica l'objecte de la mesura, la forma de càlcul, la puntuació màxima que es pot obtenir, les observacions a la mètrica (si s'escau) i exemples.

1. Dimensió Autenticitat

a. Definició/Documentació. Aquest element verifica si s'ha publicat la documentació de les dades. Concretament s'avalua si per aquells formats no autodocumentats⁹³, per exemple el CSV, s'inclou informació complementària sobre el significat de la dada, l'estructura de la dada (atributs, formats, etc.) i la referència a la dada completa si es tracta d'abreviatures. La forma de càlcul que es presenta és la que proposa la norma UNE 178301:2015; tanmateix, s'han modificat els ítems a fi de realitzar l'avaluació a nivell de dataset i no a nivell de tots els conjunts de dades.

- Puntuació màxima: 3 punts
 - » 0 Les dades no estan documentades. [Es correspon al nivell 0: resultats inexistents de la UNE 178301:2015].
 - » 1 Es publica la documentació de l'estructura de les dades (esquema del contingut de les dades i el seu significat, en cas de que el nom del camp no sigui fàcilment interpretable per tractar-se d'una abreviatura o una etiqueta interna pròpia). [Es correspon

⁹³ En els formats autodocumentats, com per exemple RDF, la documentació de l'estructura i contingut es troba implícita, el que suposa que no és necessària documentació addicional (UNE 178301:2015).

al nivell 1: resultats incipients (informal) de la UNE 178301:2015].

- » 2 Es publica la documentació de l'estructura de les dades i el tipus de dades (text, número, etc.). [Es correspon al nivell 2: resultats existents de la UNE 178301:2015].
 - » 3 Es publica la documentació de l'estructura de dades, el tipus de dades i els possibles valors que pot prendre (si s'escau), notes sobre interpretació, etc. [Es correspon al nivell 3: resultats avançats de la UNE 178301:2015].
- Fórmula: N/A
 - Fórmules alternatives: N/A
 - Observacions: si es vol realitzar una avaluació global de tots els conjunts de dades es remet a la proposta originària de la norma UNE 178301:2015.
 - Exemple: per a il·lustrar-ho considerem el dataset Dades del mapa urbanístic de Catalunya que es localitza al Portal de dades obertes de la Generalitat de Catalunya. Un cop revisat tant el dataset com les metada-

des associades es confirma que la puntuació màxima obtinguda és 2 punts, atès que a les metadades de les columnes s'informa de l'estructura de les dades i del tipus de dades. Tanmateix, es conclou que no s'informa dels possibles valors que poden prendre les dades ja que, per exemple, en el cas de l'atribut AFT s'indica que és el nom dels àmbits funcionals territorials, 8 en total, però en cap cas s'explicita quin són aquests 8 possibles valors.

- b. Conformitat.** Aquest element mesura que les dades compleixen amb normes externes (per exemple, normes ISO), polítiques i instruccions internes, regles de negoci i/o estàndards de definicions de dades, que inclou les definicions de metadades. La conformitat es pot mesurar en dos nivells: d'una banda, a nivell de dada o valor (*data element*) i, d'altra banda, a nivell de registres o files de dades (*data record*). A continuació es detalla la forma de càlcul per a cada un dels nivells (Mahanti, 2018):

Nivell dada o valor dins un conjunt de dades (*data element*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.

- Fórmula principal:
 - » Conformitat % = (Nombre de valors vàlids⁹⁴ a nivell de dades en el dataset, s'exclouen els valors perduts x 100) / Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts.
- Fórmules alternatives:
 - » Conformitat % = ((Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts - Nombre de valors no vàlids a nivell de dades en el dataset, s'exclouen els valors perduts) x 100) / Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts.
 - » No conformitat % = (Nombre de valors no vàlids a nivell de dades en el dataset, s'exclouen els valors perduts x 100) / Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts.
- Observacions: aquest element es mesura sobre aquells valors o dades que es consideren crítics dins una base de dades.
- Exemple: per a il·lustrar-ho, considerem un conjunt de dades d'alumnes d'una facultat concreta. En aquesta taula les dades que s'informen són nom, cognom 1, cognom 2, DNI/NIE, NIA, ensenyament, curs i any accés. D'aquestes dades considerem com a crítiques els atributs nom, cognom 1, DNI i NIA, ja que sense elles és fa difícil identificar a l'alumnat. En el cas del DNI/NIE si hi hagués una regla o una definició del valor que digués que per al DNI el patró és <8 dígit><lletra> i pel NIE el patró és <lletra><set dígit><dígit de control>, s'hauria de comprovar si els valors del dataset són vàlids en relació amb la definició de la dada, és a dir, si compleixen amb la regla. Imaginem que en el cas del DNI/NIE hi ha un total de 300 valors dins del dataset, dels quals 50 no són vàlids i 250 sí ho són. Un cop quantificat s'aplica la següent fórmula:
 - » $(250 \times 100) / 300 = 25.000 / 300 = 83,3$

⁹⁴ Els valors vàlids són conformes a les regles de negoci i als estàndards tant interns com externs (Mahanti, 2018). D'aquesta afirmació s'infereix que per a mesurar la conformitat és important conèixer prèviament les regles de negoci de l'organització i els estàndards d'aplicació.

De la fórmula s'infereix que la conformitat de l'atribut DNI/NIE és del 83,3 %. Finalment, destacar que aquesta mesura s'hauria de realitzar per a cada una de les dades crítiques del dataset, segons la regla que apliqui a cada una.

Nivell de registre o files de dades (*data record*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.
- Fórmula principal:
 - » Conformitat del registre % = (Nombre de registres o files vàlides en el dataset x 100) / Nombre total de registres o files en el dataset.
- Fórmules alternatives:
 - » Conformitat del registre % = ((Nombre total de registres o files en el dataset – Nombre de registres o files no vàlides en el dataset) x 100) / Nombre total de registres o files en el *dataset*.
 - » No conformitat del registre % = (Nombre de registres o files no vàlides en el dataset x 100) / Nombre total de registres o files en el dataset.

- Observacions: la determinació de que un registre o fila és vàlid o invàlid s'ha de fonamentar en regles de negoci. Així mateix, aquesta identificació es relaciona amb la validesa de les dades o valors crítics de cada una de les tuples. Una possible regla pot ser que aquells registres o files que contenen un o més valors crítics no vàlids, que per al cas de les tuples també s'inclouen camps en blanc i valors nuls, es consideren a efectes de còmput com a registres o files invàlides.

- Exemple: de la mostra del conjunt de dades d'alumnes d'una facultat concreta, imaginem que la taula disposa de 300 registres dels quals, 120 tuples contenen valors crítics no vàlids en relació amb els patrons establerts. Això significa que del total de files, hi ha 120 que no són vàlides i 180 que sí ho són. A partir d'aquest còmput s'aplicaria la següent fórmula:

$$\gg (180 \times 100) / 300 = 18.000 / 300 = 60$$

Per tant, a l'exemple proposat la conformitat de registre és del 60 %

- c. **Credibilitat.** Aquest element mesura el grau en què les dades es consideren certes i creïbles perquè es basen en fonts fiables i/o són lliurades per organitzacions de confiança. En quant als

indicadors de mesura es realitza una proposta ja que les mètriques revisades (ISO/IEC 25012:2008; Mahanti, 2018) posseeixen algunes carències. En el cas de la norma ISO només es planteja un únic criteri basat en l'auditoria per part d'una organització de confiança que certifiqui les dades; mentre que la forma de mesurar de Mahanti es basa en una enquesta a usuaris que resulta ser massa subjectiva pels criteris de credibilitat identificats. No obstant, convé destacar que si bé els criteris s'han modificat, ja que s'han incorporat com a indicadors les recomanacions realitzades per Open Data Support (2014) i també el criteri establert a la ISO/IEC 25012:2008, la forma de càlcul confeccionada per Mahanti s'ha mantingut.

- Puntuació màxima: 1 punt

- » A Els datasets contenen dades de processos que es poden verificar independentment? [Tipus booleà: No-0; Sí-1]
- » B La descripció dels datasets està realitzada per una organització de confiança? [Tipus booleà: No-0; Sí-1]

- » C El proveïdor de les dades i el propietari de les mateixes, en cas de tractar-se d'actors diferents, són organitzacions de confiança? [Tipus booleà: No-0; Sí-1]
 - » D Les dades estan certificades a partir d'auditories internes i/o externes per part d'organitzacions de confiança? [Tipus booleà: No-0; Sí-1]
- Fórmula: $(A + B + C + D) / 4$
 - Fórmules alternatives: N/A
 - Observacions: la puntuació final que es pot obtenir va d'una escala de 0 a 1, on 0 implica una baixa credibilitat i 1 una alta credibilitat.
 - Exemple: en el cas del dataset sobre el total del recompte provisional de les eleccions al Parlament de Catalunya, proveït per la Direcció General de Participació Ciutadana i Processos Electorals i publicat al Portal de dades obertes de la Generalitat de Catalunya, la puntuació seria la que es detalla a continuació:
 - » A – 1 [Els resultats electorals es poden verificar independentment del dataset].

- » B – 1 [La descripció del dataset està realitzada per la Generalitat de Catalunya que és una organització de confiança].
- » C – 1 [Tant el proveïdor de les dades com el propietari de les mateixes són organitzacions de confiança, és a dir, són fonts autoritzades].
- » D – 0 [No hi ha publicada cap tipus de certificació de les dades procedent d'una auditoria interna o externa per part d'organitzacions de confiança].

A partir d'aquest còmput s'aplica la següent fórmula:

$$\text{» } (1 + 1 + 1 + 0) / 4 = 3 / 4 = 0,75$$

L'escala del resultat final va de 0 a 1, per tant, el resultat obtingut evidencia que el dataset té una alta credibilitat (0,75).

d. Primigènia. Aquest element mesura que les dades publicades són primàries, és a dir, tenen el màxim nivell de detall possible, s'han recol·lectat directament de la font original i la publicació de les dades no ha implicat tractament d'agregació, modificació o resum de les dades. A més, en cas de modificació de les dades (per exemple, degut a processos

d'anonimització per acomplir amb la normativa en matèria de protecció de dades) el tractament només ha de centrar-se en aquelles dades protegides per raons de caràcter personal o en algun dels supòsits que limiten el dret d'accés a la informació pública segons la llei 19/2014. Així mateix, com a complement a les dades primàries es poden publicar dades agregades per a facilitar altres usos. La forma de càlcul que es presenta és la que proposa la norma UNE 178301:2015; tanmateix, s'han modificat els ítems a fi de realitzar l'avaluació a nivell de dataset i no a nivell de tots els conjunts de dades.

- Puntuació màxima: 3 punts
 - » 0 El dataset no és primari. [Es correspon al nivell 0: resultats inexistents de la UNE 178301:2015].
 - » 1 El dataset és primari, però no s'ha avaluat la publicació del màxim nivell de detall i no s'explica ni publica el mètode seguit d'agregació. [Es correspon al nivell 1: resultats incipients (informal) de la UNE 178301:2015].
 - » 2 El dataset és primari, s'ha avaluat la publicació del màxim nivell de detall, però no s'explica ni publica el mètode seguit

d'agregació. [Es correspon al nivell 2: resultats existents de la UNE 178301:2015].

- » 3 El dataset és primari, s'ha avaluat la publicació del màxim nivell de detall, i s'explica i publica el mètode seguit d'agregació. [Es correspon al nivell 3: resultats avançats de la UNE 178301:2015].

- Fórmula: N/A
- Fórmules alternatives: N/A
- Observacions: si es vol realitzar una avaluació global de tots els conjunts de dades es remet a la proposta originària de la norma UNE 178301:2015.
- Exemple: per a il·lustrar-ho considerem el dataset Registre d'Entitats Esportives (REE) que es localitza al Portal de dades obertes de la Generalitat de Catalunya. Un cop avaluat el dataset es conclou que la puntuació màxima obtinguda és 0 punts, atès que a la descripció sobre el conjunt de dades s'explicita que *«en aquest registre també s'inscriuen, entre d'altres, els actes i dades següents: la modificació dels estatuts de les entitats esportives, el nomenament, la suspensió i el cessament dels membres electes*

de l'òrgan de govern de les entitats esportives i la dissolució de les entitats esportives». No obstant, al revisar els atributs del dataset es confirma que no hi ha dades relacionades amb la dissolució de les entitats, modificació dels estatuts, etc., per la qual cosa es conclou que si bé el dataset publicat conté informació recollida de la font, hi ha hagut un procés de selecció de les mateixes ja que no es publica tota la informació continguda en el REE.

2. Dimensió Fiabilitat

- a. **Exactitud.** Aquest element mesura la correctesa de les dades, concretament, s'avalua que el contingut representa l'objecte, el fenomen, l'entitat, etc., que descriu del món real. La valoració d'aquesta propietat es pot fer de dues formes (Mahanti, 2018):
 - Per un costat, avaluant les dades mitjançant comparació directa amb l'objecte, entitat, fenomen, etc., que es descriu del món real.
 - Per l'altre, avaluant les dades mitjançant comparació amb un conjunt de dades de referència autoritzat que substitueix l'entitat del món real, i que s'ha validat per a mesurar l'exactitud de les dades.

Així mateix, l'exactitud es pot mesurar en dos nivells: d'una banda, a nivell de dada o valor (*data element*) i, d'altra banda, a nivell de registres o files de dades (*data record*). En ambos casos, per mesurar l'exactitud és necessari definir prèviament amb que es compararà el conjunt de dades que s'ha d'avaluar.

A continuació es detalla la forma de càlcul per a cada un dels nivells (Mahanti, 2018):

Nivell dada o valor dins un conjunt de dades (*data element*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.
- Fórmula:
 - » $\text{Exactitud \%} = (\text{Nombre de valors exactes}^{95} \text{ a nivell de dades en el dataset, s'exclouen els valors perduts} \times 100) / \text{Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts}.$

- Fórmules alternatives:
 - » $\text{Exactitud \%} = ((\text{Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts} - \text{Nombre de valors no exactes a nivell de dades en el dataset, s'exclouen els valors perduts}) \times 100) / \text{Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts}.$
 - » $\text{Inexactitud \%} = (\text{Nombre de valors no exactes a nivell de dades en el dataset, s'exclouen els valors perduts} \times 100) / \text{Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts}.$
- Observacions: aquest element es mesura sobre aquells valors o dades que es consideren crítics dins una base de dades.
- Exemple: per a il·lustrar-ho considerem el dataset de població de Catalunya per municipi, rang d'edat i sexe, en el qual l'atribut codi municipi és crític. Per avaluar-ne l'exactitud dels valors d'aquest atribut o columna, es compararien aquestes dades amb les contingudes a l'Institut d'Estadística de Catalunya (Idescat) que és

⁹⁵ S'utilitza per a mesurar tant l'exactitud semàntica com l'exactitud sintàctica.

una font de referència. Per aquest exemple considerem que hi ha un total de 1.896 valors, dels quals 100 valors no són exactes (ja que algun codi no es correlaciona amb els que hi ha a la base de dades d'Idescat) i 1.796 sí ho són. A partir d'aquest còmput s'aplicaria la següent fórmula:

$$\gg (1.796 \times 100) / 1.896 = 179.600 / 1.896 = 94,73$$

De la fórmula anterior s'infereix que l'exactitud de l'atribut codi municipi és del 94,73 %.

Nivell de registre o files de dades (*data record*):

- Puntuació màxima: 100%

» El resultat és percentual.

- Fórmula:

» Exactitud del registre % = (Nombre de registres o files exactes en el dataset x 100) / Nombre total de registres o files en el dataset.

- Fórmules alternatives:

» Exactitud del registre % = ((Nombre total de registres o files en el dataset – Nombre de registres o files no exactes en el dataset) x 100) / Nombre total de registres o files en el dataset.

» Inexactitud del registre % = (Nombre de registres o files inexactes en el dataset x 100) / Nombre total de registres o files en el dataset.

- Observacions: per a mesurar l'exactitud a nivell de registre s'avaluen cada un dels valors crítics que conté el registre. Si un registre conté un o més valors que no són exactes o que falten, aleshores el registre es considera que és inexacte.

- Exemple: de la mostra del conjunt de dades de població de Catalunya per municipi, rang d'edat i sexe, imaginem que la taula disposa de 948 registres dels quals, pel que fa a l'atribut codi municipi, hi ha 100 registres inexactes en relació amb la font de referència, mentre que 848 files sí que són exactes. A partir d'aquest còmput s'aplicaria la següent fórmula:

$$\gg (848 \times 100) / 948 = 84.800 / 948 = 89,45$$

Per tant, a l'exemple proposat l'exactitud de registre és del 89,45 %.

- b. Precisió.** Aquesta propietat mesura que els elements de dades contenen un nivell suficient de detall, segons el context d'ús específic (ISO/IEC 25012:2008; Mahanti, 2018). Això significa que el

nivell de precisió requerit varia en funció de les necessitats del context, consegüentment és necessari definir prèviament quin és el grau de detall per a cada atribut segons l'ús que se'n faci. Convé destacar, però, que en matemàtiques la precisió es concep i s'utilitza quan es realitzen diverses mesures —en les mateixes condicions— d'una magnitud determinada, i es calcula la dispersió de cada una de les mesures en relació amb el valor exacte a fi de trobar el grau de precisió. En aquest sentit, a menor variació dels resultats, major precisió. No obstant, en el marc d'aquest projecte la precisió es relaciona amb el concepte de xifres significatives, és a dir, amb el número de xifres que retorna un resultat, que no ha de ser menys xifres de les necessàries a fi de que no es perdi informació, però tampoc més xifres de les significatives per a que la informació no resulti supèrflua. Per tant, a l'àmbit d'aquest estudi una baixa precisió ho pot ser tant per excés com per defecte. Aquest concepte de xifres significatives es troba vinculat a l'arrodoniment de números, doncs es tracta del procés mitjançant el qual s'aconsegueix el resultat amb el número de xifres significatives necessàries.

Pel que fa a la forma de càlcul, de les investigacions consultades que enumeren la precisió (*vid. Taula 8*) només la ISO/IEC 25012:2008 estableix una funció de mesura (A/B^{96}). Altrament, aquesta fórmula no serveix per a valorar si les dades que es presenten, com a resultat d'una operació, contenen les xifres significatives indispensables; raó per la qual, es proposa la següent forma de càlcul:

- Puntuació màxima: 1 punt
 - » Els valors numèrics, resultat d'una operació, contenen les xifres significatives imprescindibles? [Tipus booleà: No-0; Sí-1]
- Fórmula: aplicació de les regles per a determinar el número de xifres significatives i també de les regles d'operació de les xifres significatives. Posteriorment aplicació de les regles d'arrodoniment.
- Fórmules alternatives: N/A

96 En aquesta forma de càlcul, A és el número de valors amb la precisió requerida, i B és el número total de valors. La divisió d'A entre B dona com a resultat un percentatge de precisió entre 0 i 1, on 0 es baixa precisió i 1 és alta precisió.

- Observacions: aquest element es mesura en dades numèriques resultat d'una o varies operacions. Per a poder avaluar si s'apliquen correctament les regles de determinació i d'operació de les xifres significatives és necessari conèixer la forma de càlcul i les dades d'origen a partir de les quals s'ha obtingut el resultat. Així mateix, per a poder avaluar l'aplicació de les regles d'arrodoniment s'ha de saber el resultat obtingut de les operacions aritmètiques.
- Exemple: una bona mostra és el dataset de places d'atenció a la gent gran amb dependència o risc social: residències, en el qual hi ha l'atribut taxa cobertura finançament públic que són les places amb finançament públic per cada 100 habitants de 65 anys i més. La fórmula de càlcul és la següent: (Places finançament públic / Població de 65 anys i més) x 100. Al revisar la columna es veu que els números resultat de les operacions consten de 15 xifres, per exemple en el primer registre el valor és 1,13636363636364. Com es disposa de les dades origen (atributs places públiques i població de 65 anys i més) a partir de les quals s'obté

aquest valor, es procedeix a realitzar l'operació i a aplicar les regles de les xifres significatives:

- » $(91 / 8008) \times 100 = \underline{1,13636363636364}$
- » La regla d'operació de les multiplicacions, divisions i exponents diu que «*el resultado obtenido mediante la operación de multiplicación, división y exponentes, sean estos $x^{\pm n}$ enteros o fraccionarios $x^{\pm 1/n}$, debe corresponder con el número de cifras significativas de aquel valor que contenga el menor número de cifras significativas*» (UNAM⁹⁷, s.d) És a dir, el resultat final s'ha d'arrodonir de forma que contingui el mateix número de xifres significatives que la dada d'origen que posseeixi el menor número de xifres significatives. Per a l'exemple exposat trobem que:
 - 91 té 2 xifres significatives.
 - 8008 té 4 xifres significatives.
 - 100 té 3 xifres significatives.

Així doncs, el resultat final hauria de contenir dues xifres, no 15.

97 Per a més informació es remet a la pàgina de la [Universidad Nacional Autónoma de México \(UNAM\) Facultad de química](#)

» Posteriorment cal aplicar la regla d'arrodoniment cap a baix que senyala que «*si el dígito siguiente al último lugar retenido es 0, 1, 2, 3 o 4 (seguido o no por otros dígitos), “consérvese” el valor del dígito situado en el último lugar retenido.*» (UNAM, s.d)

- Arrodoniment a dos xifres significatives: 1,13636363636364 s'arrodoneix a 1,1.

A partir de l'aplicació de les regles trobem que els valors numèrics, resultat d'una operació, no contenen les xifres significatives imprescindibles. Per tant, la puntuació és 0 (baixa precisió).

c. Granularitat. Aquest element mesura el nivell de detall amb el que s'emmagatzemen les dades. A diferència de l'anterior propietat, el que s'avalua és el nivell d'exhaustivitat de les dades emmagatzemades (per exemple, si el registre es realitza diàriament, mensualment, anualment, etc.), i consegüentment les possibilitats analítiques que s'hi deriven. Així doncs, les dades obertes han d'estar disponibles amb el nivell de granularitat o detall més fi possible; altrament, per a considerar que les dades presenten una

granularitat fina o una alta exhaustivitat, aquestes no han de ser dades agregades ni modificades (*Open Election Data Initiative*⁹⁸, principi 2, s.d). És important destacar que el nivell de granularitat amb el qual s'emmagatzemen les dades depèn de les necessitats de negoci i de l'ús que se'n faci de les mateixes.

Pel que fa a la forma de càlcul d'aquesta propietat no s'ha trobat referència a mètriques i indicadors en la literatura consultada, raó per la qual es presenta la següent proposta:

- Puntuació màxima: 1 punt
 - » A Les dades publicades són agregades o primàries? [Tipus booleà: 0 – Agregades; 1 – Primàries]
 - » B En cas de tractar-se de dades primàries, l'interval temporal amb el qual es registren les dades (diari, setmanal, quinzenal, anual, altres) és adequat per abordar la situació analitzada? [Tipus booleà: 0 – No; 1 – Sí]

98 Per a més informació es remet <https://openelectiondata.net/es/guide/principles/granular/>

- » C La granularitat i segmentació de les dades és correcta ja que facilita informació útil i valuosa (és a dir, es tenen en compte les variables que intervenen en el fenomen, objecte, etc., que es descriu, i la granularitat no falla ni per defecte ni per excés⁹⁹)? [Tipus booleà: 0 – No; 1 – Sí]
- Fórmula: $(A + B + C) / 3$
- Fórmules alternatives: N/A
- Observacions: aquesta propietat es relaciona amb l'element ODQ primigènia. El resultat final va de 0 a 1, on 0 significa una baixa granularitat i 1 implica alta granularitat (granularitat fina).
- Exemple: per a il·lustrar la forma de càlcul considerem el dataset Registre de casos de COVID-19 a Catalunya per municipi i sexe, el qual presenta les següents columnes: data, codi de comarca, comarca, codi de municipi, municipi, codi de districte, districte, codi de sexe, sexe, resultat, i nombre de casos. A més, la seva freqüència d'actualització és diària. Un cop realitzades aquestes consideracions, l'aplicació de la fórmula de càlcul seria la següent:
 - » A – 1 [Les dades que es presenten són primàries i facilitades pel Departament de Salut].
 - » B – 1 [La freqüència d'actualització és diària, el que permet disposar d'un registre diari dels casos de COVID-19 a Catalunya].
 - » C – 1 [El nivell de segmentació de les dades és adequat, doncs permet realitzar anàlisis per comarca, municipi, districte —per exemple, en el cas de Barcelona—, per sexe i per agregació de dates. Aquest nivell de detall amplia les possibilitats analítiques].

A continuació, s'aplica la fórmula per a calcular el nivell o ràtio de granularitat:

 - » $(1 + 1 + 1) / 3 = 3 / 3 = 1$

Del resultat anterior es conclou que el dataset Registre de casos de COVID-19 a Catalunya per municipi i sexe presenta un nivell de granularitat alt, i, a més, és adequat a les necessitats i al seu context d'ús.

99 L'excés de granularitat és causa de soroll informatiu al retornar dades que presenten informació innecessària el que dificulta comprendre l'entitat, fenomen, etc., que es descriu, així com les possibilitats analítiques de les mateixes.

d. Rellevància. Aquest element mesura que tant el contingut com la cobertura de les dades són rellevants per a les finalitats per a les quals s'utilitzen i, a més, tenen en compte les necessitats actuals i futures (Mahanti, 2018). D'aquesta descripció s'inferix que per avaluar aquesta propietat és necessari mesurar, primer, l'abast de les dades i, en segon lloc, la rellevància del contingut. El resultat d'ambdues mesures ofereix una visió de conjunt de les dades analitzades. A continuació es detalla la forma de càlcul per aquest element (Mahanti, 2018):

- Puntuació màxima: 100%

» El resultat final és percentual.

- Fórmula:

» Cobertura de les dades % = $(\text{Nombre de registres de la població actual definits per l'abast} \times 100) / (\text{Nombre de registres estimats no disponibles de la població d'interès} + \text{Nombre de registres de la població actual definits per l'abast})^{100}$.

» Rellevància de les dades % = $(\text{Nombre d'elements de dades rellevants} / \text{Nombre total d'elements de dades necessaris per a la finalitat prevista}) \times 100$

- Fórmules alternatives: N/A

- Observacions: per a poder aplicar la fórmula cobertura de les dades % s'ha de determinar l'abast de les dades, a partir de la documentació de les fonts, a fi de poder conèixer la proporció de les dades d'interès emmagatzemades en relació amb l'univers potencial de dades totals. Així mateix, per a poder aplicar la fórmula rellevància de les dades % s'ha de formular prèviament regles de negoci que determinin quins són els atributs necessaris per al propòsit previst, i posteriorment mapejar aquests atributs al conjunt de dades a analitzar (Mahanti, 2018).

- Exemple: per a il·lustrar-ho considerem una base de dades d'alumnes matriculats per ensenyament i centre a una universitat determinada. Aquesta taula conté els següents atributs: curs, any, codi centre, denominació

¹⁰⁰ Es considera que aquesta fórmula es podria simplificar, atès que el (nombre de registres estimats no disponibles de la població d'interès + nombre de registres de la població actual definits per l'abast) representa el nombre total de registres de la població d'interès.

centre, codi estudis, denominació estudis, temàtica, matrícula total, matrícula dones i matrícula homes. Des de cada secretaria de centre s'introdueixen les dades corresponents als alumnes matriculats en ensenyaments d'aquell centre; així mateix, es poden consultar i extreure dades filtrant per centre i estudis. Imaginem que al filtrar per facultat de filosofia i lletres, la base de dades retorna 302 registres d'alumnes matriculats d'un total de 18.979 registres. Amb aquestes dades es pot calcular la cobertura de la taula d'alumnes matriculats per ensenyament a la facultat de filosofia i lletres en comparació amb tot l'univers d'alumnes matriculats:

$$\begin{aligned} \gg (302 \times 100) / (18.677 + 302) &= 30.200 / 18.979 \\ &= 1,59 \end{aligned}$$

La mostra d'alumnes matriculats a algun estudi de la facultat de filosofia i lletres representa l'1,59 % de tots els alumnes matriculats en la totalitat de centres.

En quant a la rellevància del contingut, primer s'ha de considerar quins són els paràmetres establerts en funció de les necessitats i el

context d'ús. En aquest sentit, a fi de poder avaluar i realitzar estadístiques sobre l'ensenyament universitari els paràmetres requerits són ensenyament, centre, sexe i alumnes matriculats. Vist això, el següent pas és mapejar aquests paràmetres amb els atributs de la base de dades d'alumnes matriculats per ensenyament i centre a una universitat determinada:

- » L'ensenyament es deriva dels atributs codi estudis i denominació estudis.
- » El centre s'obté dels atributs codi centre i denominació centre.
- » El sexe se'n deriva de les columnes matrícula dones i matrícula homes.
- » Els alumnes matriculats s'obtenen de l'atribut matrícula total (que és el sumatori dels atributs matrícula dones i matrícula homes).

Del mapeig anterior s'infereix que el nombre d'elements rellevants és el mateix que el nombre total d'elements de dades necessaris per a la finalitat prevista, atès que tots els paràmetres essencials tenen la seva correspondència

en algun atribut del dataset¹⁰¹. A continuació s'aplica la fórmula corresponent a la rellevància de les dades:

$$\gg (4 / 4) \times 100 = 1 \times 100 = 100$$

Finalment, un cop aplicada la fórmula veiem que la rellevància del contingut és del 100 % ja que conté tots els paràmetres requerits segons les necessitats i finalitats plantejades.

3. Dimensió Integritat

a. Traçabilitat. Aquest element mesura la capacitat de fer el seguiment de les dades fins als seus orígens, així com la seva incorporació, moviment, ús i modificació dins un sistema específic. Per tant, la traçabilitat és la capacitat de conèixer tot el cicle de vida de les dades. Aquesta propietat es pot mesurar determinant si la informació necessària per a rastrejar les dades fins a la seva font està present (Mahanti, 2018). Al respecte, l'anàlisi de les metadades així com l'existència de determinats atributs (per exemple, l'identificador del sistema d'origen) ens

permeten avaluar si hi ha pistes suficients per a fer el seguiment de les dades. Convé destacar que a la literatura revisada (*vid. Taula 8*) no s'han trobat mètriques ni indicadors per mesurar aquest element ODQ; no obstant, Mahanti (2018) assenyala una sèrie de paràmetres a tenir en consideració a fi d'avaluar si la informació necessària hi és present. A continuació, es proposa una forma de càlcul a partir dels paràmetres indicats per Mahanti (2018), tot i que també s'han incorporat nous elements.

- Puntuació màxima: 1 punt
 - » A Les metadades i/o determinats atributs permeten conèixer i fer el seguiment a la font de dades originària? [Tipus booleà: 0 – No; 1 – Sí]
 - » B Les metadades i/o determinats atributs permeten conèixer i fer seguiment a la font de dades ascendent immediata? [Tipus booleà: 0 – No; 1 – Sí]

¹⁰¹ En aquest cas pràctic s'ha verificat la correspondència de les regles de negoci establertes en relació amb els atributs del dataset, és a dir, només s'ha comprovat que el paràmetre té alguna correspondència sense anotar quantes en total. Aquesta és la raó per la qual el nombre d'elements de dades rellevants ascendeix a 4, i no a 7. Tal com està plantejada la fórmula, si s'anotessin totes les equivalències el percentatge final superaria el 100%; així doncs, a fi de mantenir la puntuació màxima només es verifica si hi ha equivalències independentment de que sigui 1 – 1 o 1 – 2.

- » C Les metadades i/o determinats atributs permeten conèixer i fer seguiment de la data i hora de creació? [Tres valors: 0 – No; 0,50 – Sí, però només de la data / només de l’hora; 1 – Sí, tant de la data com de l’hora]
 - » D Les metadades i/o determinats atributs permeten conèixer i fer seguiment de la data i hora de modificació de les dades? [Tres valors: 0 – No; 0,50 – Sí, però només de la data / només de l’hora; 1 – Sí, tant de la data com de l’hora]
 - » E Quin és el mètode d’actualització de les dades?¹⁰² [Quatre valors: 0 – Les dades no s’actualitzen ja que són dades estàtiques; 0,50 – Les dades de l’arxiu que es carrega substitueixen les existents (*replace*); 0,75 – Les dades de l’arxiu que es carrega s’afegeixen com a fileres noves a la part inferior del conjunt de dades (*update*); 1 – És una combinació de les dues anteriors: els registres existents s’actualitzen i els nous s’afegeixen¹⁰³ (*upsert*)]
 - » F Hi ha un alt grau de processos manuals fora de l’arquitectura de sistemes de l’organització? [Quatre valors: 0 – 75 % o més; 0,25 - de 50% a 74%; 0,50 – de 25% a 49%; 1 – Menys de 25%]
- Fórmula: $(A + B + C + D + E + F) / 6$
 - Fórmules alternatives: N/A
 - Observacions: la puntuació va de 0 a 1, on 0 significa una baixa traçabilitat i 1 implica una alta traçabilitat.
 - Exemple: per a il·lustrar-ho considerem el dataset oferta educativa dels estudis obligatoris. Després de revisar tant els atributs com les metadades del dataset, es procedeix a respondre al qüestionari:

¹⁰² Amb aquesta pregunta es vol conèixer si les dades es substitueixen o es manté l’històric de les mateixes (cas dels mètodes d’actualització *update* i *upsert*). Aquesta qüestió és important per a les sèries temporals que són definides com una «colección de observaciones de una variable realizada de forma secuencial en el tiempo. (...) Los valores de una serie temporal van ligados a instantes de tiempo, de manera que el análisis de una serie implica el manejo conjunto de dos variables; la variable de estudio propiamente dicha y la variable tiempo.» (Esparza, s.d, 2). Dit d’una altra forma, es tracta d’una seqüència de dades, que es pot presentar en un únic recurs ordenat cronològicament o en datasets separats, els valors de la qual s’han recollit en diferents moments de temps el que determina la periodicitat de la sèrie temporal.

¹⁰³ Tal com s’indica a la guia d’empenament de les metadades del conjunt de dades per a la tramesa de dades obertes al Portal de dades obertes de la Generalitat de Catalunya, el tipus d’actualització *upsert* requereix que el conjunt de dades tingui un identificador únic de filera (2020, 25).

- » A – 1 [Les metadades indiquen que les dades estan proveïdes pel Departament d'Educació].
- » B – 0 [No hi ha metadades relacionades amb el moviment de dades entre sistemes].
- » C – 0,50 [Només s'indica data de creació].
- » D – 0,50 [S'indica la data d'actualització de les dades].
- » E – 0,50 [La taula només conté la informació relativa al curs 2021/2022 i es tracta d'un dataset amb una freqüència d'actualització anual; la qual cosa implica que el tipus d'actualització és per substitució].
- » F – 0,50¹⁰⁴ [El percentatge de processos manuals fora de l'arquitectura de sistemes comprèn del 25% al 49%].

A partir dels resultats anteriors s'aplica la següent fórmula:

$$\text{» } (1 + 0 + 0,50 + 0,50 + 0,50 + 0,50) / 6 = 3 / 5 = 0,60$$

El resultat final és que la traçabilitat del conjunt de dades oferta educativa dels estudis obligatoris obté una puntuació de 0,60 sobre 1, ja que no està present tota la informació necessària per a fer el seguiment de les dades.

- b. Completesa.** Aquest element mesura l'absència o no de dades en relació amb la totalitat. Per a procedir amb l'avaluació és necessari definir, prèviament, que s'entén per valors perduts, per exemple, valors nuls, en blanc, etc. Així mateix la completesa es pot mesurar en tres nivells: nivell dada o valor (*data element*), nivell registre o fila (*data record*) i nivell del conjunt de dades (*data set*).

A continuació es detalla la forma de càlcul per a cada un dels nivells (Mahanti, 2018):

Nivell dada o valor dins un conjunt de dades (*data element*):

- Puntuació màxima: 100%

- » El resultat final és percentual.

104 Aquest resultat és fictici, només s'ha indicat a efectes de poder mostrar com funciona la mètrica a l'exemple escollit.

- Fórmula:
 - » $\text{Completesa \%} = \left(\frac{\text{Nombre total de valors que s'han de completar per a cada dada} - \text{Nombre total de valors nuls} - \text{Nombre total d'espais} - \text{Nombre total de valors en blanc}}{\text{Nombre total de valors que s'han de completar per a cada dada}} \right) \times 100$
- Fórmules alternatives: N/A
- Observacions: La mesura es realitza sobre aquelles dades considerades crítiques, tot i que opcionalment també es pot efectuar sobre la totalitat dels atributs. Pel que fa a la fórmula, cal senyalar que el nombre total de valors que s'han de completar per a cada atribut representa el 100% de completesa. (Mahanti, 2018). Així mateix el 100% de completesa d'un valor generalment equival al nombre de registres del conjunt de dades sota mesura.
- Exemple: per a il·lustrar-ho considerem el dataset ajuts extraordinaris per al manteniment de l'activitat econòmica de persones autònomes i microempreses enfront la COVID-19 (2021), en el qual s'informen dels atributs NIF sol·licitant, nom sol·licitant i estat. Tots tres atributs són

crítics. El primer atribut, NIF sol·licitant, té 170.073 valors doncs el dataset està format per 170.073 registres. Si avaluem els valors d'aquest atribut veiem que no hi ha valors nuls, ni en blanc, ni tampoc espais. Un cop vistes aquestes dades procedim a aplicar la fórmula:

$$\begin{aligned} & \gg \left(\frac{170.073 - 0 - 0 - 0}{170.073} \right) \times 100 = \\ & \left(\frac{170.073}{170.073} \right) \times 100 = 1 \times 100 = 100 \end{aligned}$$

Del resultat anterior es conclou que la completesa de l'atribut NIF sol·licitant és del 100%. Finalment aquesta operació s'hauria de repetir amb els atributs restants.

Nivell de registre o files de dades (*data record*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.
- Fórmula:
 - » $\text{Completesa del registre \%} = \left(\frac{\text{Nombre de registres que contenen valors crítics no perduts} \times 100}{\text{Nombre total de registres que contenen valors crítics}} \right)$

- Fórmules alternatives: (per a calcular el percentatge total de registres que contenen valors crítics¹⁰⁵)
 - » Nombre total de registre % = ((Nombre de registres que contenen valors crítics – Nombre de registres que no contenen valors crítics) x 100) / Nombre de registres que contenen valors crítics.
 - » Incompletesa del registre %¹⁰⁶ = (Nombre de registres que contenen valors crítics perduts x 100) / Nombre total de registres que contenen valors crítics.
- Observacions: la mesura es realitza sobre aquells registres que contenen valors crítics. Així mateix, un registre es considera incomplet si conté un o més valors perduts (Mahanti, 2018).
- Exemple: es pot exemplificar amb el dataset ajuts extraordinaris per al manteniment de l'activitat econòmica de persones autònomes i microempreses enfront la COVID-19 (2021), el qual presenta tres atributs crítics: NIF sol·licitant, nom sol·licitant i estat. La taula conté

170.073 registres, i com tots els atributs són crítics el còmput total de registres que contenen valors crítics continua sent 170.073. Imaginem que per l'atribut estat hi ha 234 cel·les que contenen valors en blanc, per tant hi ha 234 registres que contenen valors crítics perduts, i 169.839 registres que contenen valors crítics no perduts. A continuació, s'aplica la fórmula:

$$\gg (169.839 \times 100) / 170.073 = 16.983.900 / 170.073 = 99,86$$

Del resultat anterior s'infereix que la completesa dels registres és del 99,86 %.

Nivell del conjunt de dades (*data set*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.
- Fórmula:
 - » Completesa del dataset % = (Nombre de registres presents en el dataset x 100) / Nombre de registres del dataset de referència.

¹⁰⁵ Convé destacar que la fórmula alternativa és considerada per Mahanti (2018) com una formulació per a calcular la completesa del registre; no obstant, després de valorar la fórmula es considera que aquesta no serveix per a mesurar la completesa, sinó que el resultat que retorna és el percentatge de registres que contenen valors crítics en relació amb el total de registres.

¹⁰⁶ Aquesta fórmula alternativa és una proposta per aquest treball d'investigació, ja que a l'estudi de Mahanti (2018) no es planteja.

- Fórmules alternatives: N/A
- Observacions: aquest nivell avalua la mostra d'anàlisi amb el dataset al qual fa referència, a fi de comprovar que el dataset d'anàlisi conté tots els registres que apareixen a la mostra inicial.
- Exemple: el dataset ajuts extraordinaris per al manteniment de l'activitat econòmica de persones autònomes i microempreses enfront la COVID-19 (2021) té una freqüència variable. Imaginem que el dataset publicat al portal de dades obertes de la Generalitat conté 170.073, actualitzat a data 10 de maig de 2021. No obstant, a data 10 de juny de 2021 hi ha 50 registres més en el dataset de referència, però encara no s'ha actualitzat el dataset del portal de dades obertes i, per tant, no contempla aquests nous registres. Amb aquestes dades apliquem la fórmula corresponent:

$$\gg (170.073 \times 100) / 170.123 = 17.007.300 / 170.123 = 99,97$$

Del resultat anterior es conclou que el dataset publicat al portal de dades obertes de la Generalitat està complet al 99,97% en relació amb el dataset de referència.

c. Consistència. Aquest element mesura que les dades són equivalents o idèntiques entre diferents fonts o sistemes. Convé destacar que aquesta propietat es relaciona amb l'element ODQ exactitud, ja que si els valors no són consistents indica que almenys un valor no és exacte o vàlid. No obstant, si els valors són consistents no necessàriament implica que els valors són exactes o vàlids (Mahanti, 2018). Aquesta propietat es mesura en quatre nivells:

- Nivell de combinació de dades o valors dins una mateixa taula.
- Nivell de registre o files de dades dins un mateix dataset.
- Nivell de registres creuats.
- Nivell del conjunt de dades.

A continuació es detalla la forma de càlcul per a cada un dels nivells (Mahanti, 2018):

Nivell de combinació de dades o valors (*data element consistency*):

- Puntuació màxima: 100%

» El resultat final és percentual.

- Fórmula:
 - » Consistència % = (Nombre de combinacions de valors consistents en un mateix dataset x 100) / Nombre total de combinacions de valors en un mateix dataset.
- Fórmules alternatives:
 - » Consistència % = ((Nombre total de combinacions de valors en un mateix dataset - Nombre de combinacions de valors inconsistents en un mateix dataset) x 100) / Nombre total de combinacions de valors en un mateix dataset.
 - » Inconsistència % = ((Nombre de combinacions de valors inconsistents en un mateix dataset) x 100) / Nombre total de combinacions de valors en un mateix dataset.
- Observacions: per a mesurar aquest nivell és important identificar prèviament aquells valors dins un mateix dataset que es combinen i que necessàriament han de ser consistents entre ells. Un cop identificats aquests valors, s'han de consultar les regles de consistència elaborades per a cada combinació d'atributs.

El còmput del nombre total de combinacions de valors en un mateix dataset coincideix amb el còmput de registres, ja que cada valor s'informa en cadascuna de les files.

- Exemple: per a il·lustrar-ho considerem un dataset sobre personal docent investigador (PDI) a les universitats catalanes, on els atributs dels que s'informa són any, tipus d'universitat, universitat, tipus de centre, codi nacionalitat, descripció nacionalitat, codi sexe i descripció sexe. D'aquests atributs trobem que codi sexe i descripció sexe es combinen i han de ser consistents entre ells, ja que el que s'especifiqui en el codi sexe (0-home, 1-dona) ha de coincidir amb el que s'informi a la columna descripció sexe. Aquest dataset conté 438 registres; per tant, el nombre de combinacions de valors és 438. D'aquests 438 trobem que hi ha 5 que són inconsistents, mentre que 433 combinacions són consistents. Amb aquestes dades apliquem la corresponent fórmula:

$$\text{» } (433 \times 100) / 438 = 43.300 / 438 = 98,86$$

Del resultat anterior es conclou que la consistència entre la combinació dels atributs codi sexe i descripció sexe és del 98,86 %.

Aquesta operació es repetiria amb cadascuna de les combinacions de valors existents, que en el cas de la mostra també seria codi nacionalitat i descripció nacionalitat.

Nivell de registre o files de dades (*record consistency*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.
- Fórmula:
 - » $\text{Consistència del registre \%} = (\text{Nombre de registres consistents en el dataset} \times 100) / \text{Nombre total de registres en el dataset.}$
- Fórmules alternatives:
 - » $\text{Consistència del registre \%} = ((\text{Nombre total de registres en el dataset} - \text{Nombre de registres inconsistents en el dataset}) \times 100) / \text{Nombre total de registres en el dataset.}$
 - » $\text{Inconsistència del registre \%} = ((\text{Nombre de registres inconsistents en el dataset}) \times 100) / \text{Nombre total de registres en el dataset.}$

- Observacions: un registre es considera inconsistent si conté una o més combinacions de valors que no són consistents.

- Exemple: per a exemplificar-ho considerem el dataset sobre personal docent investigador (PDI) a les universitats catalanes vist amb anterioritat. El dataset conté 438 registres, i dues combinacions de valors que són codi sexe i descripció sexe, i codi nacionalitat i descripció nacionalitat. D'aquestes combinacions, trobem que la primera té 5 inconsistències i 433 consistències, mentre que la segona combinació té 30 inconsistències i 408 consistències. En conjunt, el dataset té 35 registres inconsistents i 403 consistents. A partir d'aquestes dades s'aplica la fórmula corresponent:

$$\text{» } (403 \times 100) / 438 = 40.300 / 438 = 92,01$$

Del resultat anterior s'infereix que la consistència de registre és del 92,01 %.

Nivell de registres creuats (*cross-record consistency*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.

- Fórmula:
 - » Consistència de registres creuats % = $(\text{Nombre de registres consistents en el dataset} \times 100) / (\text{Nombre de registres consistents en el dataset} + \text{Nombre de registres inconsistents en el dataset})^{107}$
- Fórmules alternatives:
 - » Consistència de registres creuats % = $((\text{Nombre de registres en el dataset} - \text{Nombre de registres inconsistents en el dataset}) \times 100) / (\text{Nombre de registres consistents en el dataset} + \text{Nombre de registres inconsistents en el dataset})^{108}$
 - » Inconsistència de registres creuats % = $(\text{Nombre de registres inconsistents en el dataset} \times 100) / (\text{Nombre de registres consistents en el dataset} + \text{Nombre de registres inconsistents en el dataset})^{109}$
- Observacions: es tracta de la consistència entre registres de diferents datasets. Per avaluar

aquest nivell és important identificar prèviament els diferents datasets i les combinacions de valors crítics que han de ser consistents, els paràmetres que regeixen aquestes combinacions, el nombre de registres creuats amb combinacions de valors crítics i d'entre aquests registres, quants són consistents i quants inconsistents. Així mateix, es considera que els registres són inconsistents quan una o més combinacions de valors no són consistents (Mahanti, 2018).

- Exemple: un cas pràctic el trobem en els datasets Personal docent investigador (PDI) a les universitats catalanes i Avaluació recerca del personal docent investigador (PDI). En el primer dataset els atributs que s'informen són any, tipus d'universitat, universitat, tipus de centre, codi nacionalitat, descripció nacionalitat, codi sexe i descripció sexe; mentre que en el segon dataset les columnes són any, tipus d'universitat, universitat, nombre acreditats PDI, tipus acreditació i trams. Entre aquests dos conjunts de dades, els atributs considerats crítics i que es combinen són any, tipus

107 Mahanti (2018) proposa aquesta fórmula. Tanmateix, a efectes pràctics el resultat és el mateix si la fórmula es canvia per $(\text{Nombre de registres consistents en el dataset} \times 100) / \text{Nombre total de registres creuats en els datasets}$.

108 L'expressió $(\text{Nombre de registres consistents en el dataset} + \text{Nombre de registres inconsistents en el dataset})$ es podria canviar per Nombre total de registres creuats en els datasets.

109 Ídem.

d'universitat i universitat. Entre els atributs creuats dels dos datasets les regles que s'han de complir són les següents:

- » Els valors de l'atribut any del dataset Avaluació recerca personal docent investigador (PDI) no poden ser anteriors als valors de l'atribut any del dataset Personal docent investigador (PDI) a les universitats catalanes.
- » Els valors de l'atribut tipus d'universitat han de coincidir en els dos datasets.
- » Els valors de l'atribut universitat han de coincidir en els dos datasets.

Altrament el primer dataset conté 438 registres, mentre que el segon té 335 registres. Per tant, el total de registres creuats que contenen combinacions de valors crítics ascendeix a 335. D'aquests registres veiem que per a l'atribut any hi ha 50 combinacions de valors inconsistents, per a tipus d'universitat n'hi ha dues inconsistències (una inconsistència es troba en el mateix registre on també hi ha una inconsistència de l'atribut any) i per a universitat també hi ha dues inconsistències (una es troba en el mateix registre on també hi ha una inconsistència de l'atribut any). Amb tot, trobem

que el total de registres creuats inconsistents ascendeix a 52, per tant els registres creuats consistents són 283. A partir d'aquestes dades s'aplica la fórmula per a calcular la consistència de registres creuats %:

$$\gg (283 \times 100) / (283 + 52) = 28.300 / 335 = 84,48$$

Del resultat anterior es conclou que la consistència dels registres creuats és del 84,48 %.

Nivell del conjunt de dades (*data set consistency*):

- Puntuació màxima: 100%
 - » El resultat final és percentual.
- Fórmula:
 - » Inconsistència del dataset % = Valor absolut de ((Nombre de registres a la font d'origen – Nombre de registres en el sistema de destinació – Nombre de registres rebutjats) x 100) / Nombre de registres a la font d'origen.
- Fórmules alternatives: N/A
- Observacions: aquest nivell mesura la consistència del conjunt de dades entre el sistema d'origen i el sistema de destí. En aquest sentit,

les inconsistències del dataset es produeixen perquè durant la càrrega s'ha produït un error i la taula només s'ha carregat parcialment o bé no s'ha produït la recàrrega des de l'últim punt de control, cosa que fa que les dades del sistema de destinació siguin incompatibles amb la font (Mahanti, 2018).

- Exemple: en el cas del dataset de Personal docent investigador (PDI) a les universitats catalanes, trobem que la informació és proveïda per la Secretaria d'Universitats i recerca, i que la freqüència d'actualització és anual. Per aquest cas pràctic, considerem que a data 7 de juliol de 2021 el dataset es va actualitzar amb la incorporació de 30 registres nous (del període comprés entre 7 de juliol de 2020 a 6 de juliol de 2021). A fi de mesurar la consistència del dataset s'ha de comparar el nombre de registres del dataset publicat per al període mencionat, amb el nombre de registres per al mateix període a la font proveïdora de les dades (per aquest cas considerem que la font origen coincideix amb el departament que proveeix). En el sistema d'origen el nombre de registres nous per al període comprés entre 7 de juliol de 2020 a 6 de juliol de 2021 és de 31; altrament durant la càrrega del dataset per a la seva publicació un registre ha sigut rebutjat

degut a que un dels camps no coincidia amb les regles establertes. A partir d'aquestes dades s'aplica la següent fórmula per a calcular la inconsistència del dataset:

$$\gg \text{Valor absolut de } ((30 - 31 - 1) \times 100) / 31 = (-2 \times 100) / 31 = (2 \times 100) / 31 = 200 / 31 = 6,45$$

Del resultat anterior es conclou que el percentatge d'inconsistència del dataset Personal docent investigador (PDI) a les universitats catalanes en relació amb les dades que es troben al sistema origen és del 6,45 %. El que significa que hi ha una consistència del 93,55 %.

4. Dimensió Usabilitat

- Llegibilitat/Interpretabilitat.** Aquest element mesura el grau en què les dades són codificades per a ser llegibles i interpretables per màquina. Per avaluar aquesta propietat es presenta una proposta basada en un conjunt de preguntes, la resposta de la majoria de les quals és de tipus booleà. Convé destacar que la forma de càlcul que a continuació es detalla segueix l'esquema plantejat per Mahanti (2018); no obstant, les qüestions plantejades s'han modificat i adequat al context de les dades obertes.

- Puntuació màxima: 1 punt
 - » A Existeix informació codificada basada en vocabularis controlats, tesaurus i llistes de codis? [Tipus booleà: 0 – No; 1 – Sí]
 - » B La notació de les dates i l'hora segueixen estàndards específics, com la norma ISO 8601? [Tres respostes: 0 – No; 0,50 – Sí, només la data/només l'hora; 1 – Sí, tant la data com l'hora].
 - » C Les dades es troben estructurades en formats processables per màquina? [Tipus booleà: 0 – No; 1 – Sí].
 - » D Hi ha metadades assignades a nivell de catàleg, dataset, distribució i columna? [Cinc respostes: 0 – No hi ha metadades assignades a cap nivell; 0,25 – Hi ha metadades assignades a un nivell; 0,50 – Hi ha metadades assignades a dos nivells; 0,75 – Hi ha metadades assignades a tres nivells; 1 – Hi ha metadades assignades en els quatre nivells]
 - » E S'utilitzen metadades definides en vocabularis controlats, com el DCAT (estatal), DCAT-AP (europeu) o la guia de metadades de la Generalitat? [Cinc respostes: 0 – No; 0,25 – Sí, s'utilitza un model propi; 0,50 – Sí, s'utilitza un model local; 0,75 – Sí, s'utilitza la guia tècnica de la Generalitat de Catalunya; 1 – Sí, s'utilitza el DCAT o el DCAT-AP].
- Fórmula: $(A + B + C + D + E) / 5$
- Fórmules alternatives: N/A
- Observacions: el resultat final va de 0 a 1, on 0 significa una baixa interpretabilitat per màquina i 1 una alta interpretabilitat.
- Exemple: per a il·lustrar-ho considerem el dataset de dades meteorològiques de la XEMA, el qual presenta els següents atributs: identificació, codi estació, codi variable, data lectura, data extrem, valor lectura, codi estat i codi base. Un cop valorada la informació relativa a com s'informen les columnes del conjunt de dades i també revisades les metadades del dataset, es procedeix a respondre el qüestionari:
 - » A – 1 [Els atributs codi estació, codi variable, codi estat i codi base es fonamenten en sistemes de codificació normalitzats. Per exemple, en el cas del codi estat, el valor del procés de validació només pot ser un dels contemplats a la llista de codis establerta: espai en blanc (la dada no ha

iniciat el procés de validació), T (el procés de validació s'ha iniciat, però no ha finalitzat) o V (dada vàlida)].

- » B – 0,50 [L'hora es facilita en Temps Universal – T.U, és a dir, es representa en el format de 24 hores].
- » C – 1 [Les dades es poden exportar en CSV, RDF, RSS, TSV i XML].
- » D – 0,50 [Hi ha metadades assignades a nivell de dataset i de columna].
- » E – 0,75 [Sí, s'utilitza la guia d'implementació per a l'homogeneïtzació de les metadades del Catàleg de dades obertes de la Generalitat de Catalunya].

A partir de les respostes anteriors, ens quedaria el següent resultat:

$$\text{» } (1 + 0,50 + 1 + 0,50 + 0,75) / 5 = 3,75 / 5 = 0,75$$

Del resultat anterior es conclou que la puntuació obtinguda del nivell de llegibilitat / interpretabilitat per màquina és de 0,75 punts.

b. Comprensibilitat. Aquest element mesura el grau en què les dades són comprensibles i interpretables pels usuaris (ISO/IEC 25012:2008). La mètrica utilitzada en la citada norma no serveix ja que només mesura si existeixen metadades que faciliten la comprensió de les dades mestres; raó per la qual, es fa proposta per avaluar la comprensibilitat de les dades per part de les persones. Convé destacar, però, que la forma de càlcul és semblant a la utilitzada per altres propietats, tot i que les qüestions que es plantegen estan focalitzades a mesurar aquest element ODQ.

- Puntuació màxima: 1 punt

- » A Hi ha metadades que ofereixen informació per a facilitar la comprensió de les dades? [Tipus booleà: 0 – No; 1 – Sí].
- » B Les dades s'acompanyen de visualitzacions, mapes, glossaris i definicions, informació d'anàlisi, etc., que faciliten la comprensió de les mateixes als usuaris? [Tipus booleà: 0 – No; 1 – Sí].
- » C Hi ha interfícies que tradueixen les dades i les seves interpretacions a una representació entenedora per als usuaris? [Tipus booleà: 0 – No; 1 – Sí].

- Fórmula: $(A + B + C) / 3$
- Fórmules alternatives: N/A
- Observacions: el resultat final va de 0 a 1, on 0 significa una baixa comprensibilitat i 1 una alta comprensibilitat.
- Exemples: per a il·lustrar-ho considerem el dataset que recull les estadístiques de residus municipals de Catalunya, el qual està format per 33 columnes i cada fila és una estadística. A continuació, es procedeix a respondre el qüestionari per a valorar el grau de comprensibilitat d'aquest conjunt de dades:
 - » A – 1 [Aquest dataset té associat un conjunt de metadades que ofereixen informació en relació amb el conjunt de dades però també sobre el significat de cada una de les columnes que el conformen. Per exemple, en el cas de la columna codi municipi s'especifica que és un codi de 6 dígit utilitzat per l'Idescat per a identificar els municipis].
 - » B – 1 [Com a contingut destacat que s'associa al dataset hi ha un enllaç a la pàgina del Departament de Vicepresidència i de Polítiques Digitals i Territori per a consultar

visualitzacions interactives que permeten explorar diverses estadístiques de residus municipals en funció dels criteris de cerca].

- » C – 1 [Des del mateix portal, en concret des de l'opció “Veure les dades” es pot seleccionar veure les dades com a taula, com a llista enriquida o com a fila única. Així mateix, també es poden generar visualitzacions, filtrar i analitzar, entre altres aspectes].

A partir de les respostes anteriors, ens quedaria el següent resultat:

» $(1 + 1 + 1) / 3 = 3 / 3 = 1$

Del resultat anterior es conclou que el nivell de comprensibilitat del dataset Estadístiques de residus municipals és alt, ja que ha obtingut la puntuació màxima.

- c. **Georeferenciació.** Aquest element mesura el nivell en què les dades geogràfiques es troben associades a una georeferenciació basada en coordenades o en un altre sistema de referència, com el districte postal. Com a model, se segueix la forma de càlcul que es proposa a la norma UNE 178301:2015; no obstant, els ítems s'han modificat a fi de realitzar

l'avaluació a nivell de dataset i de metadades, i no a nivell de tots els conjunts de dades geogràfiques.

- Puntuació màxima: 3 punts

- » 0 El conjunt de dades geogràfiques no presenta cap tipus de georeferenciació, ni explícita ni implícita.
- » 1 El conjunt de dades geogràfiques no està publicat com a dades obertes georeferenciades explícitament amb coordenades, però sí es troba georeferenciat de forma implícita¹¹⁰.
- » 2 El conjunt de dades geogràfiques està publicat com a dades obertes georeferenciades amb coordenades.

- » 3 El conjunt de dades geogràfiques està publicat com a dades obertes georeferenciades amb coordenades, i s'acompanya de metadades geogràfiques.

- Fórmula: N/A

- Fórmules anteriors: N/A

- Observacions: si es vol realitzar una avaluació global de tots els conjunts de dades es remet a la proposta originària de la norma UNE 178301:2015.

En els conjunts de dades geogràfiques s'avalua l'ús de metadades geoespacionals contemplades a la norma ISO 19115¹¹¹, a INSPIRE¹¹² o a NEM¹¹³, tal com tipus de representació

¹¹⁰ Significa que s'utilitza una georeferenciació indirecta basada en un sistema de referència fonamentat en dades geogràfiques ben definides, com carrer, número, districte postal i localitat (UNE 178301:2015).

¹¹¹ La norma UNE-EN ISO 19115-1:2014. Informació geogràfica. Metadatos. Parte 1: Fundamentos, defineix un conjunt de metadades per a facilitar la localització, l'accés, l'intercanvi i l'ús de dades geogràfiques.

¹¹² La finalitat de la Directiva Europea INSPIRE (Directiva 2007/2/CE del Parlament Europeu i del Consell de 14 de març de 2007 per la qual s'estableix una infraestructura d'informació espacial a la Comunitat Europea) és establir normes generals a fi d'implementar una infraestructura d'informació espacial a la Comunitat Europea (article 1.1); d'entre els aspectes que es regulen destaca la creació i actualització de metadades en relació a un conjunt de temes, tal com sistemes de coordenades de referència, noms geogràfics, unitats administratives, etc. (article 5, annex I, II i III). Destaca també el Reglament (CE) 1205/2008 de la Comissió de 3 desembre de 2008 pel qual s'executa la Directiva 2007/2/CE del Parlament Europeu i del Consell en relació a les metadades, el qual estableix els requisits per a la creació i manteniment de metadades per a conjunts de dades espacionals (article 1).

¹¹³ El Núcleo Español de Metadatos o NEM (versió 1.2) és un perfil de la norma ISO 19115 que estableix el mínim de metadades a informar per a la descripció de recursos geogràfics. Altrament, la versió 1.2 del NEM contempla les especificacions del Reglament INSPIRE.

espacial, sistema de referència, localització geogràfica, etc. (Norma UNE 178301:2015).

- Exemple: per a il·lustrar-ho considerem el dataset Registre d'exploracions ramaderes, que conté la georeferenciació de totes les explotacions ramaderes enregistrades a Catalunya. Un cop valorat tant el dataset com les metadades associades trobem que la puntuació màxima obtinguda és 1, ja que malgrat a la metadada informació geogràfica s'indica que el sistema de referència són coordenades, en el dataset les columnes coord X, coord Y, longitud i latitud estan en blanc. Tanmateix, la columna codi postal es troba informada, raó per la qual aquest dataset té una puntuació d'1 punt ja que el sistema de referència és implícit.

d. Obertura. Aquest element mesura el grau d'obertura de les dades que es publiquen en el Portal de dades obertes. Per avaluar aquesta propietat es proposa l'esquema de desenvolupament de 5 estrelles de Tim Berners-Lee (2010), que és un sistema que permet diagnosticar el nivell d'obertura segons una escala de 5 nivells. En base a aquest esquema la forma de càlcul és la següent:

- Puntuació màxima: 5 punts

- » 1 Les dades es publiquen en el Portal de dades obertes en qualsevol format i sota una llicència oberta. En particular, les dades es troben en formats no estructurats, com documents en PDF, imatges, vídeos, etc.
- » 2 Les dades es publiquen en formats estructurats, però de software propietari. És a dir, les dades es troben en fulls de càlcul en Excel (formats .xls i .xlsx)
- » 3 Les dades es publiquen en formats estructurats que utilitzen software lliure, com OpenOffice o CSV.
- » 4 Les dades s'estructuren adequadament amb URIs que identifiquen els recursos. En aquest nivell s'utilitza l'estàndard RDF.
- » 5 Les dades, a més de complir tots els requeriments anteriors, es troben enllaçades amb altres dades semblants que han sigut publicades per altres organitzacions (*linked open data* - LOD).

- Fórmula: N/A

- Fórmules alternatives: N/A

- Observacions: cada un dels nivells superiors inclou els nivells anteriors.
 - Exemple: una bona mostra la trobem en el dataset Usuaris als camins del Parc Natural de la Muntanya de Montserrat, que està conformat per 731 files i 12 columnes. Des de la secció exporta es confirma que els formats en què es pot descarregar el dataset són CSV, CSV per a Excel, TSV per a Excel, XML, RSS i RDF. A partir d'aquesta informació la puntuació màxima per aquest dataset és 4 ja que s'utilitza l'estàndard RDF¹¹⁴.
- e. Recuperabilitat.** Aquest element mesura la capacitat del sistema per a recuperar les dades després d'una pèrdua, corrupció, eliminació o qualsevol altre incident que impossibiliti la localització i accés a les mateixes. Més concretament s'avaluen dos aspectes: d'una banda, que s'hagin pogut realitzar les còpies de seguretat enfront possibles pèrdues d'informació i, d'altra banda, en cas de pèrdua d'informació, que les dades es puguin recuperar a fi de ser llegides. A continuació es detalla la forma de càlcul per aquest element (ISO/IEC 25012:2008):
- Puntuació màxima: 1 punt
 - Fórmula: A/B^{115}
 - » A = nombre d'elements de dades recuperats correctament de la còpia de seguretat.
 - » B = nombre d'elements de dades realitzats amb còpia de seguretat.
 - Fórmules alternatives: N/A
 - Observacions: es tracta d'una propietat dependent del sistema i dels dispositius d'emmagatzemament de les dades.
 - El resultat final va de 0 a 1, on 0 significa una baixa recuperabilitat i 1 una alta recuperabilitat.
 - Exemples: per a il·lustrar-ho considerem el dataset Directori de centres docents (fins curs 2019-2020), que té 27.300 files, 63 columnes i 1.719.900 valors (*data element*). Imaginem per aquest cas pràctic que de tots els valors, s'han perdut un total de 100.234 valors, dels quals tots es troben guardats en còpies de seguretat però només s'han pogut

¹¹⁴ Convé destacar que tal com es detalla en el Portal de dades obertes de la Generalitat, tots els datasets disponibles a la plataforma de dades obertes es poden exportar en múltiples formats: CSV/TSV, JSON, XML, RSS, RDF/XML. I en el cas de datasets que contenen dades geogràfiques també es poden exportar en formats específics per a la representació de dades geogràfiques (KML/KMZ, SHP, GeoJSON i en format original).

¹¹⁵ En cas de voler fer el resultat percentual, la fórmula quedaria de la següent forma: $(A/B) \times 100$

recuperar 100.231 dades. A partir d'aquestes dades s'aplicaria la següent fórmula:

$$\gg 100.231 / 100.234 = 0,99$$

Del resultat anterior es conclou que el grau de recuperabilitat és alta ja que es situa al 0,99 (o en termes percentuals al 99,99 % de recuperabilitat).

f. Localització. Aquesta propietat mesura que tant les dades com les metadades siguin fàcilment localitzables mitjançant eines de cerca. Pel que fa a la forma de càlcul, s'han considerat els ítems proposats per Wilkinson *et al.* (2016) en relació als principis FAIR per a la publicació de dades obertes científiques, ja que es considera que aquests elements són aplicables al conjunt de dades obertes, no només a les dades científiques. Altrament, la valoració qualitativa realitzada pels autors s'ha transformat en una mesura quantitativa, tal com es detalla a continuació:

- Puntuació màxima: 1 punt

» A Tant les dades com les metadades tenen assignades un identificador únic i persistent,

és a dir, disposen d'un identificador de recurs uniforme (URI, en anglès)? [Tres respostes: 0 – Ni les dades ni les metadades disposen d'URI; 0,50 – Només les dades / Només les metadades disposen d'URI; 1 – Tant les dades com les metadades disposen d'URI].

» B Les dades estan descrites amb metadades de forma detallada¹¹⁶? [Tipus booleà: 0 – No; 1 – Sí].

» C Es registren o indexen les dades i les metadades en un recurs de cerca? [Tres respostes: 0 – Ni les dades ni les metadades estan indexades; 0,50 – Només les dades / Només les metadades estan indexades; 1 – Tant les dades com les metadades estan indexades].

» D En les metadades s'especifica l'identificador de les dades que es descriuen? [Tipus booleà: 0 – No; 1 – Sí].

- Fórmula: $(A + B + C + D) / 4$

- Fórmules alternatives: N/A

¹¹⁶ És important destacar que aquest ítem no mesura la completesa de les metadades en relació amb un vocabulari controlat. Només se centra en avaluar si les dades estan descrites de forma precisa a partir de les metadades.

- Observacions: N/A
- Exemples: per a il·lustrar-ho considerem el dataset Registre de Comunitats Catalanes a l'Exterior, que conté les dades de les comunitats catalanes a l'exterior oficialment reconegudes per la Generalitat de Catalunya i que actualment estan vigents. Després de revisar tant el dataset com les metadades associades es procedeix a respondre el qüestionari:
 - » A – 0 [Ni les dades ni les metadades tenen assignades cap URI, malgrat és obligatori segons la NTI-RISP. A la norma s'indica que qualsevol recurs publicat a la web ha de disposar d'un URI que permeti identificar-lo unívocament de la resta de recursos].
 - » B – 1 [Sí, les dades estan descrites amb metadades basades en la Guia d'implementació per a l'homogeneïtzació de les metadades del catàleg de dades obertes de la Generalitat de Catalunya].
 - » C – 0,50 [Sí, després de realitzar cerques al cercador del Portal de dades obertes de la Generalitat, es confirma que les metadades es troben indexades, per exemple els camps títol, categoria i etiquetes. Pel que

fa a les dades, s'han fet cerques amb valors del dataset, per exemple buscant per centre català de Mendoza o casal català de Montevideo, però els resultats que s'han obtingut no han sigut satisfactoris].

- » D – 0 [No, a les metadades no s'especifica l'identificador del dataset que es descriu].

A partir de les respostes anteriors, s'aplica la següent fórmula:

$$\text{» } (0 + 1 + 0,50 + 0) / 4 = 1,50 / 4 = 0,375 = 0,38$$

Del resultat anterior es confirma que el grau de localització del dataset és baix, ja que ha obtingut una puntuació total de 0,38.

- g. Eficiència.** Aquest element mesura si les solucions d'emmagatzematge de les dades aporten flexibilitat, escalabilitat i optimització del rendiment. En altres paraules, s'avalua el processament de les dades i el retorn de les mateixes —per exemple, davant cerques— amb els nivells de rendiment esperats segons el context d'ús. Pel que fa a la forma de càlcul, la norma ISO/IEC 25012:2008 estableix una funció de mesura però no s'ha considerat ja que avalua l'espai d'emmagatzemament desaprofitat; mentre que en el marc d'aquest projecte el

que es mesura és l'optimització del rendiment. En particular, la capacitat de realitzar un efecte desitjat, que en aquest cas és el retorn de les dades, en el menor temps possible. Així doncs, per al càlcul d'aquest element ODQ s'ha considerat el temps de resposta o d'interacció el qual dona una mesura d'agilitat del sistema que es pot associar a l'eficiència partint del supòsit de que un sistema més àgil és un sistema més eficient. Més concretament, s'ha pres com a model la mètrica d'eficiència desenvolupada pel Centre de Telecomunicacions i Tecnologies de la Informació (CTTI)¹¹⁷, que és la que es detalla a continuació:

- Puntuació màxima: 5 punts
 - » 1 Té una o més transaccions crítiques que superen 15 segons.
 - » 2 Té una o més transaccions crítiques que superen 4 segons.
 - » 3 Cap transacció supera 4 segons.
 - » 4 Cap transacció supera 2 segons.
 - » 5 Cap transacció supera 1 segon.

Per temps de resposta o temps de resposta d'interacció s'entén el temps mesurat (en segons per defecte) des de que l'usuari ha efectuat una acció (per exemple, una petició) fins que es reben les dades (CTTI, s.d). A més del temps de resposta de cada una de les interaccions, es proposa la següent fórmula per a calcular la mitjana de resposta de totes les peticions, on N_i ($i = 1, 2, \dots, n$) representa els segons de retorn des de la petició fins que es reben les dades per a cada una de les peticions que es realitzen:

» $(N_1 + N_2 + \dots + N_n) / \text{nombre de peticions}$

- Fórmula: N/A
- Fórmules alternatives: N/A
- Observacions: els ítems descriuen l'eficiència en quant al temps de resposta, considerant el nivell 5 com el més òptim i el nivell 1 com no acceptable.
- Exemples: per a il·lustrar-ho considerem un cas hipotètic en el que l'usuari A realitza una petició en el cercador del Portal de dades obertes de la

¹¹⁷ Per a més informació es remet a la pàgina del CTTI: <https://qualitat.solucions.gencat.cat/guies/>

Generalitat a l'introduir les paraules personal docent investigador. L'hora de la petició és a les 12h, i un segon més tard rep un resultat amb el dataset Personal Docent Investigador a les universitats catalanes. A aquella mateixa hora, l'usuari B fa una petició i introdueix cens població al cercador, dos segons més tard el Portal li retorna 8 resultats coincidents amb les paraules introduïdes. A partir d'aquestes dades, la puntuació obtinguda és 4 ja que el temps de retorn de les dues peticions no supera els 2 segons.

A continuació, s'aplica la fórmula per a calcular la mitjana del temps de resposta:

$$\gg (1 + 2) / 2 = 3 / 2 = 1,5$$

Del resultat anterior es conclou que la mitjana del temps de resposta és 1,5 segons; per tant, es confirma la puntuació obtinguda doncs no es supera els 2 segons.

h. Comparabilitat. Aquest element avalua el nivell de comparabilitat i interoperabilitat de les dades publicades. Per a la seva mesura s'ha optat per dissenyar un qüestionari on en funció de les respostes s'obté una puntuació específica per a cada una de les preguntes, el sumatori de les quals dona un resultat final que va de 0 a 1.

Altrament, per a l'elaboració de les qüestions s'han tingut en consideració els ítems plantejats en el principi 4 de la Carta Internacional de Dades Obertes (2015), i també l'article de Núria Espuny (2020) sobre l'estratègia de dades obertes de la Generalitat de Catalunya. A continuació es presenta la proposta per a mesurar aquest element ODQ:

- Puntuació màxima: 1 punt
 - » A Les dades es presenten en formats estructurats, oberts i estandarditzats? [Tipus booleà: 0 – No; 1 – Sí].
 - » B Els datasets inclouen metadades basades en vocabularis controlats, concretament, en el vocabulari DCAT establert a la NTI-RISP o en la Guia d'implementació per a l'homogeneïtzació de les metadades del catàleg de dades obertes de la Generalitat de Catalunya? [Tres respostes: 0 – No; 0,50 – No, però s'informa de determinades metadades que es poden equiparar a les utilitzades en els vocabularis de referència; 1 – Sí].
 - » C S'utilitzen localitzacions geogràfiques (georeferències) i referències temporals (històrics) que faciliten la comparabilitat de les dades dins

i entre sectors? [Tres respostes: 0 – No; 0,50 – Sí, només localitzacions geogràfiques / només referències temporals; 1 – Sí, tant localitzacions geogràfiques com referències temporals].

- » D Hi ha una estandardització dels conjunts de dades similars (per exemple, tenen els mateixos camps d'informació, les mateixes unitats de mesura, etc.)? [Tipus booleà: 0 – No; 1 – Sí].
 - » E S'utilitzen estàndards internacionals a fi de facilitar la interoperabilitat de les dades (per exemple, ús de nomes ISO concretes, aplicació del vocabulari DCAT-AP, etc.)? [Tipus booleà: 0 – No; 1 – Sí].
- Fórmula: $(A + B + C + D + E) / 5$
 - Fórmules alternatives: N/A
 - Observacions: el resultat final va de 0 a 1, on 0 significa baixa comparabilitat i 1 alta comparabilitat.
 - Exemples: per a exemplificar-ho s'ha considerat el dataset de Resultats de les eleccions al Parlament de Catalunya per meses 2021 de la ciutat de Badalona, que s'ha descarregat del portal Open Data Badalona. Per avaluar les

qüestions C i D s'ha pres com a model el dataset Eleccions al Parlament de Catalunya 2021 - Recompte provisional per mesa que hi ha al portal de dades obertes de la Generalitat de Catalunya. Per tant, aquestes preguntes s'han puntuat segons la seva similitud amb el citat dataset. A continuació es detalla la puntuació obtinguda per a cada resposta:

- » A – 0 [Les dades només es poden descarregar en format XLS que es tracta d'un format propietari i, per tant, no és un format obert ni reutilitzable].
- » B – 0,50 [Les metadades de les que s'informen són darrera actualització, tipus d'actualització, font, llicència, temes i total de descàrregues. Malgrat que no s'aplica ni el vocabulari DCAT establert a la NTI-RISP ni la Guia d'implementació per a l'homogeneïtzació de les metadades del catàleg de dades obertes de la Generalitat de Catalunya; es considera que les metadades que s'informen es poden mapejar i equiparar a algunes de les metadades establertes tant a la guia tècnica com al vocabulari DCAT].
- » C – 0 [No n'hi ha localitzacions geogràfiques ni referències temporals al dataset avaluat].

- » D – 1 [El dataset avaluat presenta els mateixos atributs o columnes que el dataset model del portal de dades obertes de la Generalitat de Catalunya].
- » E – 0 [No es coneix que el dataset avaluat utilitzi estàndards internacionals].

A partir de les respostes anteriors, s'aplica la següent fórmula:

$$\text{» } (0 + 0,50 + 0 + 1 + 0) / 5 = 1,50 / 5 = 0,30$$

Del resultat anterior es conclou que el grau de comparabilitat del dataset avaluat és baix ja que ha obtingut una puntuació final de 0,30.

5. Dimensió Disponibilitat

a. Pertinència temporal. Aquest element mesura si les dades estan actualitzades en relació amb la seva utilitat, és a dir, el que s'avalua no és només si les dades són actuals sinó també si estan publicades a temps per a la finalitat a la qual responen. És a dir, s'avalua la puntualitat de les dades publicades. Per a la seva mesura s'aplica la fórmula definida per Ballou, Wang, Pazer & Tayi (1998), i que també es menciona a l'obra de

Batini & Scannapieco (2016), en la que la pertinència temporal es mesura en una escala contínua de 0 a 1. Pel que fa a la relació entre actualitat i volatilitat, els autors senyalen que el desitjable és que sigui igual o propera a zero, tanmateix, a mesura que augmenta la proporció entre ambdós elements la pertinència temporal es veu afectada. Ara bé, de la mesura s'obté un valor relatiu a la puntualitat de les dades però en cap cas hi ha una qualificació del mateix, atès que el valor apropiat per a x depèn del context i de la necessitat d'ús.

Per tant, un cop aplicada la fórmula, s'incorpora una pregunta en la que s'avalua si la pertinència temporal és adequada en funció del dataset, de la seva finalitat i del context.

- Puntuació màxima: 1 punt
 - » La pertinència temporal o puntualitat de les dades és l'adequada en funció del context i la necessitat d'ús? [Tipus booleà: 0 – No; 1 – Sí].
- Fórmula: es considera la pertinència temporal com una funció de la proporció de l'actualitat i la volatilitat.

- » Pertinència temporal = $\{\text{màx.} [(1 - (\text{actualitat} / \text{volatilitat})), 0]\}$ ¹¹⁸
- Fórmules alternatives: Batini & Scannapieco (2016) estableixen una mesura qualitativa basada en dues passes. Primerament, mesurar l'actualitat de les dades i, en darrer lloc, verificar si les dades estan disponibles abans del temps d'ús previst.
- Observacions: la fórmula de Ballou, Wang, Pazer & Tayi (1998) permet establir un índex de puntualitat, sense qualificar la baixa o alta pertinència al context i ús.
- Exemple: com a cas pràctic considerem el dataset Comissió de Garantia del Dret d'Accés a la Informació Pública (GAIP), en el qual es presenten les dades anonimitzades i codificades sobre les reclamacions interposades i les resolucions aprovades per la GAIP. El dataset no es troba actualitzat, per tant té una puntuació de 0 punts; i la seva freqüència d'actualització és mensual el que implica un grau de volatilitat 2. A partir d'aquestes dades s'aplica la fórmula corresponent:

$$\begin{aligned} \gg \{ \text{màx.} [(1 - (0 / 2)), 0] \} &= \{ \text{màx.} [(1 - 0), 0] \} = \\ &= \{ \text{màx.} [(1), 0] \} = 1 \end{aligned}$$

El resultat anterior dona un valor d'1 a l'índex de puntualitat. Un cop avaluat aquest valor, així com l'actualitat de les dades, la seva freqüència d'actualització i la verificació de si estan disponibles abans de la freqüència indicada, es conclou que la pertinència temporal no és apropiada per al context i finalitat del conjunt de dades, per la qual cosa s'atorga una puntuació de 0 punts.

b. Actualitat. Aquest element mesura si les dades estan actualitzades en relació amb els canvis ocorreguts en el món real. Per a la seva avaluació s'ha optat per transformar la mètrica de Batini & Scannapieco (2016) en una pregunta on la resposta es de tipus booleà. El resultat s'obté a partir de la revisió de les metadades "data última actualització" i "freqüència d'actualització", ja que el que es verifica és si la data de darrera actualització concorda amb la freqüència indicada.

- Puntuació màxima: 1 punt

¹¹⁸ A l'obra de Batini i Scannapieco (2016) la fórmula de la pertinència temporal s'expressa de la següent manera: $\text{màx.} \{0, 1 - \text{actualitat} / \text{volatilitat}\}$ (p. 28). Altrament, la fórmula presentada s'ha modificat lleugerament ja que s'han incorporat parèntesis a la divisió, a fi d'aclarir que la divisió té preferència sobre la resta. La fórmula originària de Ballou, Wang, Pazer & Tayi (1998) és $\text{pertinència temporal} = \{\text{màx.} [(1 - \text{actualitat} / \text{volatilitat}), 0]\}$

- » Les dades es troben actualitzades? [Tipus booleà: 0 – No; 1 – Sí].
- Fórmula: N/A
- Fórmules alternatives: Ballou, Wang, Pazer & Tayi (1998) estableixen una altra fórmula, de caire quantitatiu, per a mesurar si les dades estan actualitzades. En particular, utilitzen tres variables per a mesurar aquest element ODQ: l'edat (indica l'antiguitat de les dades quan es reben. En anglès, *age*), el temps de publicació (fa referència al moment en què les dades es publiquen al portal de dades obertes i són accessibles als usuaris. En anglès, *delivery time*), i el temps de captura (fa referència al moment en què les dades són capturades dins el sistema. En anglès, *input time*). Els autors utilitzen la fórmula que a continuació es detalla:

$$\text{Actualitat} = (\text{Temps de publicació} - \text{Temps de captura}) + \text{Edat}$$

L'expressió anterior significa que l'actualitat és la suma de l'antiguitat de les dades quan es reben (edat), juntament amb la mesura entre parèntesis que representa el temps que han passat les dades al sistema d'informació (Batini & Scannapieco, 2016).

- Observacions: hi ha estats de freqüència d'actualització que dificulten l'avaluació de l'actualitat, tal com la freqüència contínua o la variable. La primera implica que el conjunt de dades està integrat amb la base de dades d'origen, per tant, cada cop que s'actualitza la base de dades ho fa el dataset; i la segona suposa que el període d'actualització és indefinit i que l'actualització es produeix cada cop que hi ha modificacions. Conseqüentment, davant la incertesa en relació quan es produiran les actualitzacions, no es pot conèixer amb exactitud si les dades estan actualitzades. No obstant, Batini & Scannapieco (2016) plantegen per aquests casos calcular una freqüència de canvi mitjana i realitzar el càlcul en relació amb aquesta mitjana, admetent un marge d'error.
- Exemple: per a il·lustrar-ho considerem el dataset Alts càrrecs de la Generalitat de Catalunya que té una freqüència d'actualització setmanal. Pel que a fa a les últimes actualitzacions, la setmana del 19 al 25 de juliol el dataset es va actualitzar a data 23 de juliol, la setmana del 26 de juliol a l'1 d'agost es va actualitzar el dia 30 de juliol i la setmana del 2 al 8 d'agost es va actualitzar el dia 6 d'agost. Així doncs, es confirma que les dades es

troben actualitzades; per tant, la puntuació final obtinguda és 1 punt.

c. Volatilitat. Aquest element mesura la freqüència en què els valors canvien en el temps, on una alta volatilitat implica una vida útil curta del dataset mentre que una baixa volatilitat significa una vida útil llarga del conjunt de dades. Tal com senyalen Batini & Scannapieco (2016), una mètrica de volatilitat ve donada per la durada del temps en què les dades continuen sent vàlides. Així doncs, a partir d'aquest supòsit es proposa una escala de 5 nivells on es descriu el grau de volatilitat en funció de la freqüència d'actualització dels datasets:

- Puntuació màxima: 4 punts
 - » 0 Volatilitat inexistent: es correspon amb aquells datasets de dades estàtiques i que no varien mai.
 - » 1 Volatilitat baixa: es correspon amb aquells datasets de freqüència d'actualització variable, superior a un any i anual.
 - » 2 Volatilitat mitjana: es correspon amb aquells datasets de freqüència d'actualització mensual, trimestral i semestral.

- » 3 Volatilitat alta: es correspon amb aquells datasets de freqüència d'actualització setmanal i quinzenal.
 - » 4 Volatilitat molt alta: es correspon amb aquells datasets de freqüència d'actualització contínua, horària i diària.
- Fórmula: N/A
 - Fórmules alternatives: N/A
 - Observacions: la volatilitat és un element que influeix en la rellevància de l'actualitat, atès que els conjunts de dades altament volàtils han d'estar actualitzats, mentre que en aquells datasets amb una volatilitat baixa o inexistent (per exemple, dades de freqüència estàtica), l'actualitat no és una propietat rellevant (Batini & Scannapieco, 2016).
 - Exemple: com a cas pràctic considerem el dataset Unitats poblacionals Catalunya que representa la llista d'unitats poblacionals de Catalunya amb la indicació del municipi a on pertanyen. A la meta-dada freqüència d'actualització s'indica dades estàtiques, el que significa que el nivell de volatilitat del dataset és 0 ja que les dades no varien mai.

d. Accessibilitat. Aquest element mesura el nivell d'accés no discriminatori al portal de dades obertes i als datasets que s'hi allotgen, independentment de les capacitats físiques, sensorials o intel·lectuals, i del context tècnic d'ús de les persones usuàries. És a dir, el que s'avalua és si el portal web i el contingut que s'hi inclou satisfan els requeriments d'accessibilitat establerts a la normativa estatal i europea, i també als estàndards internacionals i europeus, i, finalment a les pautes d'accessibilitat per al contingut web (WCAG) 2.1 del W3C. Concretament, per a l'avaluació d'aquesta propietat s'han considerat diversos aspectes: en primer lloc, el compliment dels requeriments establerts al Reial Decret 1112/2018, de 7 de setembre, sobre accessibilitat als llocs web i aplicacions per a dispositius del sector públic, que és la transposició de la Directiva (UE) 2016/2102 del Parlament Europeu i del Consell de 26 d'octubre de 2016 sobre l'accessibilitat dels llocs web i aplicacions per a dispositius mòbils dels organismes del sector públic. En segon lloc, el nivell de conformitat satisfet (A, AA o AAA) entorn als principis de perceptibilitat, operativitat, comprensibilitat i robustesa, segons escala establerta a les pautes d'accessibilitat per al contingut web (WCAG) 2.1 del W3C. En tercer lloc s'han contemplat alguns dels ítems establerts a la UNE 178301:2015; i, en darrer terme, s'ha considerat si el portal de dades obertes disposa de certificacions d'accessibilitat TIC d'AENOR, en particular, si el

lloc web està certificat en la norma UNE 139803:2012. Requisits d'accessibilitat per a contingut en la web. A partir dels aspectes anteriors, es proposa un qüestionari per avaluar el grau d'accessibilitat del portal de dades obertes i dels datasets que s'hi localitzen, amb una puntuació final que va de 0 a 1.

- Puntuació màxima: 1 punt.
 - » A Es publica una declaració d'accessibilitat detallada, exhaustiva i clara sobre la conformitat del portal de dades obertes? [Tipus booleà: 0 – No; 1 – Sí].
 - » B Es compleix amb algun dels nivells de conformitat en matèria d'accessibilitat (A, AA, AAA)? [Quatre respostes: 0 – No o es desconeix si es compleix amb algun nivell; 0,50 – Sí, amb el nivell A; 0,75 – Sí, amb el nivell AA; 1 – Sí, amb el nivell AAA].
 - » C Es requereix realitzar un tràmit administratiu per accedir als conjunts de dades? [Tipus booleà: 0 – Sí; 1 – No].
 - » D Es requereix realitzar un registre d'usuari per accedir als conjunts de dades? [Tipus booleà: 0 – Sí; 1 – No].

- » E El portal de dades obertes disposa d'alguna certificació d'accessibilitat, per exemple la norma UNE 139803:2012? [Tres respostes: 0 – No; 0,50 – Sí, però no està renovada; 1 – Sí].
- Fórmula: $(A + B + C + D + E) / 5$
- Fórmules alternatives: N/A
- Observacions: la puntuació final va de 0 a 1, on 0 significa baixa accessibilitat i 1 alta accessibilitat.
- Exemple: com a cas pràctic considerem el portal de dades obertes de la Generalitat de Catalunya, on la puntuació per a cada qüestió és la següent:
 - » A – 1 [Sí, es publica una declaració d'accessibilitat tal com marca l'article 15 del Reial Decret 1112/2018].
 - » B – 0,50 [A la declaració d'accessibilitat s'indica que «*el compromís de la Generalitat de Catalunya és arribar a complir el nivell de conformitat 'Doble-A' (AA), tal com exigeixen a les administracions públiques les legislacions europea i estatal*», per aquesta raó es

considera que encara no es compleix amb el nivell AA, però sí amb el nivell A].

- » C – 1 [No es requereix realitzar un tràmit administratiu per accedir als conjunts de dades].
- » D – 1 [No es requereix realitzar un registre d'usuari per accedir als conjunts de dades].
- » E – 0 [El portal de dades obertes no disposa de cap certificació d'accessibilitat].

A partir de les respostes anteriors s'aplica la fórmula següent:

$$\text{» } (1 + 0,50 + 1 + 1 + 0) / 5 = 3,50 / 5 = 0,70$$

Del resultat anterior es conclou que la puntuació final del nivell d'accessibilitat del portal de dades obertes de la Generalitat de Catalunya és de 0,70.

- e. **Reutilització.** Aquest element mesura el grau de reutilització dels conjunts de dades publicats, ja que tal com senyalen Abella, Ortiz-de-Urbina & De-Pablos-Heredero (2018) no és el mateix l'accés als datasets i la seva difusió que la seva reutilització. Per a mesurar aquest element ODQ

s'utilitza la mètrica Meloda 5, elaborada pels autors abans citats, la qual avalua aquells àmbits que més influeixen en la possibilitat de desenvolupar aplicacions i serveis per part d'agents reutilitzadors. Concretament, els 8 àmbits que s'analitzen són les llicències legals, l'accés a la informació, els estàndards tècnics, l'estandardització, la geolocalització, la freqüència d'actualització, la disseminació de les dades i la reputació de la font de dades. A continuació es detallen els ítems que conformen cada un d'aquests àmbits així com la puntuació que es pot obtenir (Abella, Ortiz-de-Urbina & De-Pablos-Heredero, 2014 i 2019). Així mateix, és important destacar que les puntuacions s'han extret de la pàgina web de meloda¹¹⁹.

- Puntuació màxima: 61 punts.
 - » Llicències legals (puntuació màxima: 6 punts)
 - Ús privat, per exemple copyright que permet ús personal. (1 punt)
 - Reutilització no comercial, per exemple CC BY-NC 4.0. (3 punts)

- Reutilització comercial o sense restriccions, per exemple CC BY-NC 4.0. (6 punts)
- » Accés a la informació (puntuació màxima: 6 punts)
 - Accés web o paràmetres d'URL únics al conjunt de dades (1 punt)
 - Accés web únic amb paràmetres a dades individuals (3 punts)
 - API o llenguatge de consulta (6 punts)
- » Estàndards tècnics (puntuació màxima: 6 punts)
 - Estàndards privatis, per exemple xls, shp, doc. (1 punt)
 - Estàndards oberts, per exemple csv, ods, wms. (3 punts)
 - Estàndards oberts amb metadades, per exemple rdf, rss, json. (6 punts)
- » Estandardització (puntuació màxima: 10 punts)
 - Estandardització pròpia del model de dades (1 punt)

¹¹⁹ Per a més informació es remet a <https://www.meloda.org/>

- Publicació de normalització pròpia del model de dades *ad hoc* (harmonització). (3 punts)
 - Normalització local. (6 punts)
 - Normalització global. (10 punts)
- » Geolocalització (puntuació màxima: 6 punts)
- No hi ha informació geogràfica. (1 punt)
 - Camp de text simple o complex. (3 punts)
 - Coordenades o informació geogràfica completa. (6 punts)
- » Freqüència d'actualització (puntuació màxima: 15 punts)
- Més d'un mes. (1 punt)
 - Mensualment. El període d'actualització oscil·la entre un mes i un dia. (3 punts)
 - Diàriament. El període d'actualització oscil·la entre un dia i una hora. (6 punts)
 - Hora. El període d'actualització oscil·la entre una hora i un minut. (10 punts)
 - Segons. El període d'actualització és inferior a un minut. (15 punts)
- » Disseminació (puntuació màxima: 6 punts)
- La comunicació / difusió no és sistemàtica. (1 punt)
 - Recursos disponibles sobre actualitzacions (és a dir, RSS). (3 punts)
 - Difusió proactiva / difusió *push* (informació automàtica i oportuna). (6 punts)
- » Reputació (puntuació màxima: 6 punts)
- No hi ha informació sobre la reputació de la font de dades. (1 punt)
 - Estadístiques o informes publicats sobre les opinions dels usuaris. (3 punts)
 - Indicadors o rànquings sobre la reputació de la font de dades. (6 punts)
- Fórmula: N/A
 - Fórmules alternatives: N/A
 - Observacions: en relació amb l'àmbit freqüència d'actualització, els ítems variable i dades estàtiques no es troben contemplats. A efectes pràctics, les dades estàtiques malgrat no variar mai s'inclouen dins l'opció més d'un mes. I pel que fa a la freqüència variable l'opció a escollir dependrà de la freqüència mitjana en que s'ha

anat actualitzat el dataset, en cas de no conèixer aquesta freqüència l'elecció dependrà de la darrera data d'actualització de les dades.

- Exemple: per a il·lustrar-ho considerem tant l'Open Data BCN, que és el servei de dades obertes de l'Ajuntament de Barcelona, com el dataset Miradors a la ciutat de Barcelona. Un cop revisada tant la pàgina com el dataset es procedeix a seleccionar l'ítem per a cada un dels àmbits:

» Llicències legals (puntuació màxima obtinguda: 6 punts)

- Reutilització comercial o sense restriccions, per exemple CC BY-NC 4.0. (6 punts)

» Accés a la informació (puntuació màxima obtinguda: 6 punts)

- API o llenguatge de consulta (6 punts)

» Estàndards tècnics (puntuació màxima obtinguda: 6 punts)

- Estàndards oberts amb metadades, per exemple rdf, rss, json. (6 punts)

» Estandardització (puntuació màxima obtinguda: 1 punt)

- Estandardització pròpia del model de dades (1 punt)

» Geolocalització (puntuació màxima obtinguda: 3 punts)

- Camp de text simple o complex. (3 punts)

» Freqüència d'actualització (puntuació màxima obtinguda: 3 punts)

- Mensualment. El període d'actualització oscil·la entre un mes i un dia. (3 punts)

» Disseminació (puntuació màxima obtinguda: 3 punts)

- Recursos disponibles sobre actualitzacions (és a dir, RSS). (3 punts)

» Reputació (puntuació màxima obtinguda: 1 punt)

- No hi ha informació sobre la reputació de la font de dades. (1 punt)

A partir dels ítems anteriors es conclou que la puntuació màxima obtinguda és 29 de 61. Com la puntuació no arriba a la meitat de la puntuació màxima (30,5 de 61) es conclou que el grau de reutilització és baix.

- f. Seguretat/Privacitat.** Aquest element mesura el nivell de seguretat en relació als sistemes d'emmagatzemament i també respecte a l'accés als conjunts de dades publicats. En aquest sentit, des de la Federación Española de Municipios y Provincias (FEMP) (2017) s'assenyala que per al procés d'obertura és important l'anonimització de les dades personals i també la seguretat, entenent que

«En el ámbito de la reutilización, hay que destacar la importancia del factor disponibilidad de los datos, por lo que su aseguramiento puede requerir un nivel de medidas de protección mayor (...). En todo caso, las medidas de protección deberán adaptarse tanto a los riesgos a los que esté expuesta la información y sus redes o sistemas, como a la situación tecnológica del organismo correspondiente. En el Esquema Nacional de Seguridad, se establecen los criterios para la realización de un análisis de riesgos y las pautas a seguir para

el establecimiento de unas adecuadas medidas de seguridad.» (p. 39)

Partint d'aquestes consideracions, per avaluar aquest element ODQ es proposa una mètrica centrada, d'una banda, en l'adequació als principis i mesures de seguretat de l'Esquema Nacional de Seguretat (ENS) i, d'altra banda, en la seva vinculació a la gestió documental, atès que la definició i compliment d'una política de preservació digital i d'una política de retenció dels conjunts publicats permet aplicar mecanismes automatitzats per a poder controlar l'accés a les dades i garantir la seva conservació durant el termini necessari. Si bé a la literatura consultada (vid. **Taula 8**) existeixen mètriques per avaluar la seguretat/privacitat, tal com la proposada per Mahanti (2018) o també la que s'estableix a la norma ISO/IEC 25012:2008, no s'han tingut en consideració ja que no s'adeqüen als aspectes abans citats. Així doncs, en el present model es fa una proposta de mètrica a partir de la revisió del Reial decret 3/2010, de 8 de gener, pel qual es regula l'Esquema Nacional de Seguretat en l'àmbit de l'Administració electrònica, i també a partir d'alguns dels indicadors establerts en el Model de maduresa en gestió documental per a la transparència i la publicitat activa de l'Associació de professionals de l'arxivística i la gestió

de documents de Catalunya (2016)¹²⁰. En darrer terme, és important senyalar que la proposta que es planteja es fonamenta en les relacions, ja identificades per Casellas (2016), que s'estableixen entre *open data*, seguretat de la informació, protecció de dades personals i preservació de les dades, tal com es reflecteix en el qüestionari que a continuació es presenta:

- Puntuació màxima: 45 punts

» Aspectes organitzatius (puntuació màxima obtinguda: 3 punts)

- Es disposa d'una política de seguretat? [Tipus booleà: 0 – No; 1 – Sí].
- La política de seguretat és coneguda per tots els membres de l'organització? [Tipus booleà: 0 – No; 1 – Sí]
- Existeixen instruments que desenvolupen la política de seguretat (per exemple, instruments tècnics, normativa, procediments, etc.) [Tipus booleà: 0 – No; 1 – Sí]

» Planificació de la seguretat (puntuació màxima obtinguda: 3 punts)

- Es realitza un anàlisi i gestió de riscos de forma contínua? [Tres respostes: 0 – No; 0,50 – Sí, però la gestió no és contínua; 1 – Sí, la gestió és contínua]
- Hi ha un plantejament integral de la seguretat del sistema? [Tipus booleà: 0 – No; 1 – Sí]
- Es realitza o s'ha realitzat, amb caràcter previ a la posada en explotació, un estudi previ de les necessitats i dimensionament del sistema? [Tipus booleà: 0 – No; 1 – Sí]

» Gestió i control d'accés (puntuació màxima obtinguda: 4 punts)

- Existeixen sistemes d'identificació i de control d'accés dels usuaris del sistema (per exemple, per a incorporar conjunts de dades de forma manual)? [Tipus booleà: 0 – No; 1 – Sí]
- Hi ha un registre d'activitats on hi consta qui accedeix (especialment

120 Tot i que aquest model està pensat fonamentalment per als portals de transparència i els documents que s'hi publiquen, considerem que hi ha indicadors a tenir en consideració per a mesurar el grau de seguretat/privacitat dels datasets, malgrat que en alguns casos s'ha modificat la forma de càlcul.

operadors i administradors del sistema), quan s'hi accedeix i les accions que es realitzen (per exemple, editar o esborrar conjunts de dades?) [Tipus booleà: 0 – No; 1 – Sí]

- Es defineix i s'aplica una política de retenció dels registres d'activitats? [0 – No; 0,50 – Sí, però només està definida i no s'aplica; 1 – Sí, hi ha definida una política de retenció i s'aplica]
- Hi ha mecanismes que garanteixen la gestió dels drets d'accés (per exemple, en el cas d'aquelles dades sotmeses a algun tipus de restricció que en restringeix la seva reutilització)? [Tipus booleà: 0 – No; 1 – Sí]

» Explotació de la informació (puntuació màxima obtinguda: 8 punts)

- Hi ha un catàleg actualitzat d'actius d'informació? [Tres respostes: 0 – No; 0,50 – Sí, però no està actualitzat; 1 – Sí n'hi ha i està actualitzat]
- Hi ha un inventari o catàleg actualitzat de dades obertes? [Tres respostes:

0 – No; 0,50 – Sí, però no està actualitzat; 1 – Sí n'hi ha i està actualitzat]

- El sistema està dissenyat i configurat de tal forma que es garanteix la seguretat per defecte (és a dir, es compleixen els ítems establerts a l'article 19 de l'ENS)? [Tipus booleà: 0 – No; 1 – Sí]
- Es gestiona de forma contínua la configuració dels components del sistema a fi de que es mantingui la regla de seguretat per defecte? [Tipus booleà: 0 – No; 1 – Sí]
- S'empren procediments per analitzar, prioritzar i determinar quan aplicar les actualitzacions de seguretat, pedaços, millores i noves versions en relació amb les especificacions dels fabricants? [Tipus booleà: 0 – No; 1 – Sí]
- Es manté un control continu dels canvis realitzats en el sistema? [Tipus booleà: 0 – No; 1 – Sí]
- Es disposa de mecanismes de prevenció i reacció contra codi perjudicial¹²¹ d'acord amb les recomanacions del fabricant? [Tipus booleà: 0 – No; 1 – Sí]

¹²¹ Segons l'ENS es considera codi perjudicial els virus, els cucs, els troians, els programes espies (anomenat *spyware*, en anglès) i, en general, tot el que es coneix com a *malware*.

- Hi ha un registre dels incidents de seguretat que es produeixen i de les accions de tractament que se segueixen? [Tres respostes: 0 – No; 0,50 – Sí, però només dels incidents de seguretat / només de les accions de tractament; 1 – Sí, tant dels incidents de seguretat com de les accions de tractament]
- » Serveis externs (puntuació màxima obtinguda: 1 punt)
 - En cas d'utilitzar recursos externs a l'organització, s'estableix contractualment els acords de nivell de servei (qualitat mínima, conseqüències d'incompliment, mitjans alternatius en cas d'indisponibilitat del servei contractat, etc.) i les responsabilitats de les parts? [Tipus booleà: 0 – No; 1 – Sí]
- » Continuitat del servei (puntuació màxima obtinguda: 2 punts)
 - Es disposa de còpies de seguretat? [Tipus booleà: 0 – No; 1 – Sí]
- S'ha desenvolupat un pla de continuïtat en el que s'estableixen els mecanismes necessaris per garantir la continuïtat de l'activitat? [Tipus booleà: 0 – No; 1 – Sí]
- » Monitorització del sistema (puntuació màxima obtinguda: 1 punt)
 - Es disposa de mesures de monitorització de l'activitat (per exemple, indicadors que mesurin el desenvolupament real del sistema en matèria de seguretat)? [Tipus booleà: 0 – No; 1 – Sí]
- » Gestió del personal (puntuació màxima obtinguda: 2 punts)
 - El personal de l'organització (especialment el relacionat amb la informació i els sistemes) ha rebut formació específica en matèria de seguretat? [Tipus booleà: 0 – No; 1 – Sí]
 - El personal de l'organització (especialment el relacionat amb la informació i els sistemes) ha estat informat dels deures i obligacions del seu lloc de treball en matèria de seguretat? [Tipus booleà: 0 – No; 1 – Sí]

» Protecció de les instal·lacions i infraestructures (puntuació màxima obtinguda: 5 punts)

- Els locals on s'ubiquen els sistemes d'informació i els seus components disposen de protecció contra incendis? [Tipus booleà: 0 – No; 1 – Sí]
- Els locals on s'ubiquen els sistemes d'informació i els seus components disposen de protecció contra inundacions? [Tipus booleà: 0 – No; 1 – Sí]
- En els locals on s'ubiquen els sistemes d'informació es garanteix el subministrament elèctric en cas de fallada del subministrament general? [Tipus booleà: 0 – No; 1 – Sí]
- Els locals on s'ubiquen els sistemes d'informació i els seus components estan condicionats a fi de garantir el funcionament eficaç de l'equipament instal·lat (per exemple, condicions de temperatura i humitat)? [Tipus booleà: 0 – No; 1 – Sí]

- Els sistemes d'informació i els seus components es troben instal·lats en àrees específiques per a la seva funció, dotades d'un procediment de control d'accés? [Tres respostes: 0 – No; 0,50 – Sí, estan instal·lades en àrees separades però no hi ha control d'accés; 1 – Sí, estan instal·lades en àrees separades amb control d'accés].

» Protecció dels suports d'informació (puntuació màxima obtinguda: 4 punts)

- En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*¹²²), s'apliquen mecanismes criptogràfics per a garantir la confidencialitat i integritat de la informació continguda? [Tipus booleà: 0 – No; 1 – Sí]
- En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), es

122 La conservació *nearline* es fonamenta en l'ús combinat de suports físics d'emmagatzematge massiu, preferentment òptics, i dispositius d'accés automàtic a dits suports que reben el nom de llibreries de discs o *jukebox*. Aquests dispositius permeten accedir a un magatzem de discs òptics (compact disc, DVD, etc.), i essencialment s'usen per a l'emmagatzematge de grans volums de dades i també per a la realització de còpies de seguretat orientades a garantir la disponibilitat de la informació en cas de desastre. Ans al contrari, la conservació *offline* es fonamenta només en l'ús de suports d'emmagatzematge d'informació no connectats a la xarxa; així mateix, en funció del suport serà necessari revisar periòdicament el seu estat de conservació i realitzar processos de *refreshing*, és a dir, de copiar les dades a nous suports (Serra, 2008, 136).

garanteixen les condicions ambientals necessàries per a la seva preservació? [Tipus booleà: 0 – No; 1 – Sí]

- En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), existeixen mecanismes de custòdia i control d'accés amb mesures físiques o lògiques, o totes dues? [Tipus booleà: 0 – No; 1 – Sí]
- En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), es garanteix l'esborrament i destrucció de forma segura tant de la informació continguda com dels suports? [Tipus booleà: 0 – No; 1 – Sí, es garanteix la destrucció segura]

» Protecció dels serveis (puntuació màxima obtinguda: 3 punts)

- Existeixen mecanismes de protecció contra les amenaces adreçades a serveis i aplicacions web (per exemple, prevenció d'atacs d'injecció de codi, prevenció d'atacs de manipulació d'URL, etc.)? [Tipus booleà: 0 – No; 1 – Sí]

- Existeixen mesures preventives i reactives contra atacs de denegació de servei (*DOS Denial of Service*)? [Tipus booleà: 0 – No; 1 – Sí]
- Es preveuen mitjans alternatius per a prestar els serveis en cas que fallin els mitjans habituals? [Tipus booleà: 0 – No; 1 – Sí]

» Protecció i preservació dels conjunts de dades (puntuació màxima obtinguda: 6 punts)

- Hi ha definida una política de retenció i disposició dels conjunts de dades publicats? [Tipus booleà: 0 – No; 1 – Sí]
- S'aplica la política de retenció i disposició dels conjunts de dades publicats (per exemple, eliminació de *data-sets*)? [Tipus booleà: 0 – No; 1 – Sí]
- Hi ha definida una política de preservació digital? [Tipus booleà: 0 – No; 1 – Sí]
- S'aplica la política de preservació digital definida? [Tipus booleà: 0 – No; 1 – Sí]
- Es realitzen processos d'anonimització de les dades personals, a fi de complir amb el RGPD i la LOPDGDD? [Tipus booleà: 0 – No; 1 – Sí]

- Es realitzen còpies de seguretat a fi de recuperar les dades perdudes amb una antiguitat determinada? [Tipus booleà: 0 – No; 1 – Sí]
- » Auditories de seguretat (puntuació màxima obtinguda: 1 punt)
- Es realitzen auditories de seguretat tant internes com externes per part de personal qualificat? [Tres respostes: 0 – No; 0,50 – Sí, només auditories internes per part de personal qualificat; 1 – Sí, es realitzen tant auditories internes com externes per part de personal qualificat].
- » Sistema de gestió documental (puntuació màxima obtinguda: 2 punts)
- Existeix un sistema de gestió documental¹²³? [Tres respostes: 0 – No; 0,50 – Sí, parcialment (50% d'elements que es compleixen dels explicitats a

la nota 123); 1 – Sí, en la seva totalitat (100% d'elements que es compleixen dels explicitats a la nota 123)].

- Els conjunts de dades obertes es vinculen al sistema de gestió documental? [Tipus booleà: 0 – No; 1 – Sí]

• Fórmula: N/A

• Fórmula alternativa: N/A

- Observacions: per avaluar aquest element ODQ a partir del qüestionari proposat és necessari conèixer el *back office* de l'organització proveïdora de les dades i també de l'entitat o organització que actua com a repositori dels conjunts de dades públics (si s'escau), atès que només a partir dels datasets publicats no es pot avaluar el grau de seguretat/privacitat de les dades i dels sistemes que les contenen.

123 Tal com s'indica a l'indicador 11 del Model de maduresa en Gestió Documental per a la Transparència i la Publicitat Activa de l'AAC (2016), un sistema de gestió documental (SGD) necessita dels següents instruments: política de gestió documental, quadre de classificació, registre general de documents, registre general d'expedients, calendari de conservació (vinculat al QdC), quadre de seguretat i accés (vinculat al QdC), normes de descripció (s'inclou el Vocabulari de metadades), catàleg de procediments administratius, catàleg de tipologies documentals, catàleg d'aplicacions informàtiques, catàleg de dades/catàleg de bases de dades (també anomenat catàleg d'actius d'informació), reglament del servei d'arxiu i gestió documental, i manual del sistema de gestió documental. Juntament amb els instruments del SGD, es requereixen els següents aspectes: personal expert en gestió documental, compromís exprés de la direcció de l'organització vers la implementació i continuïtat del sistema de gestió documental, pressupost escalable i suficient per fer viable el projecte, i aplicació informàtica que compleixi amb els requeriments funcionals d'un SGD.

La puntuació obtinguda va de 0 a 45 punts, i es divideix en tres nivells de seguretat/privacitat:

- » Nivell 1 (menys de 15 punts): nivell baix de seguretat/privacitat.
 - » Nivell 2 (de 15 a 30 punts): nivell intermedi de seguretat/privacitat.
 - » Nivell 3 (més de 30 punts): nivell alt de seguretat/privacitat.
- Exemple: per a il·lustrar-ho considerem que l'objecte d'avaluació és la Secretaria d'Universitats i Recerca com a proveïdora de conjunts de dades obertes. Un cop analitzats els aspectes relacionats amb la protecció de les dades personals, la seguretat de la informació i la preservació de les dades es procedeix a respondre el qüestionari¹²⁴:
 - » Aspectes organitzatius (puntuació màxima obtinguda: 3 punts)
 - Es disposa d'una política de seguretat? [1 – Sí].

- La política de seguretat és coneguda per tots els membres de l'organització? [1 – Sí]
 - Existeixen instruments que desenvolupen la política de seguretat (per exemple, instruments tècnics, normativa, procediments, etc.) [1 – Sí]
- » Planificació de la seguretat (puntuació màxima obtinguda: 2,50 punts)
 - Es realitza un anàlisi i gestió de riscos de forma contínua? [0,50 – Sí, però la gestió no és contínua]
 - Hi ha un plantejament integral de la seguretat del sistema? [1 – Sí]
 - Es realitza o s'ha realitzat, amb caràcter previ a la posada en explotació, un estudi previ de les necessitats i dimensionament del sistema? [1 – Sí]
 - » Gestió i control d'accés (puntuació màxima obtinguda: 3 punts)
 - Existeixen sistemes d'identificació i de control d'accés dels usuaris del

¹²⁴ Aquest exemple només és per mostrar com funciona i com s'aplica la mètrica, en cap cas s'ha realitzat un anàlisi del *back office* de la Secretaria d'Universitats i Recerca, per tant, la puntuació que es dona és fictícia, només és a tall d'exemple.

sistema (per exemple, per a incorporar conjunts de dades de forma manual)? [1 – Sí]

- Hi ha un registre d'activitats on hi consta qui accedeix (especialment operadors i administradors del sistema), quan s'hi accedeix i les accions que es realitzen (per exemple, editar o esborrar conjunts de dades?) [1 – Sí]
- Es defineix i s'aplica una política de retenció dels registres d'activitats? [0 – No]
- Hi ha mecanismes que garanteixen la gestió dels drets d'accés (per exemple, en el cas d'aquelles dades sotmeses a algun tipus de restricció que en restringeix la seva reutilització)? [1 – Sí]

» Explotació de la informació (puntuació màxima obtinguda: 5,50 punts)

- Hi ha un catàleg actualitzat d'actius d'informació? [1 – Sí n'hi ha i està actualitzat]
- Hi ha un inventari o catàleg actualitzat de dades obertes? [1 – Sí n'hi ha i està actualitzat]

- El sistema està dissenyat i configurat de tal forma que es garanteix la seguretat per defecte (és a dir, es compleixen els ítems establerts a l'article 19 de l'ENS)? [0 – No]
- Es gestiona de forma contínua la configuració dels components del sistema a fi de que es mantingui la regla de seguretat per defecte? [0 – No]
- S'empren procediments per analitzar, prioritzar i determinar quan aplicar les actualitzacions de seguretat, pedaços, millores i noves versions en relació amb les especificacions dels fabricants? [1 – Sí]
- Es manté un control continu dels canvis realitzats en el sistema? [1 – Sí]
- Es disposa de mecanismes de prevenció i reacció contra codi perjudicial d'acord amb les recomanacions del fabricant? [1 – Sí]
- Hi ha un registre dels incidents de seguretat que es produeixen i de les accions de tractament que se segueixen? [0,50 – Sí, però només dels incidents de seguretat / només de les accions de tractament]

» Serveis externs (puntuació màxima obtinguda: 1 punt)

- En cas d'utilitzar recursos externs a l'organització, s'estableix contractualment els acords de nivell de servei (qualitat mínima, conseqüències d'incompliment, mitjans alternatius en cas d'indisponibilitat del servei contractat, etc.) i les responsabilitats de les parts? [1 – Sí]

» Continuitat del servei (puntuació màxima obtinguda: 2 punts)

- Es disposa de còpies de seguretat? [1 – Sí]
- S'ha desenvolupat un pla de continuïtat en el que s'estableixen els mecanismes necessaris per garantir la continuïtat de l'activitat? [1 – Sí]

» Monitorització del sistema (puntuació màxima obtinguda: 1 punt)

- Es disposa de mesures de monitorització de l'activitat (per exemple, indicadors que mesurin el desenvolupament real del sistema en matèria de seguretat)? [1 – Sí]

» Gestió del personal (puntuació màxima obtinguda: 0 punts)

- El personal de l'organització (especialment el relacionat amb la informació i els sistemes) ha rebut formació específica en matèria de seguretat? [0 – No]
- El personal de l'organització (especialment el relacionat amb la informació i els sistemes) ha estat informat dels deures i obligacions del seu lloc de treball en matèria de seguretat? [0 – No]

» Protecció de les instal·lacions i infraestructures (puntuació màxima obtinguda: 4,50 punts)

- Els locals on s'ubiquen els sistemes d'informació i els seus components disposen de protecció contra incendis? [1 – Sí]
- Els locals on s'ubiquen els sistemes d'informació i els seus components disposen de protecció contra inundacions? [1 – Sí]
- En els locals on s'ubiquen els sistemes d'informació es garanteix el subministrament elèctric en cas de fallada del subministrament general? [1 – Sí]

- Els locals on s'ubiquen els sistemes d'informació i els seus components estan condicionats a fi de garantir el funcionament eficaç de l'equipament instal·lat (per exemple, condicions de temperatura i humitat)? [1 – Sí]
 - Els sistemes d'informació i els seus components es troben instal·lats en àrees específiques per a la seva funció, dotades d'un procediment de control d'accés? [0,50 – Sí, estan instal·lades en àrees separades però no hi ha control d'accés].
- » Protecció dels suports d'informació (puntuació màxima obtinguda: 3 punts)
- En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), s'apliquen mecanismes criptogràfics per a garantir la confidencialitat i integritat de la informació continguda? [0 – No]
 - En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), es garanteixen les condicions ambientals necessàries per a la seva preservació? [1 – Sí]
- En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), existeixen mecanismes de custòdia i control d'accés amb mesures físiques o lògiques, o totes dues? [1 – Sí]
 - En cas de disposar de suports d'informació (per exemple, en el cas de sistemes d'emmagatzemament de conservació *nearline* o *offline*), es garanteix l'esborrament i destrucció de forma segura tant de la informació continguda com dels suports? [1 – Sí, es garanteix la destrucció segura]
- » Protecció dels serveis (puntuació màxima obtinguda: 2 punts)
- Existeixen mecanismes de protecció contra les amenaces adreçades a serveis i aplicacions web (per exemple, prevenció d'atacs d'injecció de codi, prevenció d'atacs de manipulació d'URL, etc.)? [1 – Sí]

- Existeixen mesures preventives i reactives contra atacs de denegació de servei (*DOS Denial of Service*)? [1 – Sí]
 - Es preveuen mitjans alternatius per a prestar els serveis en cas que fallin els mitjans habituals? [0 – No]
- » Protecció i preservació dels conjunts de dades (puntuació màxima obtinguda: 2 punts)
- Hi ha definida una política de retenció i disposició dels conjunts de dades publicats? [0 – No]
 - S'aplica la política de retenció i disposició dels conjunts de dades publicats (per exemple, eliminació de datasets)? [0 – No]
 - Hi ha definida una política de preservació digital? [0 – No]
 - S'aplica la política de preservació digital definida? [0 – No]
 - Es realitzen processos d'anonimització de les dades personals, a fi de complir amb el RGPD i la LOPDGDD? [1 – Sí]
 - Es realitzen còpies de seguretat a fi de recuperar les dades perdudes amb una antiguitat determinada? [1 – Sí]
- » Auditories de seguretat (puntuació màxima obtinguda: 0,50 punts)
- Es realitzen auditories de seguretat tant internes com externes per part de personal qualificat? [0,50 – Sí, només auditories internes per part de personal qualificat].
- » Sistema de gestió documental (puntuació màxima obtinguda: 0,50 punts)
- Existeix un sistema de gestió documental? [0,50 – Sí, parcialment (50% d'elements que es compleixen dels explicitats a la nota 123)].
 - Els conjunts de dades obertes es vinculen al sistema de gestió documental? [0 – No]

La puntuació màxima obtinguda per part de la Secretaria d'Universitats i Recerca és 30,50 punts, d'un total màxim de 45 punts. Així doncs, l'organització es situa en el nivell 3, és a dir, en el nivell alt de seguretat/privacitat (més de 30 punts).

g. Portabilitat. Aquest element mesura el nivell de facilitat en què els conjunts de dades canvien d'entorn, preservant totes les seves característiques. Per al seu mesurament, la norma ISO/IEC 25012:2008 estableix una fórmula però, en el marc d'aquest projecte, no s'ha considerat ja que només avalua el nombre de dades que conserven la seva qualitat després de la migració a un sistema informàtic diferent (A), en relació amb el nombre total de dades migrades (B). Malgrat no ser una forma de càlcul incorrecte (A/B), plantejem una avaluació qualitativa en forma de qüestionari que tingui en consideració aspectes relacionats amb la interoperabilitat semàntica, organitzativa i tècnica, atès que el compliment de les mesures d'interoperabilitat és condició *sine qua non* per a la portabilitat de les dades amb les màximes garanties. Per a l'elaboració del qüestionari s'ha tingut en consideració diverses publicacions i normes, particularment el Reial Decret 4/2010, de 8 de gener, pel qual es regula l'Esquema Nacional d'Interoperabilitat a l'àmbit de l'Administració Electrònica, la Guia d'auditoria del compliment de l'ENI, la Guia d'adequació a l'ENI, o algunes NTIs, més concretament la NTI de Catàleg d'estàndards, la

NTI de Protocols d'intermediació de dades, la NTI de Relació de models de dades i la NTI de requisits de connexió a la xarxa de comunicacions de les Administracions públiques espanyoles.

A continuació es detalla la proposta per a mesurar el grau de portabilitat tant dels datasets com de les seves metadades:

- Puntuació màxima: 1 punt.
 - » A S'han establert convenis entre les Administracions Públiques emissores i receptors i, en particular, amb els nodes d'interoperabilitat? [Tipus booleà: 0 – No; 1 – Sí].
 - » B Existeixen nodes d'interoperabilitat¹²⁵ per a l'intercanvi de dades? [Tipus booleà: 0 – No; 1 – Sí].

¹²⁵ Segons el Reial Decret 4/2010, de 8 de gener, pel qual es regula l'Esquema Nacional d'Interoperabilitat a l'àmbit de l'Administració Electrònica, un node d'interoperabilitat és un «*organismo que presta servicios de interconexión técnica, organizativa y jurídica entre sistemas de información para un conjunto de Administraciones Públicas bajo las condiciones que éstas fijen.*» (Annex. Glossari de termes, p. 21).

- » C Es manté la traçabilitat dels intercanvis de dades realitzades, conforme a la NTI de Protocols d'intermediació de dades? [Tres respostes: 0 – No; 0,50 – Sí, però no es manté traça de tota la informació que obliga la NTI de Protocols d'intermediació de dades; 1 – Sí, conforme a la NTI de Protocols d'intermediació de dades].
- » D S'identifiquen i publiquen models de dades d'intercanvi per part de l'organització, tenint en consideració la NTI de Relació de models de dades? [Tres respostes: 0 – No; 0,50 – Sí, però no s'apliquen els requeriments que estableix la NTI de Relació de models de dades; 1 – Sí, tenint en consideració la NTI de Relació de models de dades].
- » E S'utilitzen estàndards oberts o d'ús generalitzat per als models de dades, segons la NTI de Catàleg d'estàndards i la NTI de Relació de models de dades? [Tipus booleà: 0 – No; 1 – Sí].
- » F Els models de dades es troben correctament identificats i descrits, segons la taula d'identificació dels models de dades que s'estableix a la NTI de Relació de models de dades? [Tipus booleà: 0 – No; 1 – Sí].
- » G Les definicions i codificacions utilitzades en els models de dades contempnen el que es disposa a la Llei 12/1989, de 9 de maig, de la Funció Estadística pública i la resta de disposicions que regulen la funció estadística¹²⁶? [Tipus booleà: 0 – No; 1 – Sí].
- » H S'utilitzen estàndards oberts, i de forma complementària, estàndards d'ús generalitzat per la ciutadania, per a l'intercanvi de dades, segons el que es preveu, sense caràcter limitatiu, a la NTI de Catàleg d'estàndards? [Tipus booleà: 0 – No; 0,50 – Sí, però només pels datasets / només per les metadades; 1 – Sí, tant pels datasets com per les metadades].

¹²⁶ La finalitat és establir un sistema estadístic coherent a partir de la normalització estadística, per la qual cosa des de l'Institut Nacional d'Estadística (INE) s'estableix un conjunt de classificacions i estàndards harmonitzats a nivell nacional i internacional. Per a més informació es remet a la pàgina de l'[INE](#).

- » I Es connecta la xarxa de l'entitat a una xarxa de comunicacions de les Administracions públiques¹²⁷ (per exemple, la Xarxa SARA o, en el cas de Catalunya, Via Oberta del Consorci AOC)? [Tipus booleà: 0 – No; 1 – Sí].
 - » J En cas de connexió a la xarxa SARA, s'aplica el *Plan de direccionamiento e interconexión de redes en la Administración*, per a la seva interconnexió a través de les xarxes de comunicacions de les Administracions Públiques? [Tipus booleà: 0 – No; 1 – Sí].
 - » K Les dades que s'han transferit d'un sistema a un altre preserven les mateixes característiques de qualitat? [Quatre respostes: 0 – Menys del 25% de les dades; 0,25 – Del 25 al 50% de les dades; 0,50 – Del 50 al 75 % de les dades; 1 – Més del 75% de les dades].
- Fórmula:
 - » $(A + B + C + D + E + F + G + H + I + J + K) / 11$
 - Fórmula alternativa: N/A
 - Observacions: el qüestionari ha de permetre avaluar la capacitat dels sistemes per a intercanviar dades, interpretar-les i reutilitzar-les en un context diferent, sense pèrdua de qualitat de les mateixes. Es parteix de la consideració que a partir del nivell d'interoperabilitat aconseguit, es pot inferir el grau de portabilitat que posseeixen les dades per a ser migrades i reutilitzades en diferents sistemes. D'aquesta manera, si la puntuació obtinguda és 0 significa que la portabilitat és baixa, mentre que si la puntuació és 1 implica una alta portabilitat. El nivell intermedi de portabilitat se situa en 0,50 punts.

¹²⁷ Tal com s'indica a l'article 13.1 del Reial Decret 4/2010, les Administracions públiques utilitzaran preferentment la xarxa de comunicacions de les Administracions públiques espanyoles per a comunicar-se entre si, en concret, la Xarxa SARA que és el conjunt d'infraestructures de comunicació i serveis bàsics que interconnecta els sistemes d'informació de les Administracions públiques i permet l'intercanvi d'informació i serveis entre les mateixes. També es possibilita la interconnexió d'aquestes amb les institucions i administracions europees, a través de la Xarxa transeuropea sTESTA.

En el cas de Catalunya, destaca Via Oberta (VO) que és el conjunt de serveis desenvolupats pel Consorci AOC a fi de facilitar l'intercanvi telemàtic de dades i documents entre administracions i entitats públiques.

NOTA: tant la Xarxa SARA com Via Oberta estan concebuts per garantir el compliment de l'article 28.2 de la Llei 39/2015, segons el qual la ciutadania no està obligada a aportar aquelles dades o documents que ja resten en poder de les pròpies administracions o que han estat elaborades per aquestes. No obstant, es considera que aquestes xarxes de comunicacions despleguen les infraestructures i serveis necessaris per a l'intercanvi i transferència de dades entre sistemes d'informació de diferents organitzacions, més enllà del compliment del citat article.

- Exemple: per a il·lustrar-ho considerem que l'objecte d'avaluació és el Departament d'Educació com a proveïdor o cedent del dataset Personal docent en centres públics titularitat del Departament d'Educació a una altra organització que actua com a cessionària. Un cop avaluats el conjunt de dades transferit, les metadades associades i aquells aspectes que possibiliten l'intercanvi de dades (protocols i estàndards, convenis, infraestructures, etc.) es procedeix a respondre el qüestionari¹²⁸:
 - » A – 1 [El Departament d'Educació, com a ens que integra Via Oberta, té un conveni de col·laboració amb el Consorci AOC i, com a departament que forma part de l'estructura organitzativa de l'Administració de la Generalitat, també li aplica el Conveni Marc d'Interoperabilitat (CMI) subscrit per l'Administració de la Generalitat de Catalunya, el Consorci Localret, l'Ajuntament de Barcelona i el Consorci AOC].
 - » B – 1 [L'intercanvi telemàtic es realitza a través de Via Oberta, per tant, el Consorci AOC actua com a node d'interoperabilitat].
 - » C – 1 [El servei de Via Oberta manté traça de les consultes realitzades, concretament es contemplen els següents aspectes: data i hora de la transacció, organisme i usuari que realitza la consulta, el servei i modalitat de VO consultada, la finalitat de la consulta i el número d'expedient. Aquesta informació conservada dels intercanvis realitzats contempla la informació mínima obligatòria per a la traçabilitat que s'indica a l'apartat III.6, punt 5, de la NTI de Protocols d'intermediació de dades].
 - » D – 0 [El Departament d'Educació ni identifica ni publica models de dades d'intercanvi].
 - » E – 0 [No s'utilitzen estàndards oberts o d'ús generalitzat per als models de dades, ja que el Departament d'Educació ni identifica ni publica models de dades d'intercanvi].
 - » F – 0 [Els models de dades no estan ni identificats ni descrits, ja que el Departament d'Educació ni identifica ni publica models de dades d'intercanvi].

¹²⁸ Aquest exemple només és per mostrar com funciona i com s'aplica la mètrica, en cap cas s'ha realitzat un anàlisi del Departament d'Educació; per tant, la puntuació que es dona és fictícia, només és a tall d'exemple.

Així mateix, algunes de les respostes donades s'infereixen de la informació facilitada a la Guia d'implantació de Via Oberta (2015) del Consorci AOC i també de les dades del servei de Via Oberta (VO) que es pot consultar a la pàgina web del [Consorci AOC](#).

- » G – 0 [No s'utilitzen ni definicions ni codificacions estadístiques, atès que el Departament d'Educació ni identifica ni publica models de dades d'intercanvi].
- » H – 1 [S'utilitzen estàndards oberts tant pels datasets com per les metadades. Els conjunts de dades es poden exportar en múltiples formats, com per exemple el CSV. I les metadades segueixen el vocabulari de la Generalitat de Catalunya, que es pot consultar a la Guia d'implementament de les metadades del conjunt de dades per a la tramesa de dades obertes al portal de dades obertes de la Generalitat de Catalunya].
- » I – 1 [Disposa del servei Via Oberta del Consorci AOC].
- » J – 0 [No s'aplica el *Plan de direccionamiento e interconexión de redes en la Administración*, per a la seva interconnexió a través de les xarxes de comunicacions de les Administracions Públiques].
- » K – 1 [Menys del 75% de les dades que s'han transferit d'un sistema a un altre preserven les mateixes característiques de qualitat].

Amb les respostes anteriors s'aplica la fórmula per a conèixer el grau de portabilitat de les dades:

$$\gg (1 + 1 + 1 + 0 + 0 + 0 + 0 + 1 + 1 + 0 + 1) / 11 = 6 / 11 = 0,545 = 0,55$$

Finalment es conclou que la puntuació final obtinguda és 0,55, el que significa que el nivell de portabilitat és intermedi.

2. 4. 2. Pes de les mètriques i indicadors

L'objectiu d'aquest apartat és establir una puntuació final a partir del pes donat a cada una de les mètriques, atès que al tractar-se d'una proposta d'agregació i ampliació cada una de les mètriques presenta formes de càlcul diferents, raó per la qual l'harmonització es realitza sobre el resultat, no en la mesura. Així doncs, el pes (establert en percentatge) s'aplica a la puntuació resultant de la mètrica a fi d'obtenir la puntuació final¹²⁹. Altrament, tal com s'evidencia a la **Taula 14**, el pes donat a cada una de les mètriques no sempre és uniforme ja que hi ha elements ODQ que poden tenir un major o menor impacte en relació amb altres elements de la mateixa dimensió. Consegüentment, dins de cada una de les dimensions, però també entre dimensions, el pes de les mètriques és diferent, tot i que la suma final sempre ascendeix a 100%. Convé destacar que el pes de cada element ODQ pot variar segons el cas avaluat i el nivell de dificultat, ja que els percentatges d'importància s'alteren en funció del cas d'ús. Una bona mostra la trobem en aquells conjunts de dades que presenten una alta volatilitat on, per aquests casos, el pes de les propietats actualitat i volatilitat augmentarien degut a la seva rellevància, en detriment d'altres elements de la mateixa dimensió.

Dimensió ODQ	Element ODQ	Pes
Autenticitat	Definició / Documentació	25%
	Conformitat	25%
	Credibilitat	25%
	Primigènia	25%
Fiabilitat	Exactitud	25%
	Precisió	25%
	Granularitat	25%
	Rellevància	25%
Integritat	Traçabilitat	30%
	Completesa	35%
	Consistència	35%
Usabilitat	Llegibilitat / Interpretabilitat	20%
	Comprensibilitat	10%
	Georeferenciació	10%
	Obertura	20%
	Recuperabilitat	10%
	Localització	10%
	Eficiència	10%
	Comparabilitat	10%

¹²⁹ Per al disseny d'aquesta forma de càlcul s'ha pres com a referència la UNE 178301:2015.

Dimensió ODQ	Element ODQ	Pes
Disponibilitat	Pertinència temporal	10%
	Actualitat	10%
	Volatilitat	10%
	Accessibilitat	20%
	Reutilització	30%
	Seguretat / Privacitat	10%
	Portabilitat	10%

Taula 14. Pes de cada mètrica (Font: Elaboració pròpia, 2021).

2. 4. 3. Càlcul del valor final i del valor total

El valor final de cada mètrica s'estableix mitjançant un càlcul entre la puntuació obtinguda de la mètrica i el pes de la mateixa. La fórmula a aplicar per a cada una de les mètriques és la següent:

- Valor final = (Puntuació obtinguda x Pes) / Puntuació màxima

En el cas de les propietats conformitat, exactitud, completesa i consistència en què l'avaluació es realitza en diferents nivells, la puntuació obtinguda i la puntuació màxima és la suma de tots els nivells.

Finalment, per a obtenir el valor total de tots els elements ODQ és necessari sumar els valors finals de cada una de

les mètriques. A continuació es presenta la fórmula de valor total on N_i representa alguna magnitud d'elements ODQ ($i = 1, 2, \dots, n$) per a un número finit d'elements.

- Valor total = $N_1 + N_2 + N_3 + \dots + N_n$

El valor màxim total que es pot obtenir ascendeix a 500 punts. Altrament el valor total es correspon amb tres nivells d'assoliment de la qualitat de les dades obertes, tal com es detalla en la següent taula:

Valor total	Nivell de qualitat	Descripció
Menys de 167 punts	Nivell 1	Baixa qualitat de les dades obertes.
De 167 a 333 punts	Nivell 2	Qualitat intermèdia de les dades obertes.
Més de 333 punts	Nivell 3	Alta qualitat de les dades obertes.

Taula 15. Correspondència entre valor total i nivells de qualitat open data (Font: Elaboració pròpia, 2021).

2. 4. 4. Resum dels criteris de mesura dels elements ODQ

A l'Annex s'inclou una taula resum dels criteris de mesura dels elements ODQ amb indicació de la forma de càlcul, la puntuació màxima de cada mètrica i la font de la mètrica.

3. Prova de concepte del model de qualitat de les dades obertes

Aquest capítol, en el qual es detalla la prova de concepte del model de qualitat de les dades obertes, s'estructura en tres apartats que són els que a continuació s'enumeren: en un primer apartat s'exposa l'abast i limitacions de la prova de concepte. Seguidament es justifiquen les raons per les quals s'han seleccionat els datasets Codis postal per municipis de Catalunya i Comissaries per a realitzar la validació del model. En el tercer i últim apartat es desenvolupa el procés de mesurament de les mostres seleccionades per a, finalment, presentar una taula de resultats i un anàlisi DAFO del model ODQ.

3.1. Abast i limitacions de la prova de concepte

Amb l'objectiu de validar el model de qualitat de les dades obertes presentat al capítol 2, en les següents pàgines es realitza una prova de concepte sobre dues mostres seleccionades: els datasets Codis postal per municipis de Catalunya i Comissaries. El procés de validació s'ha efectuat sobre la totalitat de la primera mostra (1.414 registres) i pel que fa al dataset comissaries, la prova també s'ha realitzat sobre la totalitat (118 registres). Així mateix, el procés de mesurament s'ha dut a terme en el període comprès entre el 16 d'agost i el 22 d'agost de 2021.

La prova de concepte (*proof of concept* o PoC, en anglès) és definida pel TERMCAT, Centre de terminologia de la llengua catalana (s.a.) com una «*prova que implementa de manera resumida un mètode o una idea per tal de comprovar si es poden dur a la pràctica de manera satisfactòria.*» És a dir, es tracta d'una petita prova que permet avaluar l'aplicabilitat del model, tant a nivell teòric com metodològic, abans de la seva implementació en un projecte real.

Més concretament, aquest procés de validació experimental permet constatar si el model proposat és viable; i a més permet avançar en el desenvolupament del mateix a l'estimar quins aspectes s'adeqüen o no a la realitat, i si s'escau, incorporar els reajustaments necessaris.

Així doncs, la prova de concepte és un pas necessari i rellevant en el procés de desenvolupament del model de qualitat de les dades obertes, atès que proporciona informació sobre l'aplicabilitat del mateix en unes condicions el més properes possible a la realitat.

No obstant, convé destacar que hi ha mètriques del model que no es poden provar ja que per a la seva mesura és necessari conèixer el *back office* de l'organització, n'és un exemple l'element ODQ seguretat/privacitat. Per aquests casos, s'indica

durant el procés de mesurament que la propietat no ha pogut ser avaluada; mentre que per aquelles propietats en què l'avaluació es realitza directament sobre les mostres seleccionades (datasets i metadades associades) sí s'ha pogut realitzar la prova amb èxit, atès que el procés de mesurament s'efectua sobre les sortides del sistema. D'aquestes consideracions s'infereix que el resultat final de la prova de concepte serà provisional ja que hi ha elements ODQ que no es poden avaluar degut a la falta d'informació. Tanmateix, es considera que de la prova de concepte no només és important el resultat, sinó també l'aprenentatge que es pot extraure del procés de validació experimental (Saldaña, en Leal, El Periódico, 2019¹³⁰).

En darrer terme es recorda, tal com s'ha vist a l'apartat 1.3.2, que l'ecosistema de dades obertes funciona i es comporta com un sistema cibernètic; per tant — ja sigui en aquells elements ODQ la mesura dels quals s'obté de les sortides del sistema o en aquells altres on l'avaluació es realitza sobre els sistemes i processos interns —, els resultats de les mètriques constitueixen la informació dels sistemes de retroalimentació. Aquesta informació retornarà als proveïdors de les dades i servirà, si s'escau, per a realitzar els canvis necessaris en la mateixa font o durant el processament de les dades.

3. 2. Justificació dels conjunts de dades seleccionats

Per a realitzar la prova de concepte s'han seleccionat dos conjunts de dades, concretament els datasets Codi postal per municipis de Catalunya i Comissaries que provenen del sistema de dades obertes de la Generalitat de Catalunya. El primer, procedeix del Portal de dades obertes de la Generalitat, en canvi la segona mostra es localitza al Portal de dades obertes dels Mossos d'Esquadra. Ambdós portals conformen el sistema de dades obertes de la Generalitat, en el qual la plataforma de dades obertes de la Generalitat constitueix el catàleg de referència per a localitzar fonts de dades obertes; no obstant, en alguns casos, els conjunts de dades es troben emmagatzemats i disponibles en altres portals més específics, tal com el Portal de dades obertes dels Mossos d'Esquadra o el Portal de dades obertes de l'Idescat¹³¹.

A continuació es presenta la informació bàsica de les dues mostres seleccionades:

¹³⁰ Extret de l'article <https://www.elperiodico.com/es/activos/innovadores/20191113/por-que-es-importante-la-prueba-de-concepto-para-tu-empresa-7733441>

¹³¹ Per a més informació sobre el sistema de dades obertes de la Generalitat de Catalunya es remet a la pàgina web de Govern obert de la Generalitat, concretament a la secció Informació per a desenvolupadors: https://governobert.gencat.cat/ca/dades_obertes/reutilitzacio-dades/informacio-desenvolupadors/

Nom dataset: Codis postal per municipis de Catalunya

- **Classificació NTI-RISP:** Urbanisme i infraestructures.
- **Descripció:** Taula amb els codis assignats pels serveis postals per tal de facilitar la distribució del correu, associats a municipis de Catalunya.
- **Cronologia:** N/A
- **Proveïdor:** Catàleg Tècnic de Dades - Institut d'Estadística de Catalunya (IDESCAT).
- **Lloc de publicació:** Portal de dades obertes de la Generalitat de Catalunya.
- **Data creació:** 25 de maig de 2021.
- **Data última actualització:** 25 de maig de 2021.
- **Freqüència actualització:** Variable.
- **Nombre de registres:** 1.414
- **Nombre de columnes:** 4
- **Datasets relacionats:** N/A
- **URI:** <https://analisi.transparenciacatalunya.cat/Urbanisme-infraestructures/Codis-postal-per-municipis-de-Catalunya/tp8v-a58g>

Nom dataset: Comissaries

- **Classificació NTI-RISP:** Sector Públic. (Al Portal de dades obertes de la Generalitat es classifica el web de dades obertes dels Mossos d'Esquadra com a Sector Públic).
- **Descripció:** Taula amb la localització de les comissaries (Àrea Bàsica Policial i Comissaria de Districte) de la Policia de la Generalitat - Mossos d'Esquadra.

- **Cronologia:** 2017 – actualitat.
 - » És una sèrie temporal. La informació s'actualitza en diferents recursos, de tal forma que hi ha un fitxer per any.
- **Proveïdor:** Direcció General de la Policia.
- **Lloc de publicació:** Portal de dades obertes dels Mossos d'Esquadra.
- **Data creació:** 1 de març de 2017.
- **Data última actualització:** 27 d'abril de 2021.
- **Freqüència actualització:** Anual.
- **Nombre de registres:** 118
- **Nombre de columnes:** 11
- **Datasets relacionats:** N/A
- **URL:** https://mossos.gencat.cat/ca/els_mossos_desquadra/indicadors_i_qualitat/dades_obertes/cataleg_dades_obertes/dades-organitzatives/

Els motius pels quals s'han seleccionat aquests datasets són els següents:

1. En primer lloc, la Directiva (UE) 2019/1024 del Parlament Europeu i del Consell de 20 de juny de 2019 relativa a les dades obertes i la reutilització de la informació del sector públic, introdueix el concepte de conjunts de dades d'alt valor per a referir-se a aquells conjunts la reutilització dels quals suposa considerables beneficis per a la societat, el medi ambient i l'economia, en particular degut a la seva «*idoneidad para la creación de servicios de valor añadido, aplicaciones y puestos de trabajo nuevos, dignos y de calidad, y del*

número de beneficiarios potenciales de los servicios de valor añadido y aplicaciones basados en tales conjuntos de datos.» (article 2, p. 70). A l'annex I de la citada directiva es fixa una llista de categories temàtiques de dades d'alt valor, d'entre les quals en destaquen les dades geoespacionals que en el considerant 66 s'indica que són aquelles relacionades amb codis postals, mapes nacionals i locals. Per tant, el dataset Codis postal per municipis de Catalunya és un conjunt de dades d'alt valor, segons la citada directiva europea; raó per la qual s'ha considerat oportú avaluar la seva qualitat.

2. En segon lloc, a simple vista trobem que hi ha diferències a nivell de qualitat entre ambdues mostres seleccionades. Per exemple, en el dataset Comissaries es constata que s'informa de poques metadades i, a més, no hi ha cap informació relativa sobre el significat de cada un dels atributs. Per contra, el dataset Codis postal per municipis de Catalunya segueix l'estàndard de la guia tècnica de la Generalitat, on hi destaca la incorporació de metadades relacionades amb les columnes (nom, descripció i tipus). Així doncs, s'han escollit dues mostres que presenten diferències de qualitat a fi de validar si el model s'ajusta a la realitat.
3. En tercer lloc, les dues mostres seleccionades poden ser comparades amb altres conjunts de dades o amb informació procedent d'una font de referència. En el

cas del dataset sobre codis postals la comparativa es pot realitzar amb el sistema de codificació oficial de l'organisme estatal de Correus¹³² i també amb l'Institut d'Estadística de Catalunya (INE) i amb altres datasets de l'Idescat. D'altra banda per al dataset sobre comissaries la comparativa es pot realitzar amb la informació procedent de l'INE o l'Idescat, cas del codi INE o del nom dels municipis i comarques.

En aquest sentit, disposar de fonts de referència amb les que realitzar la comparativa és d'especial rellevància per a poder avaluar determinats elements ODQ, com per exemple la conformitat o l'exactitud.

4. Finalment, un últim motiu pel qual s'ha escollit el dataset Comissaries és degut a que es tracta d'una sèrie temporal i, per tant, l'històric és rellevant. Per contra, el dataset Codis postal per municipis de Catalunya es caracteritza perquè els seus valors no es capturen en períodes de temps diferents, el que implica que no disposa d'històric.

¹³² Per a més informació es remet a la secció de metodologia de la divisió territorial postal de l'Institut d'Estadística de Catalunya: <https://www.idescat.cat/codis/?id=50&n=21&inf=m&QI&id=50&n=21&inf=s>

3. 3. Procés de mesurament

3. 3. 1. Consideracions bàsiques

Per a realitzar el procés de mesurament dels datasets seleccionats, prèviament s'han descarregat en format CSV dels portals corresponents. En el cas del dataset Codis postal per municipis de Catalunya, que s'ha exportat des del Portal de dades obertes de la Generalitat de Catalunya, s'ha hagut de realitzar algunes accions a fi de poder realitzar l'anàlisi del conjunt de dades; concretament des de l'opció "texto en columnas" del programa Microsoft Excel s'ha dividit el contingut que es trobava en una mateixa columna en diferents columnes, indicant que el delimitador que separa els diferents atributs són les comes. Aquesta acció no ha calgut per al dataset Comissaries atès que cada atribut ja es trobava en columnes diferents.

	A	B	C	D
1	Identificador,Codi postal	Codi municipi	Nom municipi	
2	0001.08630.080018	Abrera		
3	0002.08256.080023	Aguilar de Segarra		
4	0003.08281.080023	Aguilar de Segarra		
5	0004.08328.080059	Alcella		
6	0005.08587.080044	Alpens		
7	0006.08480.080057	"Ametlla del Vallès, 1"		
8	0007.08350.080060	Arenys de Mar		
9	0008.08358.080076	Arenys de Munt		
10	0009.08717.080062	Argençola		
11	0010.08310.080095	Argentona		
12	0011.08271.080109	Artes		
13	0012.08610.080116	Avià		
14	0013.08611.080116	Avià		
15	0014.08279.080121	Avinyó		
16	0015.08734.080137	Avinyonet del Penedès		
17	0016.08792.080137	Avinyonet del Penedès		
18	0017.08793.080137	Avinyonet del Penedès		
19	0018.08796.080137	Avinyonet del Penedès		
20	0019.08591.080142	Aiguafreda		

Figura 23. Dataset Codis postal per municipis de Catalunya. (Font: Elaboració pròpia, 2021)

En relació amb les metadades associades als conjunts de dades, la seva avaluació es realitza des dels mateixos portals atès que no es poden descarregar, només visualitzar a les plataformes. Altrament, hi ha elements ODQ com la comprensibilitat o l'accessibilitat que el procés de mesura es realitza en el frontal web, per exemple, si el portal web disposa de declaració d'accessibilitat. Finalment, convé recordar tal com s'ha esmentat a l'apartat 3.1 que algunes de les propietats no és possible avaluar-les ja que és necessari conèixer l'arquitectura tecnològica de l'organització, els sistemes d'origen i de destí, aspectes relacionats amb l'emmagatzemament i preservació de les dades, etc. És a dir, el procés de mesurament s'ha d'efectuar en el *back office* i no en el frontal web o directament sobre les sortides del sistema (datasets i metadades associades).

3. 3. 2. Avaluació del dataset Codis postal per municipis de Catalunya

En el present subapartat es presenten els resultats obtinguts per a cada una de les dimensions i elements ODQ que conformen el model de qualitat de les dades obertes:

1. Dimensió Autenticitat.

- Definició/Documentació.** Aquest element ODQ s'avalua a partir de les metadades associades a les columnes del dataset, les quals ofereixen informació sobre el significat de l'atribut, el tipus de dada i també hi ha notes sobre

interpretació, cas de les columnes identificador i codi postal. No obstant, es considera que en el cas de la columna codi municipi es podria explicar els possibles valors o enllaçar amb la pàgina de l'Idescat per a consultar aquests valors. La puntuació màxima obtinguda és 3 punts.

b. Conformitat. Aquest element es mesura sobre aquells valors considerats crítics en el dataset que, en aquest cas, s'estima que dels quatre atributs existents (identificador, codi postal, codi municipi i nom municipi) són crítics el codi postal, el codi municipi i el nom municipi. Així mateix, també s'efectua l'avaluació sobre les metadades associades tant al dataset com a les columnes. Amb tot, per aquest cas d'estudi el que es mesura són els següents aspectes¹³³:

- Si el codi postal compleix amb els estàndards de definicions de dades, concretament, si es tracta d'un alfanumèric de 5 dígitos enters:

D1	D2	D3	D4	D5
----	----	----	----	----

- » Els dígitos D1 i D2 corresponen a la província de la direcció postal.
- » El dígit D3 indica l'encaminament dins la província. Per exemple, un 0 en aquesta posició indica que el codi pertany a la capital de la província.
- » El dígit D4 representa la ruta, dada pròpia del servei postal.
- » El dígit D5 representa el repartiment, dada pròpia del servei postal.

Els registres amb codi superior a 99990 són casos especials, propis del catàleg tècnic de dades.

- Si el codi municipi compleix amb els estàndards de definicions de dades, concretament, si es tracta d'un alfanumèric de 6 dígitos enters.
- Si el nom municipi compleix amb els estàndards de definicions de dades, concretament, si es tracta d'un alfanumèric de 100 caràcters.

¹³³ La informació relacionada amb els estàndards de definicions de dades per als valors codi postal, codi municipi i nom municipi s'ha extret de la informació facilitada sobre els atributs tant a les metadades de les columnes com al detall de les dades de referència del dataset Codis postal per municipis de Catalunya que es descarrega de la pàgina del CTTI: <https://canigo.ctti.gencat.cat/dadesref/dadesref/>

- Si les metadades compleixen amb els estàndards de definicions de metadades, en particular amb la guia d'emplenament de les metadades del conjunt de dades per a la tramesa de dades obertes al Portal de dades obertes de la Generalitat de Catalunya, tant pel que fa a les metadades que s'informen a nivell de dataset com a nivell de columnes. En el cas d'aquelles metadades que no apareixen a la guia tècnica de la Generalitat, per exemple la data de darrera actualització de les dades, es comprova la seva conformitat en relació amb el vocabulari DCAT que s'estableix a la NTI-RISP.

A continuació es procedeix a aplicar, en primer lloc, la fórmula a nivell de valor per a cada un dels tres atributs crítics:

- Conformitat codi postal: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$
- Conformitat codi municipi: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$

- Conformitat nom municipi¹³⁴: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$

De les fórmules anteriors es conclou que la conformitat del valor codi postal és del 100%, i la dels valors codi municipi i nom municipi del 100% respectivament. En conjunt, la conformitat mitjana a nivell de valor és del 100%.

També es mesura la conformitat del registre que queda de la següent forma: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$. Del total de files, que ascendeix a 1.414, s'han considerat que totes són vàlides, ja que cap dels registres conté valors no vàlids. Així doncs, la conformitat de registre ascendeix al 100%.

Finalment, pel que fa a les metadades no hi ha cap fórmula associada a les mateixes. No obstant, la fórmula que s'aplica a nivell de registre es pot adaptar per a mesurar les metadades, quedant de la següent forma:

¹³⁴ Per a comprovar que el nom dels municipis no supera els 100 caràcters s'ha fet servir la funció LARGO de Microsoft Excel, la qual comptabilitza el nombre de caràcters d'una cel·la.

- Conformitat de les metadades % = (Nombre de metadades vàlides¹³⁵ x 100) / Nombre total de metadades¹³⁶

En aplicació de la fórmula anterior, la conformitat de les metadades és $(12 \times 100) / 20 = 1.200 / 20 = 60$. Convé destacar que del total de metadades identificades (20) n'hi ha 8 que es consideren no vàlides ja que no compleixen amb els formats i/o termes controlats que s'especifiquen:

- Llicència: no segueix la taula codificada que s'indica a la guia tècnica de la Generalitat de Catalunya.
- Enllaç font: amb aquesta metadada s'enllaça a informació relativa a la llicència d'ús; no obstant, a la guia tècnica s'indica que aquesta metadada ha de enllaçar a la URL de la institució o organisme que publica les dades amb el corresponent codi numèric.
- Tipus actor: no segueix la taula codificada que s'indica a la guia tècnica de la Generalitat de Catalunya.

- Organisme o institució: no segueix la taula codificada que s'indica a la guia tècnica de la Generalitat de Catalunya.
- Idioma: no segueix la taula codificada que s'indica a la guia tècnica de la Generalitat de Catalunya, falta especificar (ca) al costat de català.
- Dades creades: no segueix l'esquema de la ISO 8601, segons s'indica a la NTI-RISP.
- Darrera actualització de les dades: no segueix l'esquema de la ISO 8601, segons s'indica a la NTI-RISP.
- Darrera actualització de les metadades: no segueix l'esquema de la ISO 8601, segons s'indica a la NTI-RISP.

A partir del resultat obtingut a l'aplicar la fórmula, es conclou que la conformitat de les metadades en relació amb la guia tècnica i amb la NTI-RISP (aquesta última per a les metadades associades a dades) és del 60%

¹³⁵ La regla que determina si una metadada és vàlida o no ho és resideix en si aquesta compleix amb les definicions i regles que la identifiquen i normalitzen, especialment els camps tipus d'atribut, format i termes controlats.

¹³⁶ Per a determinar el nombre total de metadades es computa cada un dels elements de metadades que descriuen tant el dataset com les columnes. No obstant, només es compta un sol cop les metadades utilitzades més d'una vegada, n'és un exemple la metadada nom de columna ja que es repeteix en funció del nombre de columnes que tingui el conjunt de dades.

c. Credibilitat. El resultat del qüestionari queda de la següent forma:

- A – 1 [La informació continguda en el dataset es pot verificar independentment, per exemple directament a la pàgina web de l'Idescat o a l'INE].
- B – 1 [Sí, la descripció del dataset és realitzada per l'Idescat que és una organització de confiança].
- C – 1 [Tant el propietari de les dades, que és la Generalitat de Catalunya, com el proveïdor de les mateixes, que al Portal de dades obertes s'indica que provenen del Catàleg Tècnic de Dades de l'Institut d'Estadística de Catalunya, són organitzacions de confiança].
- D – 0 [No hi ha constància de que les dades estiguin certificades a partir d'auditories internes i/o externes per part d'organitzacions de confiança].

Del resultat anterior s'aplica la fórmula corresponent: $(1 + 1 + 1 + 0) / 4 = 3 / 4 = 0,75$. En

conclusió, del resultat anterior es confirma que el nivell de credibilitat del dataset és alt ja que ha obtingut una puntuació de 0,75.

d. Primigènia. La puntuació màxima obtinguda és 2 ja que es tracta de dades primàries que provenen del Catàleg Tècnic de Dades de Referència i que presenten el màxim nivell de detall, atès que es tracta de dades bàsiques d'obligat compliment orientades a propòsits de classificació i de suport a la gestió¹³⁷. No s'obté la puntuació màxima (3) ja que no hi ha dades agregades complementàries a les primàries per tal de facilitar altres usos; consegüentment no hi ha cap mètode d'agregació publicat.

2. Dimensió Fiabilitat.

a. Exactitud. Aquest element es mesura sobre aquells valors considerats crítics en el dataset que, en aquest cas, s'estima que dels quatre atributs existents (identificador, codi postal, codi municipi i nom municipi) són crítics el codi

¹³⁷ Des del Centre de Telecomunicacions i Tecnologies de la Informació (CTTI) es porta a terme una gestió tècnica de les dades la finalitat de la qual és establir un model per a la gestió tècnica i control dels tres grans grups de dades identificades: dada mestra, dades de referència i dades de negoci. Pel que fa a les dades de referència «són un tipus especial de dades orientades amb propòsits de classificació (codificacions i estàndards) o de suport a la gestió; en essència són codis que bàsicament transformen dades en informació significativa pel negoci.» (CTTI, 2021). Altrament, des del CTTI s'ha posat a disposició de la Generalitat de Catalunya la primera versió del Catàleg Tècnic de Dades de Referència que inclou aquells conjunts de dades de referència que són d'obligat ús pels nous sistemes d'informació; d'entre aquestes dades en destaca el dataset Codis postal per municipis de Catalunya de l'Idescat. Per a més informació es remet a <https://canigo.ctti.gencat.cat/dadesref/gestiodades/>

postal, el codi municipi i el nom municipi. Per tant, la mesura es realitza en relació als valors que conformen aquests atributs. Així mateix, per aquest cas d'estudi el que es mesura són els següents aspectes:

- Si el codi postal compleix amb el sistema de codificació oficial de l'organisme estatal de Correus. Tanmateix, la base de dades de codis postals està subjecta a comercialització, i, per tant, no és d'accés lliure¹³⁸. Com a opció, s'ha verificat el codi postal a la pàgina web de l'Idescat, concretament, a la secció Divisió territorial postal, i també s'han tingut en consideració les regles específiques que hi consten a la informació sobre la columna en relació amb els registres amb codi superior a 99990.
- Si el codi municipi i el nom municipi es corresponen amb els codis i denominacions que es localitzen tant a la pàgina de l'Idescat com al Instituto Nacional de Estadística (INE). A diferència de la columna codi postal no s'estableixen regles específiques per aquests atributs.

A continuació es procedeix a aplicar, en primer lloc, la fórmula a nivell de valor per a cada un dels tres atributs crítics:

- Exactitud codi postal: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$
- Exactitud codi municipi: $(1.412 \times 100) / 1.414 = 141.200 / 1.414 = 99,86$ [En relació amb el codi municipi s'han comptat com a no exactes els valors 999998 i 999999 ja que no hi consten ni a l'Idescat ni a l'INE, i a més no hi ha cap regla específica en relació amb aquests valors].
- Exactitud nom municipi: $(1.411 \times 100) / 1.414 = 141.100 / 1.414 = 99,79$ [En relació amb el nom municipi s'han comptat com a no exactes els valors No consta i Altres/Diversos ja que no hi consten ni a l'Idescat ni a l'INE, i a més no hi ha cap regla específica en relació amb aquests valors. Tampoc és exacte el valor Bigues i Riells atès que des de juliol de 2021 aquest municipi es denomina oficialment Bigues i Riells de Fai¹³⁹. Aquest canvi es troba incorporat al dataset de municipis que es troba a la pàgina web de l'Idescat, però no es recull

¹³⁸ Per a més informació es remet a <https://datos.gob.es/es/peticiones-datos/base-de-delimitaciones-de-los-codigos-postales-de-espana>

¹³⁹ Per a més informació es remet a la [Resolució PRE/2023/2021](#), de 29 de juny, per la qual es dona conformitat al canvi de nom del municipi de Bigues i Riells, que passa a denominar-se Bigues i Riells del Fai, publicat el 2 de juliol de 2021 al Diari Oficial de la Generalitat de Catalunya (DOGC).

ni a la mostra analitzada, que va ser actualitzada amb data 25 de maig de 2021, ni tampoc al dataset de l'INE que té una data d'última actualització de l'1 de gener de 2010. Amb tot, el valor Bigues i Riells no es correspon amb el valor que hi ha al dataset Municipis de l'Idescat; per tant, es tracta d'un valor inexacte].

De les fórmules anteriors es conclou que l'exactitud del valor codi postal és del 100%, la dels valors codi municipi i nom municipi del 99,86% i 99,79%, respectivament. En conjunt, l'exactitud mitjana a nivell de valor és del 99,88%.

També es mesura l'exactitud del registre que queda de la següent forma: $(1.411 \times 100) / 1.414 = 141.100 / 1.414 = 99,79$. Del total de files, que ascendeix a 1.414, s'han considerat que tres són inexactes, concretament aquelles on es localitzen els valors no exactes. Finalment, de la fórmula anterior es conclou que la correctesa a nivell de registre és del 99,79 %.

b. Precisió. Aquest element ODQ no s'ha pogut avaluar ja que el dataset no conté valors numèrics resultat d'una operació; consegüentment, no és possible mesurar si es contenen les xifres significatives imprescindibles.

c. Granularitat. El resultat del qüestionari és el que a continuació es detalla:

- A – 1 [Les dades publicades són primàries i provenen del Catàleg Tècnic de Dades de l'Institut d'Estadística de Catalunya].
- B – 1 [La freqüència d'actualització és variable, és a dir, les dades s'actualitzen cada cop que es produeixin modificacions en el dataset. Es considera que l'interval és adequat ja que es tracta de dades amb una nul·la o baixa volatilitat].
- C – 1 [Sí, la granularitat de les dades és l'adequada ja que s'indica l'identificador del Catàleg Tècnic de Dades, el codi postal, el codi del municipi i el nom del municipi. Aquests dos últims atributs compleixen amb les especificacions de la guia tècnica de la Generalitat de Catalunya on per a consignar el municipi es recomana consignar en camps diferents el codi i el nom (2020, 31)].

A partir de les respostes anteriors, s'aplica la fórmula corresponent: $(1 + 1 + 1) / 3 = 3 / 3 = 1$. Del resultat anterior es conclou que el dataset té una alta granularitat ja que ha obtingut la puntuació màxima, 1 punt.

d. Rellevància. En relació amb l'abast de les dades, no s'ha trobat cap dada oficial sobre el total de codis postals existents a Espanya, que és la totalitat de l'univers de codis postals. No obstant, a Wikipedia¹⁴⁰ s'indica que a l'actualitat hi ha 11.752 codis postals; per tant, com a referència es pren en consideració aquesta dada, a falta d'una dada oficial per part d'una organització autoritzada. Amb aquesta dada, es calcula la cobertura del dataset: $(1.414 \times 100) / (10.338 + 1.414) = 141.400 / 11.752 = 12,03$. Del resultat anterior es confirma que la mostra analitza representa el 12,03% del total de codis postals. En un altre ordre de coses, també és necessari mesurar la rellevància de la mostra per la qual cosa, prèviament s'ha de determinar quins paràmetres són necessaris per a la finalitat prevista, que, en aquest cas, es considera que són el codi postal i el municipi. Ambdós paràmetres tenen la seva correlació en el dataset, concretament el codi postal es correlaciona amb el atribut codi postal i el municipi amb els atributs codi municipi i nom municipi. Amb aquests aspectes, s'aplica la fórmula de rellevància de les dades: $(2 / 2) \times 100 = 1 \times 100 = 100$.

Del resultat anterior es conclou que la rellevància del contingut és del 100%.

3. Dimensió Integritat.

a. Traçabilitat. Les respostes al qüestionari per avaluar el grau de traçabilitat són les següents:

- A – 1 [Sí, hi ha la metadada productor (dades proveïdes per) en la que s'informa de la procedència de les dades que, en aquest cas, és el Catàleg Tècnic de Dades - Institut d'Estadística de Catalunya (IDESCAT)].
- B – 0 [No, existeix la metadada de productor però en cap cas es pot fer el seguiment des del productor fins a la publicació al Portal de dades obertes].
- C – 0,50 [Sí, existeix la metadada dades creades en la que s'informa de la data de publicació del dataset. És important subratllar que aquesta data informa de quan va ser publicat el dataset, però en cap cas de quan va ser creat].

¹⁴⁰ Per a més informació es remet a la secció o article "Código postal de España" de Wikipedia, que es localitza a https://es.wikipedia.org/wiki/C%C3%B3digo_postal_de_Espa%C3%B1a

- D – 0,50 [Sí, tant de la data de les metadades com del dataset atès que existeixen les metadades darrera actualització de les dades i darrera actualització de les metadades].
- E – no valorat [Falta informació per a poder valorar aquest ítem].
- F – no valorat [Falta informació per a poder valorar aquest ítem].

A partir de les respostes anteriors no s'ha pogut establir el grau de traçabilitat del dataset ja que falta informació per a poder avaluar en la seva totalitat aquest element ODQ.

b. Completesa. Aquest element es mesura sobre aquells valors considerats crítics en el dataset que, en aquest cas, s'estima que dels quatre atributs existents (identificador, codi postal, codi municipi i nom municipi) són crítics el codi postal, el codi municipi i el nom municipi. Així mateix, al revisar el dataset no s'han localitzat valors perduts (valors nuls, en blanc, etc.) Amb aquesta informació, s'aplica primerament la fórmula per avaluar cada un dels elements de dades crítics:

- Completesa del valor codi postal: $((1.414 - 0 - 0 - 0) / 1.414) \times 100 = (1.414 / 1.414) \times 100 = 1 \times 100 = 100$
- Completesa del valor codi municipi: $((1.414 - 0 - 0 - 0) / 1.414) \times 100 = (1.414 / 1.414) \times 100 = 1 \times 100 = 100$
- Completesa del valor nom municipi: $((1.414 - 0 - 0 - 0) / 1.414) \times 100 = (1.414 / 1.414) \times 100 = 1 \times 100 = 100$

La completesa per a cada un dels valors ascendeix al 100%, el que representa que la completesa mitjana a nivell d'element de dades és del 100%.

A continuació es mesura la completesa de registre: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$. Del resultat anterior es conclou que la completesa de registre ascendeix al 100%.

En relació amb el dataset, es compara la mostra analitzada amb el dataset al que es pot accedir des de la secció detall de dades de referència a la pàgina del CTTI, que és el mateix que el de la mostra analitzada. Amb aquesta informació, s'aplica la fórmula: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$. Del resultat anterior s'infereix que la completesa a nivell del conjunt de

dades ascendeix al 100%. Altrament si es compara la mostra amb el dataset Divisió territorial postal que es descarrega del web de l'Idescat, es confirma que la mostra disposa de 1.414 registres i el dataset de referència de 1.412 atès que no es comptabilitzen els dos registres propis del catàleg tècnic de dades de referència. Així mateix, si obviem aquests dos registres propis del catàleg es constata que ambdós datasets contenen 1.412 files, quedant la fórmula de la següent forma: $(1.412 \times 100) / 1.412 = 141.200 / 1.412 = 100$. Del resultat anterior es conclou que també en relació al dataset Divisió territorial postal la completesa és del 100%.

Finalment, pel que fa a les metadades no hi ha cap fórmula associada a les mateixes. No obstant, la fórmula que s'aplica a nivell de registre es pot adaptar per a mesurar les metadades, quedant de la següent forma:

- $\text{Completesa de les metadades} = (\text{Nombre de metadades obligatòries que s'informen} \times 100) / \text{Nombre total de metadades obligatòries a informar}$.

Amb la fórmula anterior es mesura l'absència o no de metadades obligatòries en relació amb la totalitat, és a dir, s'avalua si s'informen de totes

les metadades obligatòries que marca el vocabulari de metadades que, en aquest cas, és la guia tècnica de la Generalitat de Catalunya. Al revisar la guia es constata que hi ha 23 metadades obligatòries, de les quals, tres són condicionals ja que s'informen en cas de que hi hagi contingut destacat, i altres tres són obligatòries però la seva visualització és privada, per la qual cosa no és possible establir amb exactitud la completesa a nivell de metadades ja que només hi ha accés a avaluar les que són públiques i es visualitzen en el Portal de dades obertes. Tanmateix, amb la finalitat d'obtenir una puntuació aproximada la valoració es realitza sobre les metadades públiques, sense incloure les condicionals; per tant, el total de metadades es queda en 17. A partir d'aquesta dada s'aplica la fórmula: $(14 \times 100) / 17 = 1.400 / 17 = 82,35$. Del resultat anterior es conclou que la completesa a nivell de metadades obligatòries és del 82,35%.

- c. **Consistència.** Per mesurar la consistència s'avaluen quatre nivells: combinació d'elements de dades dins una mateixa taula, registre dins un mateix dataset, registres creuats i conjunt de dades.

Pel que fa a la combinació d'elements de dades dins un mateix dataset el que particularment es mesura es la consistència entre els valors

dels atributs codi municipi i nom municipi, i es constata la seva combinació i consistència en un dataset de referència que és el de municipis que es troba a la pàgina de l'Idescat¹⁴¹. No obstant, a diferència de la mostra analitzada hi ha dues combinacions que no hi consten ja que són pròpies de Catàleg tècnic de dades de referència, en concret són 999998 – No consta i 999999 – Altres/Diversos. Tanmateix, aquestes combinacions s'han donat com a vàlides però és necessari la seva verificació al Catàleg tècnic de dades de l'Idescat. A partir de les consideracions anteriors s'aplica la fórmula: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$. El resultat anterior significa que la consistència de la combinació dels valors dels atributs codi municipi i nom municipi és del 100%.

En relació amb la consistència de registre la fórmula queda de la següent forma: $(1.414 \times 100) / 1.414 = 141.400 / 1.414 = 100$. És a dir, la consistència dels registres dins el dataset és del 100%.

En quant a la consistència de registres creuats es mesura la consistència entre la mostra inicial i el dataset Municipis Catalunya Geo¹⁴² que també es localitza al Portal de dades obertes de la Generalitat de Catalunya. Entre ambdós datasets hi ha 948 registres creuats, dels quals no hi ha cap inconsistència ja que les dades no presenten contradiccions, són coherents i equivalents o idèntiques. Arran d'aquestes consideracions, la fórmula a aplicar és $(948 \times 100) / (948 + 0) = 94.800 / 948 = 100$. Del resultat anterior es conclou que la consistència de registres creuats és del 100%. En relació amb el resultat convé destacar la relació, ja apuntada a l'apartat 2.4.1, entre les propietats exactitud i consistència ja que es confirma que si un valor és consistent no necessàriament implica que el valor sigui exacte o vàlid, tal és el cas del valor Bigues i Riells.

Finalment, pel que fa a la consistència del conjunt de dades no s'ha pogut avaluar ja que no es disposa d'informació per a poder mesurar la consistència del dataset entre el sistema d'origen i el sistema de destí.

¹⁴¹ Per a consultar el dataset de referència es remet a la secció municipis de l'Institut d'Estadística de Catalunya (Idescat): <http://www.idescat.cat/codis/?id=50&n=9&lang=es>

¹⁴² El dataset Municipis Catalunya Geo és el llistat de municipis de Catalunya amb indicació de la comarca a on pertanyen i amb les dades de geolocalització de l'Institut Cartogràfic i Geològic de Catalunya. El proveïdor de les dades és el Catàleg Tècnic de Dades - Institut d'Estadística de Catalunya (Idescat), Institut Cartogràfic i Geològic de Catalunya (ICGC), i la URL per accedir-hi és la següent: <https://analisi.transparenciacatalunya.cat/Urbanisme-infraestructures/Municipis-Catalunya-Geo/9aju-tpwc>

4. Dimensió Usabilitat.

a. Llegibilitat/Interpretabilitat. Un cop analitzat el dataset es respon al qüestionari per avaluar el grau de llegibilitat/interpretabilitat:

- A – 1 [Sí, tant el codi postal com el codi municipi es basen en llistes de codis que permeten identificar els municipis i el codi postal associat al mateix].
- B – 0 [Al dataset no hi ha dades relacionades amb dates, però a les metadades si n’hi ha i no es segueix cap tipus d’estàndard específic].
- C – 1 [Sí, les dades es poden descarregar en CSV, XML, RDF, RSS i TSV que són formats processables per màquina].
- D – 0,50 [Hi ha metadades assignades a nivell de dataset i de columna].
- E – 0,75 [Sí, s’utilitza la guia d’implementació per a l’homogeneïtzació de les metadades del Catàleg de dades obertes de la Generalitat de Catalunya].

A partir de les respostes anteriors s’aplica la fórmula corresponent: $(1 + 0 + 1 + 0,50 + 0,75) / 5 = 3,25 / 5 = 0,65$. Finalment es conclou que la puntuació obtinguda és 0,65 punts.

b. Comprensibilitat. Un cop analitzat el dataset es respon al qüestionari per avaluar el grau de comprensibilitat:

- A – 1 [Sí, hi ha metadades a nivell de dataset i de columnes].
- B – 0 [Tot i que hi ha metadades que contenen informació descriptiva de les columnes el que facilita la comprensió dels atributs que conformen el conjunt de dades, no n’hi ha informació d’acompanyament a les dades tal com visualitzacions, glossaris, etc.].
- C – 1 [Sí, des del Portal de dades obertes de la Generalitat de Catalunya concretament des de l’opció “Veure les dades” es pot seleccionar veure les dades com a taula, com a llista enriquida o com a fila única. Així mateix, també es poden generar visualitzacions, filtrar i analitzar, entre altres aspectes].

Amb la informació anterior s’aplica la fórmula corresponent: $(1 + 0 + 1) / 3 = 2 / 3 = 0,66$. Del resultat anterior es conclou que la puntuació obtinguda és 0,66 sobre una puntuació màxima d’1 punt.

c. Georeferenciació. Tal com s’informa a la meta-dada informació geogràfica el tipus d’informació

geogràfica que s'aporta és un codi d'element, definit com un codi alfanumèric que identifica unívocament un element geogràfic amb el que s'associen les dades (Generalitat de Catalunya, 2020, 21). N'és un exemple el codi de municipi o el codi postal. D'aquestes consideracions s'infereix que la puntuació obtinguda per aquest element ODQ és 1 punt, atès que el conjunt de dades geogràfiques no està publicat com a dades obertes georeferenciades explícitament amb coordenades, però sí es troba georeferenciat de forma implícita.

- d. Obertura.** Hi ha la possibilitat de descarregar les dades en format RDF/XML, durant l'anàlisi de les mateixes es comprova que l'URI del dataset funciona i redirigeix al conjunt de dades que es troba al Portal de dades obertes de la Generalitat de Catalunya.

No obstant, l'URI que identifica cada un dels registres dona error ja que al clicar sobre l'enllaç s'accedeix al registre en format JSON amb l'API de dades d'accés obert de Socrata (SODA, per la seva sigla en anglès) però s'indica el següent missatge d'error *"Path not found: /resource/_tp8v-a58g.html"*. Degut a aquest error, els URIs a nivell de registre no serveixen ja que no es pot identificar ni enllaçar a cada una de les files; consegüentment la puntuació obtinguda és 3 ja que no es pot atorgar el nivell de 4 estrelles (4 punts) atès que els identificadors de registre no es localitzen.

Este fichero XML no parece tener ninguna información de estilo asociada. Se muestra debajo el árbol del documento.

```

<?xml:namespace prefix="rdf" base="http://www.w3.org/1999/02/22-rdf-syntax-ns#" />
<?xml:namespace prefix="socrata" base="https://api.socrata.com/" />
<?xml:namespace prefix="ds" base="https://data.socrata.com/" />
<?xml:namespace prefix="dbase" base="https://data.socrata.com/" />
<rdf:RDF>
  <dbase:tp8v-a58g rdf:about="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/row-f6nc_8am.exzb">
    <socrata:rowID>row-f6nc_8am.exzb</socrata:rowID>
    <rdf:member rdf:resource="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/">
      <ds:identificador>0001</ds:identificador>
      <ds:codi_postal>08630</ds:codi_postal>
      <ds:codi_municipi>080018</ds:codi_municipi>
      <ds:nom_municipi>Aberera</ds:nom_municipi>
    </dbase:tp8v-a58g>
  </dbase:tp8v-a58g rdf:about="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/row-ak73_zkkg-6avd">
    <socrata:rowID>row-ak73_zkkg-6avd</socrata:rowID>
    <rdf:member rdf:resource="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/">
      <ds:identificador>0002</ds:identificador>
      <ds:codi_postal>08256</ds:codi_postal>
      <ds:codi_municipi>080023</ds:codi_municipi>
      <ds:nom_municipi>Aguilar de Segarra</ds:nom_municipi>
    </dbase:tp8v-a58g>
  </dbase:tp8v-a58g rdf:about="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/row-qcpr_y3n5-35r5">
    <socrata:rowID>row-qcpr_y3n5-35r5</socrata:rowID>
    <rdf:member rdf:resource="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/">
      <ds:identificador>0003</ds:identificador>
      <ds:codi_postal>08281</ds:codi_postal>
      <ds:codi_municipi>080023</ds:codi_municipi>
      <ds:nom_municipi>Aguilar de Segarra</ds:nom_municipi>
    </dbase:tp8v-a58g>
  </dbase:tp8v-a58g rdf:about="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/row-88zy-nm4v.8fyh">
    <socrata:rowID>row-88zy-nm4v.8fyh</socrata:rowID>
    <rdf:member rdf:resource="https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g/">
      <ds:identificador>0004</ds:identificador>
  </dbase:tp8v-a58g>
</rdf:RDF>

```

Figura 24. Conjunt de dades Codis postal per municipis de Catalunya en format RDF/XML. (Font: Portal dades obertes de la Generalitat de Catalunya, 2021).

JSON	Datos sin procesar	Cabeceras
Guardar	Copiar	Contraer todo
		Expandir todo
		Filtrar JSON
message:	"Path not found: /resource/_tp8v-a58g.html"	
errorCode:	"not-found"	
▼ data:		
path:	"/resource/_tp8v-a58g.html"	

Figura 25. Missatge d'error a l'enllaçar en un URI de registre. (Font: Portal dades obertes de la Generalitat de Catalunya, 2021).

e. Recuperabilitat. Aquest element ODQ no s'ha pogut avaluar ja que no es disposa de la informació necessària per a poder mesurar el grau de recuperabilitat. Cal recordar que es tracta d'una propietat dependent del sistema i del repositori digital en el que s'emmagatzemen les dades, raó per la qual la seva avaluació es realitza dins el sistema, no en el frontal web.

f. Localització. A partir de l'anàlisi tant del dataset com de les metadades es procedeix a respondre el qüestionari:

- A – 0,50 [El dataset disposa d'URI, concretament és el següent: <https://analisi.transparenciacatalunya.cat/resource/tp8v-a58g>. Tanmateix, les metadades no tenen assignades un identificador únic i en el cas dels registres que conformen la taula sí disposen d'URI però dona error].
- B – 1 [Sí, tant el dataset com les columnes estan descrites de forma detallada mitjançant metadades].

- C – 0,50 [Només s'indexen les metadades, tal com títol, categoria, etiquetes, freqüència d'actualització o informació geogràfica, entre d'altres].
- D – 0 [No hi ha cap metadada associada a l'identificador del dataset, malgrat que a la NTI-RISP s'indica a l'apartat IV.1 que els recursos d'informació reutilitzables estaran identificats per referències úniques i unívocues¹⁴³.]

A partir de les respostes anteriors s'aplica la corresponent fórmula: $(0,50 + 1 + 0,50 + 0) / 4 = 2 / 4 = 0,50$. És a dir, la puntuació obtinguda és 0,50 punts el que significa que el nivell de localització és intermedi.

g. Eficiència. Per a poder avaluar aquest element ODQ s'han realitzat cinc peticions en el cercador del Portal de dades obertes, totes relacionades amb la mostra seleccionada:

- Petició 1. A les 15:44h s'ha introduït les paraules codis postals al cercador, a les 15:45h el sistema retorna 62 resultats. El primer resultat és Codis postal per municipis de Catalunya.

¹⁴³ Convé subratllar que a l'apartat 2.3 ja s'ha esmentat la contradicció existent entre el que s'estableix a l'apartat IV.1 de la NTI-RISP i l'annex III de la citada NTI, ja que a l'annex s'especifica que la metadada identificador, tant a nivell de catàleg com de dataset, no és obligatòria.

- Petició 2. A les 15:46h s'ha introduït la paraula variable al cercador, a les 15:46h el sistema retorna 234 resultats.
- Petició 3. A les 15:46h s'ha introduït les paraules catàleg tècnic dades al cercador, a les 15:46h el sistema retorna 52 resultats.
- Petició 4. A les 15:47h s'ha introduït les paraules codi municipi, a les 15:48h el sistema retorna 268 resultats.
- Petició 5. A les 15:48h s'introdueix les paraules codi element, a les 15:48h el sistema retorna 18 resultats.

Per tant, cap resposta supera 1 segon el que significa que la puntuació obtinguda és 5 punts. Altrament, a partir de les dades de les peticions es calcula la mitjana de resposta de totes les peticions: $(1 + 0 + 0 + 1 + 0) / 5 = 2 / 5 = 0,40$. El resultat obtingut és una mitjana de 0,40 segons, el que confirma la puntuació abans atorgada.

h. Comparabilitat. A partir de l'anàlisi tant del dataset com de les metadades associades es respon al qüestionari per avaluar aquest element ODQ:

- A – 1 [Sí, les dades es presenten en formats estructurats, oberts i estandarditzats tal com el CSV, XML o RDF-XML.]
- B – 1 [Sí, les metadades segueixen l'esquema que s'indica a la Guia d'implementació per a l'homogeneïtzació de les metadades del catàleg de dades obertes de la Generalitat de Catalunya].
- C – 0 [No, el dataset Codis postal per municipis de Catalunya no conté referències temporals ni tampoc georeferències, ja que el tipus d'informació geogràfica es basa en codis d'elements (codi de municipi i codi postal)].
- D – 0 [No s'ha localitzat cap estandardització de conjunts de dades similars, a diferència del que succeeix amb altres datasets com per exemple el d'accidents de trànsit on s'especifiquen els atributs mínims del recurs, tant per part de la FEMP (2019) com del Consorci AOC (2020)].
- E – 0 [No s'utilitzen d'estàndards internacionals a fi de facilitar la interoperabilitat de les dades, tal com el vocabulari DCAT-AP].

A partir de les respostes anteriors s'aplica la fórmula corresponent: $(1 + 1 + 0 + 0 + 0) / 5 = 2 / 5 = 0,40$.

Finalment es conclou que la puntuació obtinguda per a l'element comparabilitat és de 0,40 punts, és a dir, hi ha un nivell baix de comparabilitat.

5. Dimensió Disponibilitat.

- a. Pertinència temporal.** Per a valorar aquest element ODQ, primerament s'ha de conèixer la puntuació de les propietats actualitat i volatilitat. Per a la mostra analitzada, l'actualitat té una puntuació de 0 punts ja que el dataset no està actualitzat i la volatilitat 1 punt. A partir d'aquestes dades s'aplica la fórmula corresponent: $\{\text{màx.} [(1 - (0 / 1)), 0]\} = \{\text{màx.} [(1 - 0), 0]\} = \{\text{màx.} [(1), 0]\} = 1$. El resultat anterior dona 1 a l'índex de puntualitat. Així mateix, un cop avaluat aquest valor, així com l'actualitat de les dades, la seva freqüència d'actualització i la verificació de si estan disponibles abans de la freqüència indicada, es conclou que la pertinència temporal no és apropiada ja que no es publiquen de forma puntual en relació al context, per la qual cosa s'atorga una puntuació de 0 punts.
- b. Actualitat.** A la metadada darrera actualització de les dades s'indica que el dataset va ser actualitzat a data 25 de maig de 2021, i a la freqüència d'actualització s'estableix variable. És a dir, el període

d'actualització és indefinit, només s'actualitza quan es produeixen modificacions en el dataset. Tanmateix, tal com s'ha vist abans, el municipi Bigues i Riells va canviar la seva denominació oficial i actualment rep el nom de Bigues i Riells del Fai, segons s'estableix a la Resolució PRE/2023/2021, de 29 de juny, per la qual es dona conformitat al canvi de nom del municipi de Bigues i Riells, que passa a denominar-se Bigues i Riells del Fai. Malgrat que a data 6 de juliol de 2021, des de l'Idescat es publica la notícia de que aquest canvi ja es recull a la geonomenclatura oficial catalana als efectes estadístics, en concret a la base de dades de Codis territorials i d'entitats¹⁴⁴; aquest canvi no s'ha recollit al Catàleg tècnic de dades de referència, per la qual cosa el dataset no es troba actualitzat en relació amb els canvis ocorreguts en el món real. Per les consideracions anteriors, la puntuació obtinguda és 0 punts.

- c. Volatilitat.** A la metadada freqüència actualització s'indica variable, el que implica que la volatilitat del dataset és baixa i, per tant, rep una puntuació d'1 punt.
- d. Accessibilitat.** Aquest element ODQ s'avalua sobre el Portal de dades obertes de la Generalitat de Catalunya, en tant que és el catàleg de

144 Per a més informació es remet a la notícia de l'Idescat: <https://www.idescat.cat/novetats/?id=3963>

referència per a localitzar fonts de dades obertes, essent l'espai a partir del qual s'accedeix a la mostra seleccionada. Un cop analitzat el Portal es respon a les qüestions plantejades:

- A – 1 [Sí, es publica una declaració d'accessibilitat tal com marca l'article 15 del Reial Decret 1112/2018].
- B – 0 [A la declaració d'accessibilitat s'indica que *«el compromís de la Generalitat de Catalunya és arribar a complir el nivell de conformitat 'Double-A' (AA), tal com exigeixen a les administracions públiques les legislacions europea i estatal»*, per aquesta raó es considera que encara no es compleix amb el nivell AA, però es desconeix si ja es compleix amb el nivell A].
- C – 1 [No es requereix realitzar un tràmit administratiu per accedir als conjunts de dades].
- D – 1 [No es requereix realitzar un registre d'usuari per accedir als conjunts de dades].

- E – 0 [El portal de dades obertes no disposa de cap certificació d'accessibilitat].

A partir de les respostes anteriors s'aplica la fórmula corresponent: $(1 + 0 + 1 + 1 + 0) / 5 = 3 / 5 = 0,60$. Del resultat anterior es conclou que la puntuació final del nivell d'accessibilitat del portal de dades obertes de la Generalitat de Catalunya és de 0,60.

e. Reutilització. Amb aquest element ODQ s'avalua el grau de reutilització del dataset Codis postal per municipis de Catalunya, tenint en consideració aspectes relacionats no només amb el propi conjunt de dades sinó també amb l'arquitectura tecnològica del servei de dades obertes de la Generalitat de Catalunya:

- Llicències legals: 6 punts
 - » Reutilització comercial o sense restriccions, per exemple CC BY-NC 4.0. [A la metadada enllaç font hi ha un enllaç a la pàgina informativa sobre la Llicència oberta d'ús d'informació – Catalunya¹⁴⁵].

145 És important destacar que al Decret 8/2021, de 9 de febrer, sobre la transparència i el dret d'accés a la informació pública s'indica al títol IV relatiu a la reutilització de la informació pública, article 75.1, que les Administracions públiques han de fomentar l'ús de llicències amb les mínimes restriccions possibles sobre la reutilització de la informació. Com a regla general, la reutilització de la informació queda subjecta a la Llicència oberta d'ús d'informació - Catalunya o a les llicències de Creative Commons que compleixin les condicions establertes a l'article 75.2. Malgrat que el decret es concep per a la publicitat activa i el dret d'accés a la informació pública, es considera que hi ha aspectes del mateix, tal és el cas de la RISP, que poden ser d'aplicació a l'àmbit de les dades obertes.

- Accés a la informació: 6 punts
 - » API o llenguatge de consulta. [Convé fer-ne una sèrie de consideracions: la plataforma de dades obertes de la Generalitat de Catalunya utilitza la tecnologia Socrata, que permet l'ús d'API. Així mateix, es poden consultar les fonts de dades obertes mitjançant el frontal web o accedir-hi a les mateixes via API REST¹⁴⁶, tal com s'especifica a la secció d'informació per a desenvolupadors¹⁴⁷ del Portal de dades obertes de la Generalitat].
- Estàndards tècnics: 6 punts
 - » Estàndards oberts amb metadades, per exemple RDF, RSS, JSON. [Els conjunts de dades es poden exportar en múltiples formats, concretament són els següents: CSV, TSV, RDF-XML, XML, RSS i en JSON via API SODA].
- Estandardització: 1 punt
 - » Estandardització pròpia del model de dades. [El conjunt de dades sobre codis postals no disposa d'una estandardització compartida, a diferència d'altres datasets com per exemple accidents de trànsit o registre d'entitats. En aquest sentit, la normalització és pròpia però no s'ha localitzat publicat el model de dades, només es localitza la taula de codis postals associats a municipis de Catalunya].
- Geolocalització: 3 punts
 - » Camp de text simple o complex. [La metadada informació geogràfica informa que el tipus d'informació és codi d'element, en són una bona mostra el codi municipi o el codi postal].
- Freqüència d'actualització: 1 punt

¹⁴⁶ Segons la NTI-RISP, una Interfície de Programació d'Aplicacions o API és un «*punto de comunicación entre componentes de software, que ofrece un conjunto de llamadas a librerías de programación que ofrecen acceso a servicios desde los procesos, consiguiendo la abstracción en la programación entre niveles inferiores y superiores del software.*» (Annex I. Glossari, p. 17050). En relació a l'API REST, aquesta és una tipologia de protocol estàndard d'intercanvi de dades en la que s'utilitza HTTP per a obtenir dades i generar operacions sobre aquestes dades en tots els formats possibles, com XML i JSON. Més concretament, en un sistema REST les operacions que es realitzen són les següents: post (crear), get (llegir i consultar), put (editar) i delete (eliminar). Així mateix, per a poder realitzar dites accions sobre objectes concrets aquests s'identifiquen mitjançant URIs (BBVA, 2016). Per a més informació es remet a <https://www.bbvaapimarket.com/es/mundo-api/api-rest-que-es-y-cuales-son-sus-ventajas-en-el-desarrollo-de-proyectos/>

¹⁴⁷ Per a més informació es remet a la secció Informació per a desenvolupadors on es descriu, entre altres aspectes, l'arquitectura tecnològica del servei de dades obertes de la Generalitat de Catalunya: https://governobert.gencat.cat/ca/dades_obertes/reutilitzacio-dades/informacio-desenvolupadors/

- » Més d'un mes. [La metadada freqüència d'actualització informa de que la freqüència és variable. No obstant, com les metadades dades creades i darrera actualització de les dades indica 25 de maig de 2021, per defecte, es selecciona l'opció de més d'un mes].
- Disseminació: 3 punts
 - » Recursos disponibles sobre actualitzacions (és a dir, RSS). [A la pàgina web de Govern obert de la Generalitat de Catalunya, a la secció actualitat, hi ha l'opció de descarregar-se el recurs *feed RSS*¹⁴⁸, el que permet la distribució de contingut amb les novetats sobre transparència, dades obertes i participació, en temps real basat en un llenguatge XML].
- Reputació: 1 punt
 - » No hi ha informació sobre la reputació de la font de dades. [Malgrat que l'Institut d'Estadística de Catalunya (Idescat), com a proveïdor de la mostra analitzada, és una font oficial i autoritzada, no s'ha localitzat ni estadístiques o informes publicats sobre

les opinions dels usuaris, ni indicadors o rànquings sobre la reputació de la font de dades; raó per la qual s'ha seleccionat l'opció "No hi ha informació sobre la reputació de la font de dades"].

El sumatori de les respostes anteriors dona una puntuació final de 27 punts d'un total de 61 punts. Altrament, com la puntuació obtinguda no arriba a la meitat de la puntuació màxima es conclou que el grau de reutilització és baix.

- f. **Seguretat/Privacitat.** Aquest element ODQ no s'ha pogut mesurar atès que no es disposa de la informació necessària per a la seva avaluació. Tal com s'infereix de la mètrica dissenyada, per al seu mesurament és necessari conèixer l'arquitectura tecnològica, tant de la plataforma de dades obertes de la Generalitat de Catalunya que actua com a repositori digital dels conjunts de dades com del proveïdor de les mateixes. Així mateix, es tracta d'una mètrica que s'avalua en *back office*, no en el frontal web; i on és important examinar tant el sistema origen com el sistema de destí de les dades.

148 La tecnologia RSS permet que els usuaris d'un canal de notícies segueixin les actualitzacions a través d'un programa anomenat lector o agregador de notícies (*news reader*) que agrupa aquelles fonts de notícies a les que un usuari s'ha subscrit i, a més, permet que es consultin els titulars des d'un únic lloc (Universitat Oberta de Catalunya, s.d.). Per a més informació es remet a <http://biblioteca.uoc.edu/ca/com-funciona/faqs/com-es-fa-servir-lrss>

g. Portabilitat. Aquest element ODQ no s'ha pogut mesurar atès que no es disposa de la informació necessària per a la seva avaluació. Tal com s'interfereix de la mètrica proposada, per al seu mesurament és important conèixer tant el sistema d'origen com el sistema de destí a fi d'avaluar la capacitat dels sistemes per intercanviar dades, interpretar-les i reutilitzar-les, sense pèrdua de qualitat de les mateixes.

3. 3. 3. Avaluació del dataset Comissaries

En el present subapartat es presenten els resultats obtinguts per a cada una de les dimensions i elements ODQ que conformen el model de qualitat de les dades obertes:

1. Dimensió Autenticitat.

a. Definició / Documentació. Per a la mostra analitzada no es disposa de metadades associades a les columnes, tal com nom, descripció i tipus. Si bé la denominació dels atributs és fàcilment interpretable (adreça, municipi, comarca, CP, codi_ine, etc.), falta informació relacionada amb el tipus de dades, possibles valors que poden prendre les dades, etc. Per la qual cosa la puntuació obtinguda és 0 punts atès que les dades no estan documentades.

b. Conformitat. El dataset Comissaries té 11 atributs (nom, adreça, municipi, CP, comarca, latitud, longitud, tipus, horari, codi_ine, i denúncies), dels quals es consideren crítics 6 atributs (nom, adreça, municipi, CP, tipus i codi_ine). Convé recordar que l'avaluació es realitza sobre els valors crítics i també sobre les metadades associades al dataset. No obstant, pel que fa als atributs nom i tipus es desconeix si existeixen estàndards de definicions de dades, per la qual cosa no es pot

avaluar la seva conformitat en relació amb regles, instruccions i/o normes específiques. Amb tot, per aquest cas d'estudi finalment el que es mesura són els següents aspectes¹⁴⁹:

- Si el codi postal (CP) compleix amb els estàndards de definicions de dades, concretament, si es tracta d'un alfanumèric de 5 dígits enters:

D1 D2 D3 D4 D5

- » Els dígits D1 i D2 corresponen a la província de la direcció postal.
- » El dígit D3 indica l'encaminament dins la província. Per exemple, un 0 en aquesta posició indica que el codi pertany a la capital de la província.
- » El dígit D4 representa la ruta, dada pròpia del servei postal.

» El dígit D5 representa el repartiment, dada pròpia del servei postal.

- Si el municipi compleix amb els estàndards de definicions de dades, concretament, si es tracta d'un alfanumèric de 100 caràcters.
- Si el codi_INE compleix amb els estàndards de definicions de dades, en particular si es tracta d'un alfanumèric de sis dígits¹⁵⁰:

D1 D2 D3 D4 D5 D6

- » Els dígits D1 i D2 corresponen al codi de província.
- » Els dígits D3, D4 i D5 al municipi dins la província.
- » El dígit D6 representa un dígit de control, assignat mitjançant una regla de càlcul, que permet la detecció d'errors de gravació i codificació.

¹⁴⁹ La informació relacionada amb els estàndards de definicions de dades per als valors codi postal i nom municipi s'ha extret de la informació facilitada sobre els atributs tant a les metadades de les columnes com al detall de les dades de referència del dataset Codis postal per municipis de Catalunya que es descarrega de la pàgina del CTTI: <https://canigo.ctti.gencat.cat/da/detalldadesref/>

¹⁵⁰ La informació sobre l'estàndard de dades en relació al codi de municipi (codi INE) s'ha extret de la pàgina web de l'Institut Nacional de Estadística (INE): https://www.ine.es/dyngs/INEbase/es/operacion.htm?c=Estadistica_C&cid=1254736177031&menu=ultiDatos&idp=1254734710990

- Si les metadades compleixen amb els estàndards de definicions de metadades, en concret amb el model propi del Portal de dades obertes dels Mossos d'Esquadra¹⁵¹ i també amb la guia d'emplenament de les metadades del conjunt de dades per a la tramesa de dades obertes al Portal de dades obertes de la Generalitat de Catalunya¹⁵². El procediment que se segueix és el següent: en primer lloc, es revisa si la metadada té termes controlats en el model de metadades propi dels Mossos d'Esquadra; en cas negatiu, es revisa si es disposa d'informació associada a termes controlats i formats en la guia tècnica de la Generalitat i, finalment, en cas de que tampoc hi hagi cap estandardització en dita guia es revisa si hi ha informació a complir a la NTI-RISP.

A continuació es procedeix a aplicar, en primer lloc, la fórmula a nivell de valor per a cada un dels tres atributs crítics:

- Conformitat del codi postal: $(118 \times 100) / 118 = 11.800 / 118 = 100$
- Conformitat del municipi¹⁵³: $(118 \times 100) / 118 = 11.800 / 118 = 100$
- Conformitat del codi INE: $(116 \times 100) / 118 = 11.600 / 118 = 98,31$ [En relació amb els valors del codi INE s'han trobat dos valors que no són conformes a l'especificació de les dades ja que contenen 10 dígits, en lloc de 6. Aquests valors són Ametlla de Mar (en Excel registre 77, en JSON registre 75) i Tarragona (en Excel registre 116, en JSON registre 113). Així mateix, s'ha verificat a la pàgina de l'INE en concret al llistat "*Relación de municipios y códigos por provincia*" que aquests valors contenen 6 dígits].

De les operacions anteriors es confirma que la conformitat dels valors codi postal i municipi és del 100%, mentre que del codi INE és del 98,31%.

¹⁵¹ Per a més informació es remet a la secció Ajuda sobre Dades Obertes Mossos: https://mossos.gencat.cat/ca/els_mossos_desquadra/indicadors_i_qualitat/dades_obertes/Ajuda-Dades-obertes-Mossos/. Més concretament els apartats Com utilitzar les dades: termes d'ús i llicències; Quines dades trobem al catàleg i com estan classificades?; i Informació que trobareu a la Fitxa.

¹⁵² Malgrat que aquesta guia tècnica està concebuda per a la tramesa dels datasets que s'incorporen al Portal de dades obertes de la Generalitat de Catalunya, es considera que també és d'aplicació per aquells conjunts de dades que es troben en altres portals que conformen el sistema de dades obertes de la Generalitat, tal és el cas dels datasets que hi ha al Portal de dades obertes dels Mossos d'Esquadra.

¹⁵³ Per a comprovar que el nom dels municipis no supera els 100 caràcters s'ha fet servir la funció LARGO de Microsoft Excel, la qual comptabilitza el nombre de caràcters d'una cel·la.

Altrament, la conformitat mitjana a nivell de valor o element de dades ascendeix a 99,44%.

En relació amb la conformitat de registre es troba que hi ha dos registres que no són vàlids ja que contenen els valors crítics no vàlids del codi INE. A partir d'aquestes consideracions la fórmula queda de la següent forma: $(116 \times 100) / 118 = 11.600 / 118 = 98,31$. És a dir, la conformitat a nivell de registre ascendeix a 98,31%.

Finalment, pel que fa a la conformitat de les metadades la fórmula que s'aplica és $(6 \times 100) / 10 = 600 / 10 = 60$. Convé destacar que del total de dades identificades n'hi ha 4 que es consideren no vàlides pels motius que a continuació es detallen:

- **Etiquetes:** a la guia tècnica de la Generalitat de Catalunya s'indica que cada terme s'ha de separar per una coma i un espai, no obstant, això no es compleix ja que l'etiqueta és Dades organitzatives edifici. En aplicació de la regla les etiquetes haurien de quedar de la següent forma: Dades organitzatives, edifici
- **Llicència de les dades:** en el Portal de dades obertes dels Mossos d'Esquadra s'utilitza la frase "Sense llicència associada: sense cap mena de restricció més enllà de les

condicions bàsiques establertes en l'article 8 de la Llei 37/2007 sobre reutilització de la informació del sector públic (citació de la font, no alteració ni desnaturalització de la informació i especificació de la data d'última actualització)". No obstant, es considera que s'hauria de seguir el criteri establert a la guia tècnica de la Generalitat, on s'identifica una sèrie de termes controlats a fi d'homogeneïtzar la descripció dels conjunts de dades obertes.

- **Data creació:** no segueix l'esquema de la ISO 8601, segons s'indica a la NTI-RISP.
- **Data actualització:** no segueix l'esquema de la ISO 8601, segons s'indica a la NTI-RISP.

A partir del resultat obtingut a l'aplicar la fórmula es conclou que la conformitat de les metadades en relació amb les especificacions (model propi, guia tècnica de la Generalitat o NTI-RISP) és del 60%

c. Credibilitat. A partir de l'anàlisi tant del conjunt de dades com de les metadades associades es procedeix a respondre el qüestionari:

- A – 1 [Sí, ja que la informació que conté el dataset es pot verificar en altres fonts, per exemple, a l'organigrama de la Direcció

General de la Policia que s'inclou al web dels Mossos d'Esquadra o a l'organigrama Comissaries - Departament d'Interior que hi consta a la pàgina web de la Generalitat de Catalunya. Altrament, els codis postals i els noms dels municipis i de les comarques es poden consultar al dataset Municipis de la pàgina de l'Idescat i, finalment, pel que fa al codi INE es pot verificar a la pàgina web de l'INE].

- B – 1 [Sí, la Policia de la Generalitat - Mossos d'Esquadra són una organització de confiança].
- C – 1 [Sí, la font d'informació és la Direcció General de la Policia que és un òrgan del Departament d'Interior de la Generalitat de Catalunya, segons s'estableix a l'article 1.1 del Decret 320/2011, de 19 d'abril, de reestructuració del Departament d'Interior].
- D – 0 [No, les dades no estan certificades o no s'ha localitzat cap certificació de les mateixes a partir d'auditories internes i/o externes per part d'organitzacions de confiança].

A partir de les respostes anteriors s'aplica la següent fórmula: $(1 + 1 + 1 + 0) / 4 = 3 / 4 = 0,75$. El resultat obtingut evidencia que el dataset té una alta credibilitat (0,75 d'una puntuació màxima d'1 punt).

d. Primigènia. A l'analitzar el dataset es confirma que és primari, ja que no es tracta de dades agregades com, per exemple, els conjunts de dades Personal operatiu PG-ME -Dades demogràfiques i categoria o el de Víctimes de violència domèstica, ambdós es poden descarregar del Portal de dades obertes dels Mossos d'Esquadra. Altrament, a l'analitzar la mostra seleccionada es considera que la publicació no té el màxim nivell de detall possible atès que es podria incorporar atributs relacionats amb l'àrea bàsica policial o la regió policial. A més, no hi ha constància de que s'hagi avaluat aquest nivell de detall. Per tots els motius exposats anteriorment, la puntuació obtinguda és d'1 punt.

2. Dimensió Fiabilitat.

a. Exactitud. L'avaluació d'aquest element ODQ es realitza mitjançant comparació amb conjunts de dades de referència que provenen de fonts de confiança. Concretament, per aquest cas d'estudi el que es mesura són els següents aspectes:

- Si el codi postal compleix amb el sistema de codificació oficial de l'organisme estatal de Correus. Tanmateix, com la base de dades de codis postals està subjecta a comercialització, i, per tant, no és d'accés lliure; es verifica

el codi postal a la pàgina web de l'Idescat, en concret a la secció Divisió territorial postal.

- Si el municipi es correspon amb la denominació que apareix al dataset Municipis descarregat de la pàgina de l'Idescat.
- Si la comarca es correspon amb la denominació que apareix al dataset Municipis descarregat de la pàgina de l'Idescat.
- Si el codi_ine es correspon amb el codi de municipi que es localitza a la pàgina de l'INE.
- Si l'adreça, el nom i tipus són les que apareixen a l'organigrama Comissaries – Departament d'Interior de la pàgina web de la Generalitat de Catalunya.

A partir de les consideracions anteriors s'avalua l'exactitud per a cada un dels atributs indicats:

- Exactitud codi postal: $(116 \times 100) / 118 = 11.600 / 118 = 98,31$. [Concretament hi ha dos valors que no són exactes, el primer és el codi postal de Sitges que en el dataset analitzat s'indica 08770, però a la pàgina de l'Idescat els codis postals són 08860, 08870 i 08871. El segon és el codi postal de Tarragona que en el dataset

s'indica 73007, però al web de l'Idescat aquest codi no apareix associat a Tarragona].

- Exactitud municipi: $(105 \times 100) / 118 = 10.500 / 118 = 88,98$. [En total hi ha 13 valors no exactes, el motiu resideix en què al dataset Comissaries l'article precedeix a la denominació del municipi, com per exemple la seu d'Urgell o l'Escala; mentre que a l'Idescat l'article va després del nom del municipi, n'és un exemple Seu d'Urgell, la].
- Exactitud comarca: $(117 \times 100) / 118 = 11.700 / 118 = 99,15$. [Hi ha un valor que no és exacte, ja que a la mostra seleccionada apareix com Val d'Aran mentre que a l'Idescat està com Aran].
- Exactitud codi INE: $(115 \times 100) / 118 = 11.500 / 118 = 97,46$. [S'han trobat tres valors no exactes en relació amb els codis INE, en concret són l'Ametlla de Mar que s'indica que el codi INE és 4301360009, Sabadell amb el codi 081870 i Tarragona amb el codi 4314800000. Per contra, a l'INE s'indica que el codi de l'Ametlla de Mar és 430136, el de Sabadell és 081878 i el de Tarragona és 431482].

- Exactitud adreça: $(88 \times 100) / 118 = 8.800 / 118 = 74,58$. [Al respecte convé fer una sèrie d'aclariments: en primer lloc, la comparativa s'ha realitzat amb l'organigrama de comissaries i policia de trànsit del Departament d'Interior que es localitza a la pàgina web de la Generalitat, però com no totes les comissaries apareixien a l'organigrama també s'ha buscat en el visor de comissaries que hi ha a la pàgina web dels Mossos d'Esquadra, i, finalment, en el cas de la Oficina d'atenció ciutadana dels Mossos d'Esquadra a Plaça Catalunya s'ha buscat directament a Google ja que no apareixia ni en el visor. Dels 118 valors, hi ha 30 que no són exactes ja que les adreces no són les mateixes que les consultades ja sigui per faltes d'ortografia (cas de la comissaria de Mossos d'Esquadra a l'estació de Barcelona-Sants), ja sigui per l'ús d'abreviatures (cas de l'Àrea Regional de Trànsit Mossos d'Esquadra a Girona) o directament perquè les adreces són diferents (cas de la comissaria de Mossos d'Esquadra a Montcada i Reixac)].
- Exactitud nom: $(114 \times 100) / 118 = 11.400 / 118 = 96,61$. [Concretament hi ha 4 valors no exactes ja que la denominació que apareix en el dataset no és exactament la mateixa que la que s'indica a l'organigrama del Departament d'Interior].

- Exactitud tipus: $(114 \times 100) / 118 = 11.400 / 118 = 96,61$. [S'ha trobat que 4 valors no són exactes ja que la tipologia de comissaria no es correlaciona amb la denominació, per exemple, pel que fa a la comissaria de Lloret de Mar a l'organigrama s'indica que és Oficina Policial de la Generalitat - Mossos d'Esquadra a Lloret de Mar, per tant, el tipus és Oficina policial; per contra, al dataset s'indica Comissaria de Districte. Convé destacar que en tres dels valors no exactes tampoc és exacte el nom de la comissaria, el que implica que en un mateix registre coincideix en tres de quatre casos que no són exactes els valors nom i tipus].

De les operacions anteriors s'infereix que l'exactitud del valor codi postal és del 98,31%. L'exactitud del valor municipi és del 88,98%; pel que fa al valor comarca l'exactitud ascendeix al 99,15%. L'exactitud del valor codi INE és del 97,46%. El nivell d'exactitud del valor adreça és el més baix de tots els valors, ja que arriba al 74,58% i, finalment, els valors nom i tipus tenen una exactitud del 96,61 cada un. Amb tot, la mitjana d'exactitud a nivell d'elements de dades és del 93,10%.

En quant a l'exactitud de registre la fórmula queda de la següent forma: $(75 \times 100) / 118 = 7.500 / 118 = 63,56$. Del total de registres (118) s'han

comptabilitzat 43 com a no exactes que són aquells que contenen valors no exactes. Amb aquestes dades i amb l'aplicació de la fórmula, el resultat obtingut és que l'exactitud a nivell de registre és del 63,56%

b. Precisió. Aquest element ODQ no s'ha pogut avaluar ja que el dataset no conté valors numèrics resultat d'una operació; consegüentment, no és possible mesurar si es contenen les xifres significatives imprescindibles.

c. Granularitat. Per aquest element ODQ s'avalua el nivell d'exhaustivitat del dataset i, consegüentment, les possibilitats analítiques del mateix. Per a calcular el nivell de granularitat es respon al qüestionari:

- A – 1 [Les dades publicades són primàries].
- B – 1 [Sí, a la metadada període de les dades presentades s'indica que és anual d'entre una llista de tres valors: mensual, trimestral o anual. D'entre els valors a escollir l'interval seleccionat és el més adequat ja que es tracta de dades que varien poc o molt poc].
- C – 0 [Es considera que per a facilitar l'anàlisi del conjunt de dades faltaria incorporar altres

atributs essencials, tal com la regió policial o l'àrea bàsica policial. D'aquesta forma es podria realitzar estudis per regió o àrea, i inclús fomentar visualitzacions en les que les oficines o comissaries s'agrupessin per àrea policial].

Arran de les respostes anteriors s'aplica la fórmula: $(1 + 1 + 0) / 3 = 2 / 3 = 0,66$. Del resultat anterior es conclou que la puntuació obtinguda per al dataset analitzat és del 0,66.

d. Rellevància. Per valorar aquest element ODQ primer es mesura la cobertura de dades en relació amb la totalitat de la població d'interès i, en segon lloc, s'avalua la rellevància de les dades per aquella cobertura concreta. En relació al primer punt, per a calcular la totalitat s'ha tingut en consideració el conjunt de comissaries de Mossos d'Esquadra i també d'àrees regionals de trànsit, ja que al dataset s'inclouen també aquestes últimes. En total surt una població de 133 comissaries i àrees regionals de trànsit a l'àmbit de Catalunya. A partir d'aquestes consideracions s'aplica la fórmula corresponent: $(118 \times 100) / (15 + 118) = 11.800 / 133 = 88,72$. Del resultat anterior es confirma que la cobertura de dades del dataset Comissaries representa el 88,72% en relació amb la totalitat de la població d'interès.

Pel que fa a la rellevància de les dades és condició indispensable establir quins atributs són necessaris per al propòsit previst i posteriorment verificar si aquests atributs estan contemplats en el dataset. Per aquest cas d'estudi es considera que els atributs indispensables que permeten maximitzar les possibilitats analítiques són els que s'informen a l'organigrama comissaries – Departament d'Interior a la pàgina web de la Generalitat de Catalunya i també a l'aplicació web¹⁵⁴ de comissaries dels Mossos d'Esquadra:

- La regió policial que no s'obté de cap dels atributs contemplats en el dataset.
- L'àrea bàsica policial que no s'obté de cap dels atributs contemplats en el dataset.
- El nom complet i oficial de l'oficina policial, comissaria o àrea regional de trànsit que s'obté dels atributs nom i tipus.
- L'adreça que es deriva de l'atribut adreça.
- La població que s'obté dels atributs CP i municipi.

- La comarca que s'obté de l'atribut comarca.
- El telèfon que no s'obté de cap dels atributs contemplats en el dataset.
- L'horari de l'oficina policial o comissaria que es deriva de l'atribut horari.
- La possibilitat de posar denúncia a l'oficina policial o comissaria que es deriva de l'atribut denúncia.
- Les coordenades de l'oficina policial o comissaria que s'obtenen dels atributs latitud i longitud.

A partir del mapeig anterior s'aplica la fórmula corresponent per a calcular el grau de rellevància de les dades: $(7 / 10) \times 100 = 0,70 \times 100 = 70$. Finalment es conclou que la rellevància del contingut és del 70% ja que no conté el total d'elements de dades indispensables.

¹⁵⁴ Aquesta aplicació web facilita la cerca i localització de les oficines policials atès que es troben georeferenciades. Per a la seva consulta es remet a la següent pàgina: <https://mossos.gencat.cat/.content/home/dadesobertes/comissaries/index.html?lang=ca>

3. Dimensió Integritat.

a. Traçabilitat. Un cop analitzat tant el conjunt de dades com les metadades associades es respon al qüestionari per avaluar el nivell de traçabilitat:

- A – 1 [Sí, la metadada font de les dades informa de que la font és la Direcció General de la Policia].
- B – 0 [No, no n'hi cap metadada ni atribut que permeti conèixer i fer el seguiment a la font de dades ascendent immediata].
- C – 0,50 [Sí, però només de la data a partir de la metadada data creació].
- D – 0,50 [Sí, però només de la data a partir de la metadada data actualització].
- E – 0,50 [Les dades de l'arxiu que es carrega substitueixen les existents. No obstant, convé aclarir que els fitxers anteriors no s'eliminen per la qual cosa queda l'històric del dataset].
- F - no valorat [Aquest ítem no s'ha pogut valorar a partir de la informació que es localitza en el Portal de dades obertes].

A partir de les respostes anteriors no s'ha pogut establir el grau de traçabilitat del dataset ja que falta informació per a poder avaluar en la seva totalitat aquest element ODQ.

b. Completesa. La mesura d'aquest element ODQ es realitza sobre la totalitat dels 11 atributs, no només en aquells considerats crítics, a fi de tenir un panorama complet de l'absència o no de dades en relació a la totalitat del dataset. Primerament s'avalua la completesa a nivell d'element de dades: $((1.288 - 0 - 0 - 10^{155}) / 1.288) \times 100 = (1.278 / 1.288) \times 100 = 0,99 \times 100 = 99,22$. Del resultat anterior es conclou que la completesa a nivell d'elements de dades és del 99,22%.

En relació a la completesa a nivell de registre la mesura es realitza sobre la totalitat dels valors, no només dels crítics atès que l'avaluació a nivell d'elements de dades s'ha realitzat sobre el total: $(108 \times 100) / 118 = 10.800 / 118 = 91,53$. Al respecte convé senyalar que del total de registres hi ha 10 que són incomplets ja que contenen valors perduts (en blanc, nuls, etc.). Amb tot, el resultat obtingut és del 91,53%.

155 Per a calcular el nombre total de valors en blanc en el dataset s'ha fet servir la fórmula CONTAR.BLANCO de Microsoft Excel.

Pel que fa a la completesa del conjunt de dades no es disposa de la mostra inicial; no obstant, per avaluar aquest nivell s'ha partit de les següents consideracions:

- Es disposa de l'històric des de l'any 2017. La forma d'actualització és publicar un fitxer cada any, mantenint els fitxers anteriors.
- Es tracta d'un conjunt de dades amb un nivell de volatilitat baix o molt baix, ja que es pressuposa que no hi ha canvis constants.

A partir de les consideracions anteriors s'ha revisat el nombre de registres per any: 2021 té 118 registres, 2020 té 117 registres, 2019 té 117 registres, 2018 té 118 registre i 2017 en té 117. Com s'observa el nombre total de registres és 118, però alguns anys ha faltat un registre que es correspon amb l'Oficina d'Atenció Ciutadana dels Mossos d'Esquadra i la Guàrdia Urbana (Eixample), així doncs, es pressuposa que el dataset de referència ha de contenir 118 files. A partir d'aquesta dada s'aplica la fórmula corresponent: $(118 \times 100) / 118 = 11.800 / 118 = 100$. Del resultat anterior es conclou que la completesa a nivell de dataset és del 100%.

Finalment, pel que fa a les metadades es mesura la seva completesa en relació amb el model

propi i amb la guia tècnica de la Generalitat de Catalunya, atès que el Portal de dades obertes dels Mossos d'Esquadra forma part del sistema de dades obertes de la Generalitat. Al revisar la guia es constata que hi ha 23 metadades obligatòries, de les quals, tres són condicionals ja que s'informen en cas de que hi hagi contingut destacat, i altres tres són obligatòries però la seva visualització és privada, per la qual cosa no és possible establir amb exactitud la completesa a nivell de metadades ja que només hi ha accés a avaluar les que són públiques i es visualitzen en el Portal de dades obertes. Tanmateix, amb la finalitat d'obtenir una puntuació aproximada la valoració es realitza sobre les metadades públiques, sense incloure les condicionals; per tant, el total de metadades es queda en 17. A partir d'aquesta dada s'aplica la fórmula: $(6 \times 100) / 17 = 600 / 17 = 35,29$. Del resultat anterior es conclou que la completesa a nivell de metadades obligatòries és del 35,29%.

- c. Consistència.** Per mesurar la consistència s'avalua en quatre nivells: combinació d'elements de dades dins una mateixa taula, registre dins un mateix dataset, registres creuats i conjunt de dades.

Pel que fa a la combinació d'elements de dades dins un mateix dataset el que particularment es mesura són les següents dues combinacions:

- La consistència entre els valors dels atributs municipi i codi INE, i es constata la seva combinació i consistència en un dataset de referència que és el de Relación de municipios y códigos por provincia de l'Instituto Nacional de Estadística (INE).
- La consistència entre els valors dels atributs municipi i codi postal, i es constata la seva combinació i consistència en la pàgina web de l'Idescat, en concret a la secció Divisió territorial postal.

Pel que fa a la primera combinació, l'aplicació de la fórmula corresponent queda de la següent forma: $(115 \times 100) / 118 = 11.500 / 118 = 97,46$. Al respecte convé aclarir que de les 118 combinacions de valors hi ha tres que són inconsistents ja que el codi INE no és exacte i, per tant, no pot estar associat al municipi. Amb tot, de l'operació realitzada es conclou que el grau de consistència de la combinació dels valors dels atributs municipi i codi INE és del 97,46%. I en quant a la segona combinació la fórmula és $(116 \times 100) / 118 = 11.600 / 118 = 98,31$. Per tant, del resultat obtingut es conclou que la consistència de la combinació entre els valors dels atributs codi postal i municipi és del 98,31%, ja que s'ha trobat dues combinacions inconsistents. La mitjana de consistència de la combinació d'elements és del 97,89%

Pel que fa a la consistència a nivell de registre en total hi ha quatre registres inconsistents ja que són els que contenen les combinacions inconsistents, dues d'aquestes combinacions es troben a la mateixa fila. A partir d'aquestes consideracions s'aplica la fórmula: $(114 \times 100) / 118 = 11.400 / 118 = 96,61$. És a dir, la consistència a nivell de registre és del 96,61%.

En relació amb l'avaluació de la consistència de registres creuats la mesura es realitza entre el dataset Comissaries i el dataset Relación de municipios y códigos de l'INE. Concretament, hi ha 118 registres creuats dels quals 3 són inconsistents ja que presenten alguna contradicció o incoherència. Al respecte, la fórmula queda de la següent forma: $(115 \times 100) / (115 + 3) = 11.500 / 118 = 97,46$. Del resultat anterior es conclou que la consistència a nivell de registres creuats és del 97,46%. En relació amb el resultat convé subratllar la vinculació que hi ha entre consistència i exactitud, però també la diferència existent entre ambdues. D'una banda, es constata que hi ha una correlació entre els dos elements ODQ ja que l'existència de valors no consistents indica que almenys algun valor no és exacte o vàlid; de l'altra, s'ha comprovat que si els valors són consistents no necessàriament implica que els valors són exactes o vàlids. En aquest sentit, durant l'avaluació de l'exactitud s'han

considerat com a valors no vàlids els codis INE que no s'adequaven a la realitat i també aquelles denominacions en les que l'article precedia al nom del municipi, atès que no eren exactes als valors del dataset de referència. Ara bé, per a l'avaluació de la consistència les denominacions amb l'article davant no s'han considerat com a valors inconsistents ja que són equivalents als valors de l'altra dataset i, a més, no hi ha incoherències com si succeeix amb els valors de l'atribut codi INE que s'han considerat inconsistents. És a dir, no s'avalua l'exactitud o correctesa en relació a unes dades de referència, sinó la seva coherència. Dins d'aquesta lògica no és coherent que el codi INE del municipi Ametlla de Mar tingui un codi de 10 dígit, quan són de 6; però no és incoherent que la denominació del municipi sigui l'Ametlla de Mar o Ametlla de Mar, L'.

Finalment, pel que fa a la consistència del conjunt de dades no s'ha pogut avaluar ja que no es disposa d'informació per a poder mesurar la consistència del dataset entre el sistema d'origen i el sistema de destí.

4. Dimensió Usabilitat.

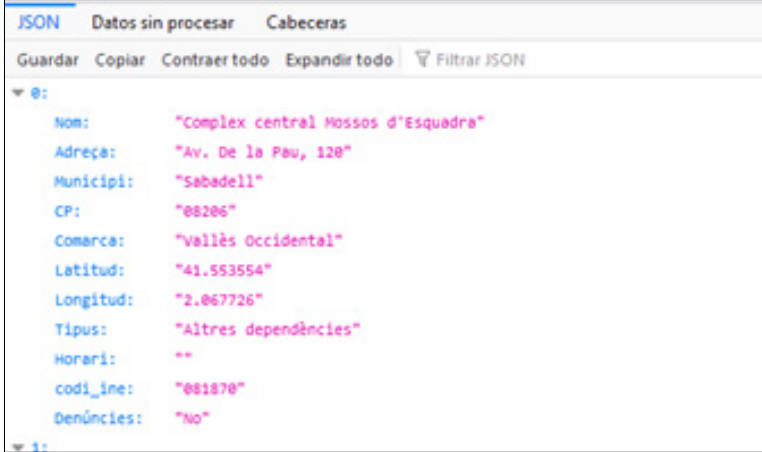
a. Llegibilitat / Interpretabilitat. A partir de l'anàlisi tant del dataset com de les metadades associades es respon al qüestionari:

- A – 1 [Sí, al dataset s'utilitza el codi INE que serveix per a identificar els municipis].
- B – 0 [No, el format de les dates no segueix l'esquema fixat a la norma ISO 8601].
- C – 1 [Sí, el conjunt de dades es troba estructurat en formats processables per màquina, concretament es pot descarregar en XLS, CSV i JSON].
- D – 0,25 [Hi ha metadades assignades a nivell de dataset].
- E – 0,25 [Sí, s'utilitza un model propi].

A partir de les respostes anteriors s'aplica la fórmula: $(1 + 0 + 1 + 0,25 + 0,25) / 5 = 2,50 / 5 = 0,50$. La puntuació final obtinguda és 0,50 punts, per tant, el dataset avaluat té un nivell de llegibilitat / interpretabilitat intermèdia.

b. Comprensibilitat. Després d'analitzar tant el dataset com les metadades associades es respon al qüestionari:

- A – 0 [No, si bé existeix un model propi de metadades que descriu i permet identificar el dataset (data de creació, data d'actualització, descripció, font, etc.); en cap cas, aquestes metadades ofereixen informació sobre el significat dels atributs del dataset per tal de facilitar la comprensió de les dades].
- B – 1 [Sí, tot i que no es troba directament associat a un dataset en concret, sinó al catàleg de dades obertes, en el Portal hi ha un enllaç a diccionaris i recursos en línia a fi de consultar o ampliar la terminologia. Altrament en el Portal de dades obertes hi ha un visor amb les comissàries georeferenciades, on s'hi pot accedir des de la secció Visors d'altres dades].
- C – 1 [Sí, en el cas de descarregar el dataset en format JSON s'utilitza una interfície per a representar el fitxer d'una forma entenedora per als usuaris].



```

JSON  Datos sin procesar  Cabeceras
Guardar Copiar Contraer todo Expandir todo Filtrar JSON
0:
  Nom: "Complex central Mossos d'Esquadra"
  Adreça: "Av. De la Pau, 120"
  Municipi: "Sabadell"
  CP: "08206"
  Comarca: "Vallès Occidental"
  Latitud: "41.553554"
  Longitud: "2.067726"
  Tipus: "Altres dependències"
  Horari: "**"
  codi_ine: "081870"
  Denúncies: "No"

```

Figura 26. Dataset Comissaries en format JSON. (Font: Portal dades obertes dels Mossos d'Esquadra, 2021).

A partir de les respostes s'aplica la fórmula corresponent: $(0 + 1 + 1) / 3 = 2 / 3 = 0,66$. Del resultat anterior es conclou que la comprensió ha obtingut una puntuació de 0,66 punts.

c. Georeferenciació. El dataset Comissaries presenta els atributs latitud i longitud que són les coordenades que s'utilitzen per a referenciar una localització dins un sistema de coordenades geogràfiques. Per tant, la puntuació obtinguda és 2 punts ja que el conjunt de dades geogràfiques està publicat com a dades obertes georeferenciades amb coordenades, però no obté la puntuació màxima (3 punts) atès que no s'acompanya de metadades sobre informació

geogràfica basades en la norma ISO 19115, la Directiva INSPIRE o NEM. Malgrat que una de les metadades que s'informa és l'àmbit geogràfic falta incorporar altres metadades contemplades a les normes i perfils citats, tal com el sistema de referència o la localització geogràfica.

d. Obertura. En base a la informació facilitada a la metadada formats així com les opcions de descàrrega en el *front end*¹⁵⁶ es confirma que la puntuació obtinguda és 3 punts. Aquesta puntuació es correspon amb el nivell 3 de l'escala de cinc estrelles de Tim Berners-Lee ja que les dades es publiquen en formats estructurats que utilitzen software lliure, com CSV.

e. Recuperabilitat. Aquest element ODQ no s'ha pogut avaluar ja que no es disposa de la informació necessària per a poder mesurar el grau de recuperabilitat. Cal recordar que es tracta d'una propietat dependent del sistema i del repositori digital en el que s'emmagatzemen les dades, raó per la qual la seva avaluació es realitza dins el sistema, no en el frontal web.

f. Localització. Un cop avaluat tant el dataset com les metadades associades es respon al qüestionari:

- A – 0 [No, ni les dades ni les metadades disposen d'URI].
- B – 0 [No, les dades presenten un mínim conjunt de metadades però hi ha aspectes que no es descriuen tal com el significat de les columnes, l'idioma o la informació geogràfica].
- C – 0,50 [Sí, s'han fet cerques al cercador del Portal de dades obertes dels Mossos d'Esquadra i es confirma que les metadades associades a paraules clau es troben indexades, tal com comissaries (títol), dades organitzatives (etiquetes) i edifici (etiquetes). Pel que fa a les dades també s'han fet cerques amb valors concrets, tal com Complex central Mossos d'Esquadra o Mossos d'Esquadra a les Corts, i el sistema retorna el següent missatge “No s'ha trobat cap resultat amb els criteris especificats”. Així doncs, només es troben indexades algunes metadades vinculades a paraules clau del dataset].

¹⁵⁶ El *front end* és la interfície gràfica d'usuari (*graphical user interface – GUI*, en anglès), és a dir, és la capa que els usuaris poden veure i utilitzar.

- D – 0 [No, a les metadades no s'especifica l'identificador del conjunt de dades que descriu atès que el dataset no té URI].

A continuació s'aplica la fórmula corresponent: $(0 + 0 + 0,50 + 0) / 4 = 0,50 / 4 = 0,13$. Del resultat anterior es conclou que la puntuació obtinguda és 0,13 punts d'una puntuació màxima d'1 punt; per tant, es confirma que el grau de localització del dataset és baix.

g. Eficiència. Per a poder avaluar aquest element ODQ s'han realitzat cinc peticions en el cercador del Portal de dades obertes, totes relacionades amb la mostra seleccionada:

- Petició 1. A les 17:56h s'ha introduït la paraula comissaries al cercador, a les 17:56h el sistema retorna 1 resultat.
- Petició 2. A les 17:56h s'ha introduït la paraula edifici al cercador, a les 17:56h el sistema retorna 1 resultat.
- Petició 3. A les 17:57h s'ha introduït les paraules dades organitzatives al cercador, a les 17:58h el sistema retorna 7 resultats.

- Petició 4. A les 17:58h s'ha introduït la paraula Catalunya al cercador, a les 17:58h el sistema retorna el missatge “No s'ha trobat cap resultat amb els criteris especificats”.

- Petició 5. A les 17:59h s'introdueix la paraula ABP al cercador, a les 17:59h el sistema retorna 1 resultat.

Per tant, cap resposta supera 1 segon el que significa que la puntuació obtinguda és 5 punts. Atrament, a partir de les dades de les peticions es calcula la mitjana de resposta de totes les peticions: $(0 + 0 + 1 + 0 + 0) / 5 = 1 / 5 = 0,20$. El resultat obtingut és una mitjana de 0,20 segons, el que confirma la puntuació abans atorgada.

h. Comparabilitat. Un cop avaluat tant el dataset com les metadades associades es respon al qüestionari:

- A – 1 [Sí, les dades es presenten en formats estructurats, oberts i estandarditzats tal com el CSV o JSON].
- B – 0,50 [No, es disposa d'un model propi amb 10 metadades (títol, descripció, àmbit geogràfic, etiquetes, data creació, data actualització, formats, període dades, font dades i llicència), tot i que aquestes es poden equiparar a alguns

elements de metadades de la guia tècnica de la Generalitat i del vocabulari DCAT].

- C – 1 [Sí, existeix un històric del dataset comissaries des de l'any 2017 fins a l'actualitat i, a més, cada una de les taules anuals conté dades geogràfiques basades en un sistema de coordenades (latitud i longitud)].
- D – 0 [No s'ha localitzat cap estandardització de conjunts de dades similars, a diferència del que succeeix amb altres datasets com per exemple el d'accidents de trànsit on s'especifiquen els atributs mínims del recurs, tant per part de la FEMP (2019) com del Consorci AOC (2020)].
- E – 0 [No s'utilitzen estàndards internacionals a fi de facilitar la interoperabilitat de les dades, com per exemple la norma ISO 19115 o el Reglament INSPIRE].

A partir de les respostes anteriors s'aplica la fórmula corresponent: $(1 + 0,50 + 1 + 0 + 0) / 5 = 2,50 / 5 = 0,50$. Finalment es conclou que la puntuació obtinguda per a l'element comparabilitat és de 0,50 punts, és a dir, hi ha un nivell intermedi de comparabilitat.

5. Dimensió Disponibilitat.

- Pertinència temporal.** Per avaluar aquesta propietat s'ha de conèixer primerament els resultats dels elements actualitat i volatilitat, que han obtingut una puntuació d'1 punt cadascuna. A continuació s'aplica la fórmula corresponent: $\{\text{màx.} [(1 - (1 / 1)), 0]\} = \{\text{màx.} [(1 - 1), 0]\} = \{\text{màx.} [0, 0]\} = 0$. El resultat anterior dona 0 a l'índex de puntualitat. Així mateix, un cop avaluat aquest valor, així com l'actualitat de les dades, la seva freqüència d'actualització i la verificació de si estan disponibles abans de la freqüència indicada, es conclou que la pertinència temporal és adequada, per la qual cosa s'atorga una puntuació d'1 punt.
- Actualitat.** Un cop revisades les metadades període de les dades (anual) i data d'actualització (27/04/2021) es confirma que les dades es troben actualitzades, per tant, la puntuació obtinguda per aquest element ODQ és 1 punt.
- Volatilitat.** A la metadada període de les dades s'indica que és anual i al revisar l'històric es constata que hi ha un fitxer per cada any, tot i que la data d'actualització que es manté és la darrera, per la qual cosa no se sap exactament quina és la freqüència d'actualització. No obstant, i malgrat no disposar d'una metadada sobre la freqüència d'actualització,

s'infereix que cada conjunt de dades és vàlid durant el període en curs. Així mateix, a la secció “Ajuda sobre dades obertes Mossos”, subsecció “Cada quan s'actualitzen les dades?”, s'indica que «(...) el termini d'actualització estimat és d'un o dos mesos a partir de la finalització del termini d'introducció de dades en els sistemes d'informació policial (mensual, trimestral o anual); aquests terminis poden augmentar en aquells conjunts de dades que requereixen de la intervenció de serveis externs a la Direcció General de la Policia». En el cas del dataset Comissaries s'indica que el període de les dades és anual i, per tant, s'infereix que la introducció de dades en els sistemes informàtics també ho és, raó per la qual la puntuació obtinguda és 1 punt. Aquesta puntuació significa que la volatilitat és baixa.

d. Accessibilitat. Aquest element ODQ s'avalua directament en el Portal de dades obertes dels Mossos d'Esquadra. A partir del seu anàlisi la puntuació per a cada pregunta és la següent:

- A – 1 [Sí, en la pàgina web dels Mossos d'Esquadra, des de la qual s'enllaça al Portal de dades obertes, hi ha una declaració d'accessibilitat detallada, exhaustiva i clara que aplica al web dels Mossos d'Esquadra].

- B – 0 [A la declaració d'accessibilitat s'indica que «el compromís de la Generalitat de Catalunya és arribar a complir el nivell de conformitat 'Doble-A' (AA), tal com exigeixen a les administracions públiques les legislacions europea i estatal»; no obstant, es desconeix si es compleix amb el nivell A ja que no s'indica la conformitat amb algun dels nivells establerts].
- C – 1 [No es requereix realitzar un tràmit administratiu per accedir als conjunts de dades].
- D – 1 [No es requereix realitzar un registre d'usuari per accedir als conjunts de dades].
- E – 0,50 [Malgrat no es disposa d'una certificació de la norma UNE 139803:2012, convé destacar que a la declaració d'accessibilitat s'indica que el «lloc web és revisat per l'Observatori d'Administració Electrònica (OBSAE), havent-se realitzat la darrera revisió al novembre de 2018» i que s'estan realitzant treballs d'auditoria i consultoria per part d'ILUNION Tecnologia y Accesibilidad —empresa pertanyent al Grup Social ONCE— per tal de garantir que el lloc web compleix amb els requisits d'accessibilitat del Reial Decret 1112/2018, de 7 de setembre].

A partir de les respostes anteriors s'aplica la fórmula corresponent: $(1 + 0 + 1 + 1 + 0,50) / 5 = 3,50 / 5 = 0,70$. Del resultat anterior es conclou que la puntuació final del nivell d'accessibilitat del web dels Mossos d'Esquadra és de 0,70 punts.

e. Reutilització. Amb aquest element ODQ s'avalua el grau de reutilització del dataset Comissaries, tenint en consideració aspectes relacionats no només amb el propi conjunt de dades sinó també amb el web dels Mossos d'Esquadra:

- Llicències legals: 6 punts.

- » Reutilització comercial o sense restriccions, per exemple CC BY-NC 4.0. [A la metadada llicència de les dades s'indica «sense llicència associada: sense cap mena de restricció més enllà de les condicions bàsiques establertes en l'article 8 de la Llei 37/2007 sobre reutilització de la informació del sector públic (citació de la font, no alteració ni desnaturalització de la informació i especificació de la data d'última actualització)»].

- Accés a la informació: 1 punt.

- » Accés web o paràmetres d'URL únics al conjunt de dades. [Des del Portal de dades obertes dels Mossos d'Esquadra s'accedeix al

catàleg de dades obertes on es localitzen tots els datasets, els quals es poden descarregar però en cap cas veure les dades en el web].

- Estàndards tècnics: 6 punts.

- » Estàndards oberts amb metadades, per exemple rdf, rss, json. [Els conjunts de dades es poden descarregar en tres formats: XLS, CSV i JSON].

- Estandardització: 1 punt.

- » Estandardització pròpia del model de dades. [No existeix una publicació de normalització pròpia, local o global del model de dades].

- Geolocalització: 6 punts.

- » Coordenades o informació geogràfica completa. [El dataset comissaries conté els atributs longitud i latitud, els quals conformen el sistema de coordenades per a cada una de les oficines policials i comissaries identificades].

- Freqüència d'actualització: 1 punt.

- » Més d'un mes. [A partir de la metadada període de les dades i de l'històric del conjunt de dades Comissaries s'infereix que la

frequència d'actualització és anual, atès que hi ha un fitxer per any. Per a més informació es remet a l'avaluació de l'element ODQ [volatilitat].

- Disseminació: 3 punts.
 - » Recursos disponibles sobre actualitzacions (és a dir, RSS). [Al web dels Mossos d'Esquadra, a la secció de comunicació, hi ha l'opció de descarregar-se l'aplicació RSS].
- Reputació: 1 punt.
 - » No hi ha informació sobre la reputació de la font de dades. [Malgrat que la Direcció General de la Policia, com a proveïdor de les dades analitzades, és una font oficial i autoritzada, no s'ha localitzat ni estadístiques o informes publicats sobre les opinions dels usuaris, ni indicadors o rànquings sobre la reputació de la font de dades; raó per la qual s'ha seleccionat l'opció "No hi ha informació sobre la reputació de la font de dades"]].

El sumatori de les respostes anteriors dona una puntuació final de 25 punts d'un total de 61 punts. Altrament, com la puntuació obtinguda

no arriba a la meitat de la puntuació màxima es conclou que el grau de reutilització és baix.

- f. **Seguretat / Privacitat.** Aquest element ODQ no s'ha pogut mesurar atès que no es disposa de la informació necessària per a la seva avaluació. Tal com s'infereix de la mètrica dissenyada, per al seu mesurament és necessari conèixer l'arquitectura tecnològica, tant de la plataforma de dades obertes de la Generalitat de Catalunya que actua com a repositori digital dels conjunts de dades com del proveïdor de les mateixes. Així mateix, es tracta d'una mètrica que s'avalua en *back office*, no en el frontal web; i on és important examinar tant el sistema origen com el sistema de destí de les dades.
- g. **Portabilitat.** Aquest element ODQ no s'ha pogut mesurar atès que no es disposa de la informació necessària per a la seva avaluació. Tal com s'infereix de la mètrica proposada, per al seu mesurament és important conèixer tant el sistema d'origen com el sistema de destí a fi d'avaluar la capacitat dels sistemes per intercanviar dades, interpretar-les i reutilitzar-les, sense pèrdua de qualitat de les mateixes.

3. 4. Anàlisi dels resultats

En aquest apartat es presenta una taula amb els resultats obtinguts per a cada un dels elements ODQ mesurats a les dues mostres seleccionades, concretament són la mostra 1 que es correspon al dataset Codis postal per municipis de Catalunya i la mostra 2 que fa referència al dataset Comissaries. Per a cada mostra hi ha dues columnes, en la primera s'agreguen les puntuacions obtingudes durant el procés de mesurament de cada un dels elements de qualitat, amb indicació expressa d'aquelles propietats que no s'han pogut avaluar. A la segona columna s'identifica el valor final per a cada un dels elements ODQ, un cop aplicada la fórmula indicada a l'apartat 2.4.3. Altrament les propietats es troben agrupades per dimensió i a la filera de cada dimensió s'ha especificat el valor final de cada una, a partir del sumatori de tots els elements ODQ que conformen la dimensió. Finalment la darrera filera és el valor total de cada una de les mostres; no obstant, el resultat és provisional atès que hi ha elements ODQ que no s'han pogut avaluar a causa de la falta d'informació.

Elements ODQ	Mostra 1		Mostra 2	
	Puntuació proves	Valor final	Puntuació proves	Valor final
Dimensió Autenticitat	82,08 punts		48,56 punts	
Definició / Documentació	3 punts	25 punts	0 punts	0 punts
Conformitat	<i>Nivell element dades: 100%</i> <i>Nivell registre: 100%</i> <i>Nivell metadades: 60%</i>	21,67 punts	<i>Nivell element dades: 99,44%</i> <i>Nivell registre: 98,31%</i> <i>Nivell metadades: 60%</i>	21,48 punts
Credibilitat	0,75 punts	18,75 punts	0,75 punts	18,75 punts
Primigènia	2 punts	16,66 punts	1 punt	8,33 punts
Dimensió Fiabilitat (no resultat precisió)	74,96 punts		53,58 punts	
Exactitud	<i>Nivell element dades: 99,88%</i> <i>Nivell registre: 99,79%</i>	24,96 punts	<i>Nivell element dades: 93,10%</i> <i>Nivell registre: 63,56%</i>	19,58 punts
Precisió	No avaluat. No operacions.	No avaluat	No avaluat. No operacions.	No avaluat
Granularitat	1 punt	25 punts	0,66 punts	16,50 punts
Rellevància	<i>Cobertura dades: 12,03%</i> <i>Rellevància dades: 100%</i>	25 punts	<i>Cobertura dades: 88,72%</i> <i>Rellevància dades: 70%</i>	17,50 punts
Dimensió Integritat (no resultat traçabilitat)	68,46 punts		62,59 punts	
Traçabilitat	No avaluat. Falta preguntes E i F.	No avaluat	No avaluat. Falta pregunta F.	No avaluat
Completesa	<i>Nivell element dades: 100%</i> <i>Nivell registre: 100%</i> <i>Nivell dataset: 100%</i> <i>Nivell metadades: 82,35%</i>	33,46 punts	<i>Nivell element dades: 99,22%</i> <i>Nivell registre: 91,53%</i> <i>Nivell dataset: 100%</i> <i>Nivell metadades: 35,29%</i>	28,53 punts
Consistència	<i>Nivell combinació: 100%</i> <i>Nivell registre: 100%</i> <i>Nivell registre creuats: 100%</i> <i>Nivell dataset: No avaluat. Falta informació.</i>	(La proporció es realitza sense avaluar dataset) 35 punts	<i>Nivell combinació: 97,89%</i> <i>Nivell registre: 96,61%</i> <i>Nivell registre creuats: 97,46%</i> <i>Nivell dataset: No avaluat. Falta informació.</i>	(La proporció es realitza sense avaluar dataset) 34,06 punts

Elements ODQ	Mostra 1		Mostra 2	
	Puntuació proves	Valor final	Puntuació proves	Valor final
Dimensió Usabilitat (no resultat recuperabilitat)	57,33 punts		51,56 punts	
Llegibilitat / Interpretabilitat	0,65 punts	13 punts	0,50 punts	10 punts
Comprensibilitat	1 punt	10 punts	0,66 punts	6,60 punts
Georeferenciació	1 punt	3,33 punts	2 punts	6,66 punts
Obertura	3 punts	12 punts	3 punts	12 punts
Recuperabilitat	No avaluat. Falta informació.	No avaluat	No avaluat. Falta informació.	No avaluat
Localització	0,50 punts	5 punts	0,13 punts	1,30 punts
Eficiència	5 punts	10 punts	5 punts	10 punts
Comparabilitat	0,40 punts	4 punts	0,50 punts	5 punts
Dimensió Disponibilitat (no resultat seguretat/ privacitat ni portabilitat)	27,78 punts		48,80 punts	
Pertinència temporal	Valor escala: 1 0 punts	0 punts	Valor escala: 0 1 punt	10 punts
Actualitat	0 punts	0 punts	1 punt	10 punts
Volatilitat	1 punt	2,50 punts	1 punt	2,50 punts
Accessibilitat	0,60 punts	12 punts	0,70 punts	14 punts
Reutilització	27 punts	13,28 punts	25 punts	12,30 punts
Seguretat / Privacitat	No avaluat. Falta informació.	No avaluat	No avaluat. Falta informació.	No avaluat
Portabilitat	No avaluat. Falta informació.	No avaluat	No avaluat. Falta informació.	No avaluat
VALOR TOTAL	310,61 punts		265,09 punts	

Taula 16. Resultats del procés de mesurament en les dues mostres seleccionades. (Font: Elaboració pròpia, 2021)

A continuació s'estableix la correspondència existent entre els valors totals de cada una de les mostres i el nivell d'assoliment de la qualitat de les dades obertes (nivell ODQ), que en les dues mostres analitzades coincideix amb el nivell 2 tal com es mostra a la següent taula:

Valor total		Nivell ODQ
Mostra 1	Mostra 2	
310,61 punts	265,09 punts	NIVELL 2: Qualitat intermèdia de les dades obertes (de 167 a 333 punts)

Taula 17. Correspondència entre els valors totals i el nivell ODQ. (Font: Elaboració pròpia, 2021).

Finalment, s'adjunta un gràfic comparatiu dels valors totals obtinguts per a cada una de les mostres:

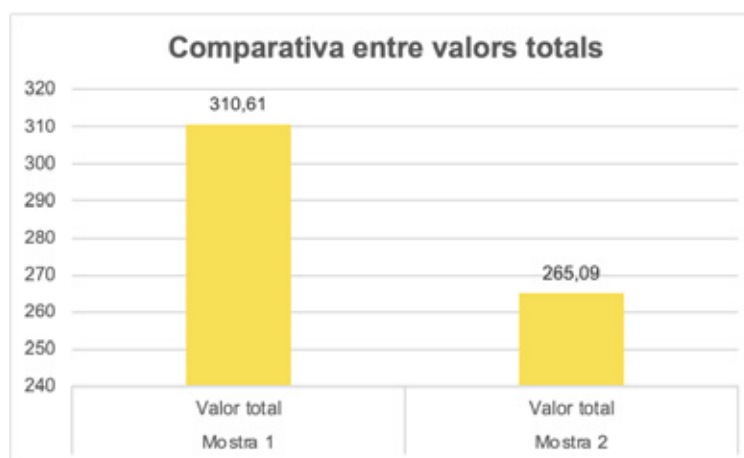


Figura 27. Comparativa entre els valors totals. (Font: Elaboració pròpia, 2021).

3. 5. Discussió i conclusions

Es resultats obtinguts durant el procés de mesurament de les dues mostres seleccionades posen de manifest quatre aspectes rellevants per a la investigació:

- En primer lloc, el model de qualitat de les dades obertes en tant que abstracció de la realitat funciona. Convé remarcar que un dels objectius de l'execució de la prova de concepte era la validació funcional del model, i amb aquest fi es van seleccionar dues mostres que presentaven diferències de qualitat que ja es percebien a simple vista, per exemple, a nivell de metadades. A la vista dels resultats que es recapitulen a la **Taula 16** es confirma que el model ODQ s'ajusta a la realitat ja que recull les diferències de qualitat existents entre ambdues mostres, la qual cosa corrobora la validació del model en les seves tres vessants (conceptual, lògic i metodològic).
- En segon lloc, arran del procés de mesurament es confirma l'afirmació de Mahanti (2018) pel que fa a la relació existent entre exactitud i consistència, concretament es confirma que: 1) si hi ha valors inconsistents almenys un valor no és exacte, i 2) si els valors són consistents no necessàriament indica que els valors són exactes. La primera correlació s'ha demostrat a la mostra 2, ja que hi ha inconsistències entre els dos conjunts de dades comparats pel que fa al nombre de dígit del codi INE, i al seu torn també hi ha valors no

exactes en el dataset analitzat. I en quant a la segona correlació s'ha evidenciat a la mostra 1, atès que no hi ha valors inconsistents o incoherències entre els dos conjunts de dades comparats però sí hi ha elements de dades no exactes, en concret, el valor Bigues i Riells.

- En tercer lloc, de l'avaluació de l'element pertinència temporal s'evidencia la relació existent entre índex de puntualitat i pertinència temporal. En particular, sembla que es tracta d'una correlació inversa o negativa ja que quan l'índex de puntualitat és 0, la pertinència temporal és adequada i, per tant, s'obté 1 punt (mostra 2). En canvi, quan l'índex de puntualitat és 1, la pertinència temporal no és apropiada i s'obté 0 punts (mostra 1). No obstant, convé remarcar que es tracta d'una hipòtesis i que caldria realitzar més proves a fi de corroborar aquesta correlació inversa.
- En darrer terme, es confirma la idea plantejada a l'apartat 3.1 en relació amb la importància de la prova de concepte, no només pel que fa als resultats sinó també en referència al procés d'aprenentatge. En aquest sentit, amb l'execució de la prova s'han detectat les fortalezes i debilitats del model, que juntament amb les amenaces i oportunitats del context han permès realitzar un anàlisi DAFO i proposar accions de millora adreçades a perfeccionar el model ODQ, tal com es detalla en el següent subapartat.

3. 5. 1. DAFO i propostes de millora

L'anàlisi DAFO és un mètode de planificació estratègica multidimensional que permet identificar els següents aspectes (Speth, 2016, 12):

- D'una banda, distingir entre factors interns del projecte (fortalezes i debilitats) i factors externs vinculats al context (oportunitats i amenaces).
- D'altra banda, diferenciar entre punts dèbils del projecte (debilitats i amenaces) i punts forts (fortalezes i oportunitats).

L'anàlisi de les **debilitats**, **amenaces**, **fortalezes** i **oportunitats** (DAFO) del projecte es materialitza en una matriu (anomenada matriu DAFO) que es compon de quatre quadrants, on s'encreuen les valoracions de les fortalezes i debilitats amb les valoracions de les oportunitats i amenaces (TERMCAT, Centre de Terminologia). Cada quadrant representa el següent:

- **Fortalezes:** factors o característiques internes del projecte que influeixen de forma positiva per a la consecució dels objectius.
- **Debilitats:** factors o característiques internes del projecte que influeixen de forma negativa per a l'assoliment dels objectius.

- **Oportunitats:** factors o característiques externes, vinculades al context, que poden representar un avantatge per al desenvolupament del projecte.
- **Amenaces:** factors o característiques externes, vinculades al context, que poden representar un perill per al desenvolupament del projecte.

En el marc de la present investigació s'han elaborat dues matrius DAFO del model de qualitat de les dades obertes on s'han identificat tant els punts dèbils i forts com els factors interns i externs que influeixen, ja sigui limitant o potenciant, l'aplicabilitat del model ODQ. La primera matriu, anomenada matriu DAFO inicial, presenta una radiografia de la situació del model abans de la incorporació d'algunes millores durant el procés de mesurament:

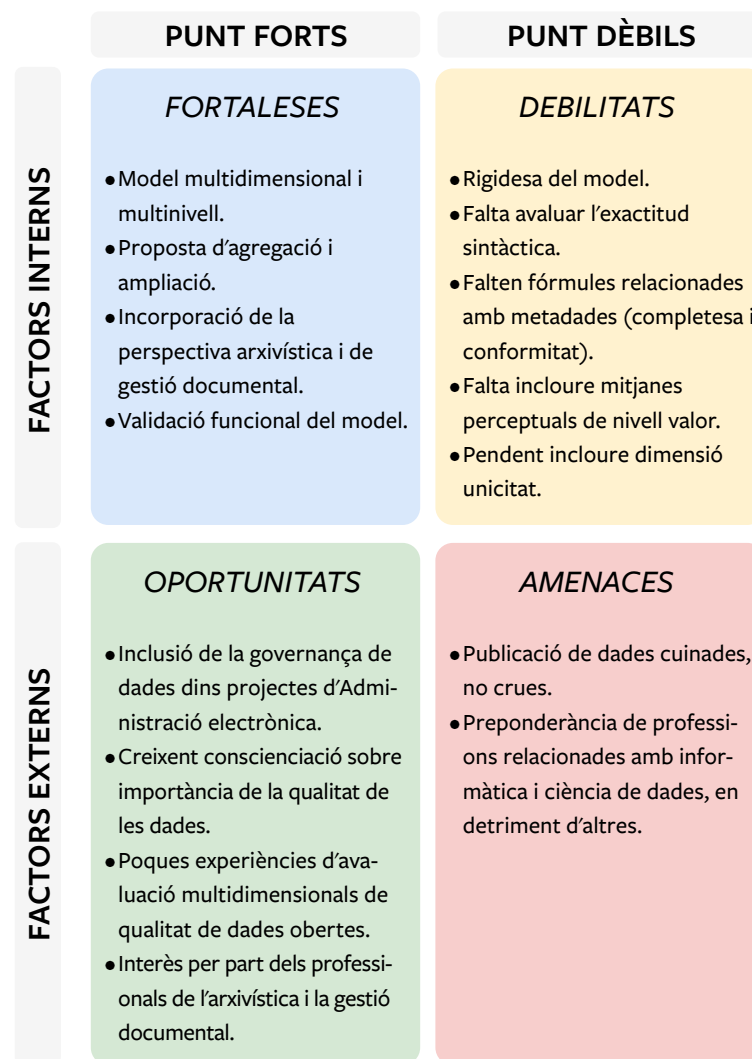


Figura 28. Matriu DAFO inicial: abans de la incorporació de millores. (Font: Elaboració pròpia, 2021).

Així doncs, en l'execució de la prova de concepte s'han detectat certes mancances en algunes de les mètriques, el que ha permès incorporar les següents millores durant el procés de mesurament de les mostres seleccionades:

- En les propietats conformitat, exactitud i completesa el nivell element de dades conté tants percentatges com valors crítics mesurats. En aquest sentit, a més d'aquests percentatges individuals s'incorpora també la mitjana percentual a nivell d'element de dades o valors.
- A l'element conformitat s'ha afegit una fórmula per a mesurar si el conjunt de metadades és conforme a l'estàndard de referència. Per a dissenyar aquesta fórmula s'ha pres com a model la fórmula de conformitat de registre.
- A l'element completesa s'ha afegit una fórmula per a mesurar el total de metadades obligatòries que s'informen en relació amb el total de metadades mínimes obligatòries segons estàndard de referència. Per a dissenyar aquesta fórmula s'ha pres com a model la fórmula de completesa de registre.

Un cop incorporades les millores anteriors la matriu DAFO final queda de la següent forma:

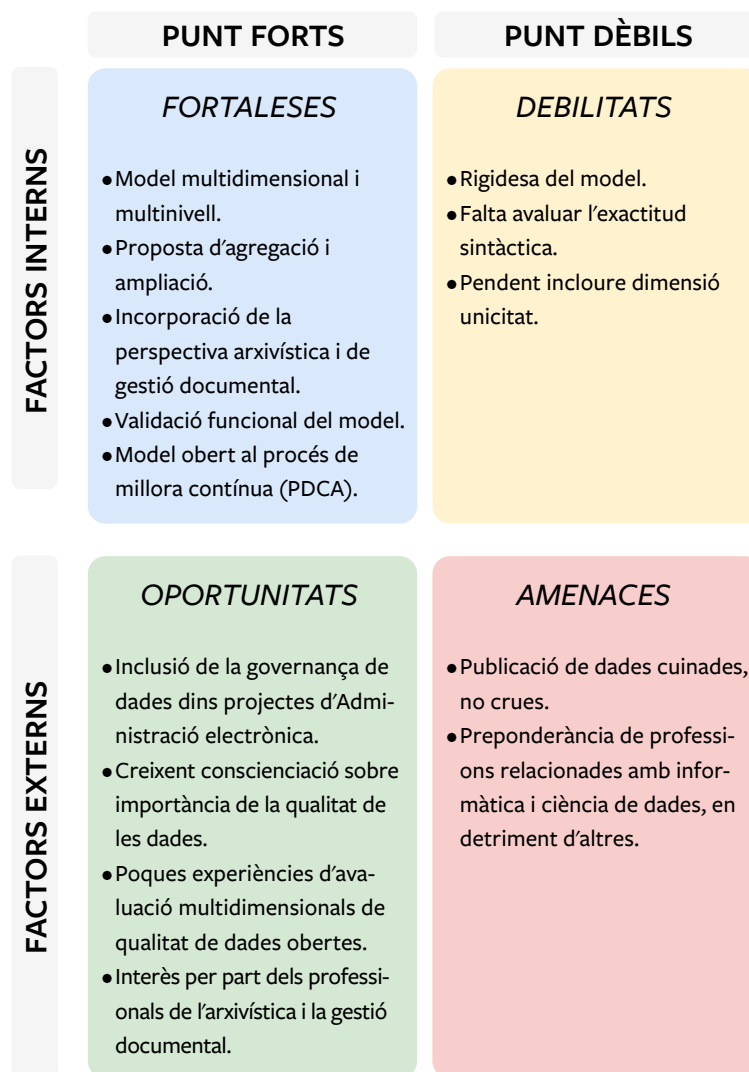


Figura 29. Matriu DAFO final: després de la incorporació de millores. (Font: Elaboració pròpia, 2021).

En quant a la resta de limitacions que s'han identificat s'estableix una relació de propostes de millora per a incorporar en el futur:

- Flexibilitzar el model, atès que hi ha elements ODQ que no sempre apliquen com la precisió; per la qual cosa es fa necessari que el pes i els valors finals s'adaptin a la realitat de cada organització i als conjunts de dades avaluats.
- Incloure mètrica relacionada amb l'exactitud sintàctica, ja que el model només avalua l'exactitud semàntica, és a dir, la correctesa de les dades.
- Incloure la dimensió unicitat i els elements ODQ que la conformen, tal com la duplicitat, la redundància, etc.
- I en darrer terme revisar la norma UNE-ISO 16363:2017, a fi de captar si hi ha aspectes relacionats amb els repositoris digitals que es poden afegir a l'element seguretat/privacitat.

Aquesta recerca s'inicia amb una hipòtesi i dues preguntes d'investigació que s'han treballat a partir dels objectius generals i específics fixats. La hipòtesi planteja que la integració teòrica i, en alguns casos, metodològica de l'arxivística i la gestió documental, la gestió de les dades, la teoria sistèmica i la teoria provinent de les dades obertes i el govern obert, contribueix a millorar l'aproximació a l'avaluació de les dimensions de qualitat de les dades obertes.

Per a desenvolupar la hipòtesi s'ha realitzat, primerament, una revisió i anàlisi bibliogràfic del marc teòric i estat de l'art dels quatre àmbits d'estudi, per a posteriorment elaborar un model unificat d'avaluació de les propietats ODQ. Aquesta aproximació incorpora elements provinents de les diferents disciplines, tal com aspectes extrets d'estàndards i convencions de l'arxivística i la gestió documental, principis i bones pràctiques provinents de la gestió i administració de les dades obertes, mètriques desenvolupades des d'enginyeria informàtica, etc. Així doncs, davant la pluralitat existent el model s'erigeix com una proposta d'agregació i ampliació que destaca, d'una banda, per la incorporació de la perspectiva arxivística i de gestió documental, i d'altra banda, per la integració de diferents àmbits d'estudi per a una mateixa finalitat. Amb tot, el Model de qualitat de les dades obertes està conformat per tres models específics (*vid.* **Figura 19**) que són el model conceptual, el model lògic i el model metodològic, que al seu torn es correlacionen amb els objectius específics 1 i 2.

Pel que fa a l'objectiu específic 3, la validació experimental de la proposta s'ha realitzat en dues mostres concretes que, entre altres consideracions, presenten diferents nivells de qualitat que a simple vista s'observen. Convé destacar que hi ha elements ODQ que no s'han pogut avaluar per falta d'informació, ja que per a realitzar el mesurament és necessari conèixer els sistemes d'informació i de gestió, i en general, el *back office* de l'organització; no obstant, es considera que els resultats obtinguts de la prova de concepte confirmen dos aspectes:

- Per una part, es posa de manifest que el model —en tant que abstracció de la realitat— funciona, atès que les puntuacions finals i totals capten les diferències de qualitat existents entre els datasets i les metadades avaluades. És a dir, el model s'ajusta a la realitat.
- Per l'altra, la hipòtesi plantejada es corrobora ja que la combinació dels quatre àmbits d'estudi ha possibilitat l'elaboració d'un model més complert i integrador. En aquest sentit, tant l'arxivística i la gestió documental, com la gestió de les dades i la teoria provinent de les dades obertes i el govern obert comparteixen un problema central, que és l'avaluació i millora de la qualitat de les dades (obertes). Altrament, al combinar aquestes disciplines s'avança molt més en la recerca i, a més, s'amplien les teories i mètodes de cada àmbit.

De manera paral·lela, l'aplicació de la teoria sistèmica i cibernètica permet anar més enllà de les dades obertes i concebre tot un ecosistema, format per diferents actors, amb entrades i sortides i amb circuits de retroalimentació, que contextualitza i justifica el model atès que els resultats de les mesures retornen com a informació al mateix sistema i serveixen, en cas d'error, per aplicar les mesures necessàries. Així mateix, convé destacar que la concepció plantejada de l'ecosistema de dades obertes com a sistema cibernètic es troba vinculada al cicle Deming o PDCA. Tal com s'ha evidenciat durant la prova de concepte, l'aplicació del cicle PDCA assegura la millora contínua ja que es tracta d'una metodologia en la que davant la detecció d'errors o incidències, s'apliquen millores al sistema a fi de resoldre els problemes identificats.

En un altre ordre de coses, el Model de qualitat de les dades obertes pretén superar les problemàtiques identificades durant la revisió de les investigacions, que són les que s'enumeren a continuació:

- Existència d'una gran pluralitat de propostes en relació amb les dimensions que conformen la qualitat de les dades.
- Ús de termes diferents amb un significat similar.
- Ús de mateixos termes però amb significats diferents.

- Confusió o diversitat de definicions en relació amb algunes propietats de qualitat.
- Dificultats o diversitat de classificació en relació amb algunes de les característiques de qualitat.

Així doncs, el model es presenta com una primera versió unificada de dimensions/elements ODQ i mètriques. Altra ment, la finalitat de la proposta és esdevenir una eina metodològica per a que les administracions puguin avaluar les dimensions de qualitat de les dades a partir d'un procés de mesurament de cada un dels elements ODQ, a fi de conèixer, en última instància, la correlació entre el valor total obtingut i un dels tres nivells d'assoliment de la qualitat.

Certament, el model s'ha demostrat que funciona i, a més, els objectius generals fixats s'han assolit totalment. Pel que fa a les línies de futur, s'evidencia que hi ha continuïtat en la recerca atès que, d'una banda, hi ha propostes de millora que s'hi poden introduir a fi de perfeccionar el model, tal com incorporar la dimensió unicitat. I, d'altra banda, es considera que les proves de concepte han validat la proposta i que el següent nivell és la seva aplicabilitat en una institució, a fi de verificar que les mètriques s'ajusten al model conceptual i, en cas necessari, realitzar les millores oportunes.

Bibliografia

Abella, A. (2011). Reutilización de información pública y privada en España. Avance de situación para agentes públicos y privados. Una oportunidad para los negocios y el empleo. Rooter Analysis S.L.

https://gobiernoabierto.navarra.es/sites/default/files/opendata/reutilizacion_informacion_publica_privada_od_rooter.pdf

Abella, A.; Ortiz-de-Urbina-Criado, M.; De-Pablos-Heredero, C. (2014). Meloda, métrica para evaluar la reutilización de los datos abiertos. *El profesional de la información*, 23 (6).

<https://doi.org/10.3145/epi.2014.nov.04>

Abella, A.; Ortiz-de-Urbina-Criado, M.; De-Pablos-Heredero, C. (2018). Indicadores de calidad de datos abiertos: el caso del portal de datos abiertos de Barcelona. *El profesional de la información*, 27 (2).

<https://doi.org/10.3145/epi.2018.mar.16>

Abella, A.; Ortiz-de-Urbina-Criado, M.; De-Pablos-Heredero, C. (2019). Meloda 5: a metric to assess open data reusability. *El profesional de la información*, 28 (6).

<https://doi.org/10.3145/epi.2019.nov.20>

Abella, A.; Ortiz-de-Urbina-Criado, M.; De-Pablos-Heredero, C.; Vidal, C.; i Ferrer, A. (2019). *La reutilización de datos abiertos en España II*. Fundación COTEC para la innovación.

Acosta, L. (2000). Cibernética y teoría de sistemas. *Números: Revista de didáctica de las matemáticas*, (43-44), 233-236.

AENOR (2004). *UNE-ISO/IEC 14598-1. Tecnología de la información. Evaluación del producto de software. Parte 1: Visión general*. AENOR.

AENOR (2015). *UNE 178301. Ciudades inteligentes. Datos Abiertos (Open Data)*. AENOR.

AENOR (2016). *UNE-ISO 15489-1:2016. Información y documentación. Gestión de documentos. Parte 1: Conceptos y principios*. AENOR.

AENOR (2018). *UNE-EN ISO 9004:2018. Gestión de la calidad. Calidad de una organización. Orientación para lograr el éxito sostenido*. AENOR.

AENOR (2021). *UNE-ISO 30300. Información y documentación. Gestión de documentos. Conceptos fundamentales y vocabulario*. AENOR.

Aguado, J. (2004). *Introducción a las Teorías de la Información y la Comunicación*. Facultad de Comunicación y Documentación, Universidad de Murcia.

[https://www.um.es/tic/Txtguia/Introduccion%20a%20las%20Teorias%20de%20la%20Informa%20\(20\)/TIC%20texto%20guia%20completo.pdf](https://www.um.es/tic/Txtguia/Introduccion%20a%20las%20Teorias%20de%20la%20Informa%20(20)/TIC%20texto%20guia%20completo.pdf)

Ajuntament de l'Hospitalet (s.d.). *Glossari de termes de dades obertes*.

<https://dadesobertes.l-h.cat/obrefitxer.ashx?Fw9E-Vw48XS5BCW3KHt8k2lo8UEePI4eUVsbuMqX9QQMqazB>

Almansa, A. (2017). *Transparencia y datos abiertos en la Administración pública*. INAP. Instituto Nacional de Administración Pública.

Álvarez, M. (2014). *Apertura y reutilización de datos públicos*. Generalitat de Catalunya.

https://governobert.gencat.cat/web/.content/01_Queres/04_Publicacions/colleccio_govern_obert/GovernObert_2/governobert_2_es.pdf

APORTA (2017). *El valor de los datos abiertos para la Administración*.

https://datos.gob.es/sites/default/files/blog/file/informe_el_valor_de_los_datos_abiertos_para_la_adminis.pdf

APORTA (2017). *Conceptos básicos, beneficios del open data y barreras para su aplicación*.

https://datos.gob.es/elearning/Unidades_Didacticas/Unidad_1/contenidos/descargas/unidad_imprimible.pdf

APORTA (2017). *Manual práctico para mejorar la calidad de los datos abiertos*.

https://datos.gob.es/sites/default/files/doc/file/manual_practico_para_mejorar_la_calidad_de_los_datos_abiertos_1.pdf

APORTA (2018). *DCAT-AP y sus extensiones. Contexto y evolución*.

https://datos.gob.es/sites/default/files/doc/file/informe_dcat-ap_y_sus_extensiones_1.pdf

Arnold, M.; Osorio, F. (1998). *Introducción a los conceptos básicos de la Teoría General de Sistemas. Cinta de Moebio*, (3). Facultad de Ciencias Sociales. Universidad de Chile.

<https://www.redalyc.org/articulo.oa?id=10100306>

Arnold, M.; Osorio, F. (2008). La Teoría General de Sistemas y su aporte conceptual a las ciencias sociales. Dins F. Osorio; M. Arnold; S. González; E. Aguado (Coord.). *La nueva teoría social en Hispanoamérica: introducción a la teoría de sistemas constructivista*. (pp. 17-44). Universidad Autónoma del Estado de México. [http://repositorio.uchile.cl/bitstream/handle/2250/122268/La teoria general de sistemas y su aporte.pdf?sequence=1&isAllowed=y](http://repositorio.uchile.cl/bitstream/handle/2250/122268/La%20teoria%20general%20de%20sistemas%20y%20su%20aporte.pdf?sequence=1&isAllowed=y)

Asociación Multisectorial de la Información (ASEDIE) (2020). *Sector infomediario*. <https://static1.squarespace.com/static/600a99c4d2a8133c3599fc67/t/60361da7172ae6638e3c2c1c/1614159282231/informe-asedie-sobre-el-sector-infomediario-2020-vf.pdf>

Associació d'Arxivers de Catalunya (2002). *Codi deontològic dels arxivers catalans*. Associació d'Arxivers de Catalunya.

Badia, A. (1998). Los “gurús” de la calidad. *Harvard deusto business review*, (87), 88-93

Ballou, D.; Wang, R.; Pazer, H.; Tayi, G. (1998). Modeling Information Manufacturing Systems to Determine Information Product Quality. *Management Science*, 44 (4), 462-484. <https://www.jstor.org/stable/2634609>

Batini, C.; Scannapieco, M. (2016). *Data and Information Quality. Dimensions, Principles and Techniques*. Springer International Publishing Switzerland.

Bertalanffy (1989). *Teoría general de los sistemas. Fundamentos, desarrollo, aplicaciones*. Fondo de Cultura Económica.

Boisot, C.; Canals, A. (2004). Data, information and knowledge: have we got it right? *Journal of Evolutionary Economics*, 14 (1), 43-67. <http://dx.doi.org/10.1007/s00191-003-0181-9>

Bourdieu, P. (1993). Esprits d'Etat. *Actes de la recherche en sciences sociales*, (96-97), 49-62. <https://doi.org/10.3406/arss.1993.3040>

Bovee, M.; Srivastava, R., Mak, B. (2003). A conceptual framework and belief-function approach to assessing overall information quality. *International journal of intelligent systems*, 18 (1), 51-74. <http://dx.doi.org/10.1002/int.10074>

Bowker, G. (2013). Data Flakes: an afterword to “Raw Data” is an oxymoron. Dins L. Gitelman (Ed.). *“Raw Data” is an oxymoron*. (pp. 167- 171). The MIT Press.

Brunet, I.; Morell, A. (2001). Epistemología y cibernética. *Papers*, 65, 41-45. <https://doi.org/10.5565/rev/papers/v65n0.1705>

Bustelo, C. (2018). ¿Cómo aplicar la normativa dispersa sobre gestión del documento electrónico? Dins G. Bustos Pretel (Coord.). *La gestión del documento electrónico* (pp. 29-44). Wolters Kluwer España, S.A.

Cai, L.; Zhu, Y. (2015). The challenges of data quality and data quality assessment in the big data era. *Data Science Journal*, 14 (2), 1-10.

<http://doi.org/10.5334/dsj-2015-002>

Camisón, S.; Cruz, S.; González, T. (2006). *Gestión de la calidad: conceptos, enfoques, modelos y sistemas*. Pearson Educación, S.A.

Camps, R. (2013). Les dades: conceptes introductoris. Dins J. Sistac (Ed.). *Bases de dades*. (pp. 17-42). Editorial UOC.

Casadesús, A. (2018). *La gestión del riesgo aplicada a la gestión de documentos y su impacto en la rendición de cuentas pública*. (Tesi doctoral, Universitat Autònoma de Barcelona).

<http://hdl.handle.net/10803/665386>

Casellas, Ll. (2016). A la preservación de datos... ¡y más allá! *Legajos. Boletín del AGN. Octava época, año 3* (9), 157-187.

https://www.girona.cat/sgdap/docs/CASELLAS_2016_Legajos-Datos.pdf

Cavano, J.; McCall, J. (1978). A framework for the measurement of software quality. *ACM SIGSOFT Software Engineering Notes*, 3 (5), 133-139.

<https://doi.org/10.1145/953579.811113>

Cerdá, J. (2013). *El archivo en las estrategias de gobierno abierto y transparencia. Los sistemas de gestión documental en el nuevo modelo de administración*. Jornadas Ibéricas de Archivos Municipais. Políticas, sistemas e instrumentos, Universidade Lusófona.

<http://arquivomunicipal.cm-lisboa.pt/fotos/editor2/jcerda.pdf>

Cerdá, J. (2015). Gestión documental y gobierno abierto. Nuevos roles para nuevos retos. *Tria. Revista de Archivística de la Asociación de Archiveros de Andalucía*, (19), 115-123.

Cerrillo, A. (2012). La contribución de las TIC a la mejora de la transparencia administrativa. *ARBOR Ciencia, Pensamiento y Cultura*, 188 (756), 707-724.

<https://doi.org/10.3989/arbor.2012.756n4006>

Cerrillo, A. (2014). Los principios de los datos abiertos en la legislación española. *IDP. Revista d'Internet, Dret i Política*, (19), 62-77.

<https://dialnet.unirioja.es/servlet/articulo?codigo=5582974>

Cerrillo, A. (2019). Com obrir les caixes negres de les Administracions públiques? Transparència i rendició de comptes en l'ús dels algorismes. *Revista catalana de dret públic*, (58), 13-28.
<http://dx.doi.org/10.2436/rcdp.i58.2019.3277>

Chacón, J.; Rugel, S. (2018). Artículo de revisión. Teorías, Modelos y Sistemas de Gestión de Calidad. *Revista Espacios*, 39 (50), 14-22.
<https://www.revistaespacios.com/a18v39n50/a18v39n50p14.pdf>

Chengalur-Smith, I.; Neely, M.; Tribunella, T. (2005). The information quality of databases. Dins L. Rivero i J. Doorn (Ed.) *Encyclopedia of Database Technologies and Applications*. (pp. 281-285). IGI Global, ProQuest Ebook Central.

Chesbrough, H. (2003). *Open innovation. The new imperative for creating and profiting from Technology*. Harvard Business School Press.

Colom, A. (1975). Pensamiento y método cibernético. (Su aplicación a la Educación y a las Ciencias Sociales). *Mayurqa*, 14, 119-154.
<https://raco.cat/index.php/Mayurqa/article/view/117569>

Comissió Europea (2011). *Comunicación de la Comisión al Parlamento Europeo, al Consejo, al Comité económico y social europeo y al Comité de las regiones. Datos abiertos. Un motor para la innovación, el crecimiento y la gobernanza transparente* [COM (2011) 882 final].

<https://eur-lex.europa.eu/legal-content/ES/TXT/PDF/?uri=CELEX:52011DC0882&from=ES>

Comissió Europea. (2013). *A vision for public services. Draft version dated 13/06/2013.*

<https://digital-strategy.ec.europa.eu/en/news/vision-public-services>

Comissió Europea (2017). *Anexo de la comunicación de la Comisión al Parlamento Europeo, al Consejo, al Comité económico y social europeo y al Comité de las regiones. Marco Europeo de Interoperabilidad – Estrategia de aplicación.* [COM/2017/0134 final].

<https://eur-lex.europa.eu/legal-content/es/ALL/?uri=CELEX%3A52017DC0134>

Comissió Europea (2019). *DCAT Application Profile for data portals in Europe. Version 2.0.1.*

<https://joinup.ec.europa.eu/collection/semantic-interoperability-community-semic/solution/dcat-application-profile-data-portals-europe/release/201-0>

Comissió Europea (2020). *Analytical Report 5: barriers in working with Open Data*. Publications Office of the European Union. https://data.europa.eu/sites/default/files/edp_analytical_report_n5_-_barriers_in_open_data.pdf

Consorti Administració Oberta de Catalunya (Consorti AOC) (2015). *Guia d'implantació Via Oberta*. Generalitat de Catalunya.

https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwi7vIa0__5AhVhxoUKHU-TaChsQFnoECAMQAQ&url=https%3A%2F%2Fwww.aoc.cat%2Fwp-content%2Fuploads%2F2015%2F11%2F-Guia-implantacio-Via-Oberta-v2.pdf&usg=AOvVaw0b5NAv-zUOTP6kDtTcBZGxl

Consorti Administració Oberta de Catalunya (Consorti AOC) (2020). *Manual del portal de dades obertes i recursos pels ens locals. Versió 2.0*. Generalitat de Catalunya.

https://www.aoc.cat/wp-content/uploads/2020/03/manual-portal_dades_obertes_ens_locals-marc-2020.pdf

Costal, D. (2013). El model relacional i l'àlgebra relacional. Dins J. Sistac (Ed.). *Bases de dades* (pp. 79-107). Editorial UOC.

Crosby, P.B. (1990). *La calidad no cuesta. El arte de cercionarse de la calidad*. Compañía editorial continental, S.A. de C.V.

CRUE Universidades Españolas (2017). *Guía Linked Open Data para archivos universitarios*. Grupo de Trabajo Linked Open Data y Archivos Universitarios.

http://cau.crue.org/wp-content/uploads/GT_9_Gu%C3%ADa_Linked_Open_Data_para_Archivos_Universitarios_2017.pdf

Cruz, J.R. (2011). *Diccionario de Archivística*. Alianza Editorial.

Cruz, J.R. (2012). *Archivística. Gestión de documentos y administración de archivos*. Alianza Editorial.

DAMA International (2009). *The DAMA Guide to the Data Management Body of Knowledge (DAMA-DMBOK Guide)*. Technics Publications, LLC.

DAMA International (2017). *DAMA-DMBOK: Data Management Body of Knowledge*. (2a edició). Technics Publications, LLC.

Davies, T. (2011). *Open Data: Infrastructures and ecosystems*. <https://www.semanticscholar.org/paper/Open-Data%3A-Infrastructures-and-ecosystems-Davies/0607eada1e13331e86107c623a50c234a45a8b47>

Duranti, L.; Michetti, G. (2017). The archival method. Dins A.J. Gilliland, S. McKemmish i A. J. Lau (Ed.). *Research in the Archival Multiverse* (pp. 75-95). Monash University Publishing.

Esparza, C. (s.d). *Series temporales*. Laboratorio de Estadística, CSIC.

http://humanidades.cchs.csic.es/cchs/web_UAE/tutoriales/PDF/SeriesTemporales.pdf

Espuny, N. (2020). L'estratègia de Dades Obertes de la Generalitat de Catalunya. *Revista Idees*, (48 – intel·ligència artificial).

<https://revistaidees.cat/es/la-estrategia-de-datos-abiertos-de-la-generalitat-de-catalunya/>

Eurostat (2017). *Handbook on data quality assessment methods and tools*.

<https://millenniumindicators.un.org/unsd/dnss/docs-nqaf/Eurostat-HANDBOOK%20ON%20DATA%20QUALITY%20ASSESSMENT%20METHODS%20AND%20TOOLS%20%20I.pdf>

Federación Española de Municipios y Provincias (FEMP)

(2017). *Datos abiertos. Guía estratégica para su puesta en marcha. Conjuntos de datos mínimos a publicar*. Wolters Kluwer.

https://datos.gob.es/sites/default/files/doc/file/guia_datos_abiertos.pdf

Federación Española de Municipios y Provincias (FEMP)

(2019). *40 conjuntos de datos a publicar por las Entidades Locales*.

https://datos.gob.es/sites/default/files/doc/file/datos_abiertos_femp_2019-40_conjuntos_de_datos.pdf

Fernández, F. (2016). Documentando gobiernos abiertos, gobernando archivos abiertos. *Carencias del modelo español*. *Tábula*, 19, 53-64.

Fernández, R. (2019). *El auténtico valor del dato: ¿cómo medir su impacto real en el negocio?* 9ª reunión Chief Data Officer. Club Spain & Latam.

https://clubcdo.com/wp-content/uploads/2019/12/eb-ook_el-autentico-valor-del-dato_evento-Club-CDO.pdf

Food and Agriculture Organization of the United Nations (FAO) (2009). *Glosario de agricultura orgánica*.

<http://www.fao.org/3/k4987t/k4987t.pdf>

Fundación Telefónica (2018). *Big data*. Fundación Telefónica.

https://www.fundaciontelefonica.com/wp-content/uploads/2019/12/PROFESIONES_DIGITALES_1.pdf

García, F.; Piattini, M.; García, I. (2018). *Calidad de sistemas de información* (4a edició). RAMA Editorial.

García-Alsina, M. (2015). El sector infomediari en alça: algunes reflexions. *COMeIN. Revista dels Estudis de Ciències de la Informació i de la Comunicació*, (41).

<https://doi.org/10.7238/c.n41.1515>

García-Alsina, M. (2017). Transversalidad y gestión: documentos y datos al Servicio de la toma de decisiones y la transparencia. *RUIDERAE: Revista de Unidades de Información*, (11), 1-16.
<https://revista.uclm.es/index.php/ruiderae/article/view/1382>

García-Morales, E. (2012). Gobernanza de la información. *Anuario ThinkEPI*, 6, 100-103
<https://thinkepi.profesionaldelainformacion.com/index.php/ThinkEPI/article/view/30392>

Generalitat de Catalunya (2020). *Guia d'emplenament de les metadades del conjunt de dades per a la tramesa de dades obertes al Portal de dades obertes de la Generalitat de Catalunya*.
https://governobert.gencat.cat/web/.content/20_DadesObertes/01_Dades_obertes_a_la_gencat/20201130_Guiatecnica_DDOO_GENCAT.pdf

Gitelman, L; Jackson, V. (2013). Introduction. Dins L. Gitelman (Ed.). *"Raw Data" is an oxymoron*. (pp. 1- 14). The MIT Press.

Govern d'Espanya (2014). *Guía de adecuación al Esquema Nacional de Interoperabilidad*. Ministerio de Hacienda y Administraciones Públicas. Secretaría General Técnica. Subdirección General de Información, Documentación y Publicaciones. Centro de Publicaciones.
https://administracionelectronica.gob.es/pae_Home/dam/jcr:a65cea77-17ed-440c-9ab9-824421a2ac97/Guia_adequacion_al_ENI_PDF_NIPO_630-14-238-6.pdf

Govern d'Espanya (2016). *Guía de aplicación de la Norma Técnica de Interoperabilidad de Reutilización de recursos de información*. (2ª edición). Ministerio de Hacienda y Administraciones Públicas. Secretaría General Técnica. Subdirección General de Información, Documentación y Publicaciones. Centro de Publicaciones.

https://administracionelectronica.gob.es/pae_Home/dam/jcr:f73fde29-734e-43bf-b6c6-bf51eaa2e42a/Guia_NTI_PDF_Reutilizacion_recursos_informacion_2ed.pdf

Govern d'Espanya (2016). *Guía de aplicación de la Norma de Interoperabilidad del Documento electrónico*. (2ª edición). Ministerio de Hacienda y Administraciones Públicas. Secretaría General Técnica. Subdirección General de Información, Documentación y Publicaciones. Centro de Publicaciones.
https://administracionelectronica.gob.es/pae_Home/dam/jcr:5881e773-6d5d-48b6-b4a6-7760e63fcfef/Guia_NTI_documento_electronico_PDF_2ed_2016.pdf

Govern d'Espanya (2016). *Guía de aplicación de la Norma Técnica de Interoperabilidad de la Política de gestión de documentos electrónicos*. (2ª edición). Ministerio de Hacienda y Administraciones Públicas. Secretaría General Técnica. Subdirección General de Información, Documentación y Publicaciones. Centro de Publicaciones.
https://administracionelectronica.gob.es/pae_Home/dam/jcr:34e78339-de2e-4fe5-b576-3107e9d3a54c/Guia_NTI_Politica_Gestion_DocElect_PDF_2ed_2016.pdf

Govern d'Espanya (2016). *Guía de auditoría de cumplimiento del Esquema Nacional de Interoperabilidad (ENI)*. Ministerio de Hacienda y Administraciones Públicas. Secretaría General Técnica. Subdirección General de Información, Documentación y Publicaciones. Centro de Publicaciones. https://administracionelectronica.gob.es/pae_Home/dam/jcr:a859d9ac-9519-4cf9-b525-cc7238b5271b/Guia_auditoria_ENI_PDF_1ed_2016.pdf

Hamelink, C. (2015). *La ética del ciberespacio*. Siglo veintiuno editores.

Harrison, T.; Pardo, T.; Cook, M. (2012). Creating Open Government Ecosystems: A Research and Development Agenda. *Future Internet*, 4 (4), 900-928. <https://doi.org/10.3390/fi4040900>

Heimstädt, M.; Sauderson, F.; Heath, T. (2014). From Toddler to Teen: Growth of an Open Data Ecosystem. Longitudinal Analysis of Open data Developments in the UK. *JeDEM*, 6 (2), 123-135. <https://doi.org/10.29379/jedem.v6i2.330>

Hoyer, R.; Hoyer, B. (2001). ¿Qué es calidad? *Revista Quality Progress*, 0 (7), 53-62 <https://es.calameo.com/read/00620574249998b1ff41c>

ISO (2007). *ISO/IEC 15939. Systems and software engineering – Measurement process*. ISO.

ISO (2008). *ISO/IEC 25012. Software engineering – Software product. Quality requirements and evaluation (SQuaRE) – Data quality model*. ISO.

ISO (2015). *ISO 9000:2015. Sistemas de gestión de calidad – Fundamentos y vocabulario*. ISO.

ISO (2016). *ISO 8000-61. Data quality – Part 61: Data quality management: process reference model*. ISO.

Janssen, M.; Charalabidis, Y.; Zuiderwijk, A. (2012). Benefits, adoption barriers and myths of open data and open government. *Information Systems Management*, 29 (4), 258-268.

Jarke, M.; Jeusfeld, M.; Quix, C.; i Vassiliadis, P. (1999). Architecture and quality in data warehouses: an extended repository approach. *Information Systems*, 24 (3), 229-253. [https://doi.org/10.1016/S0306-4379\(99\)00017-4](https://doi.org/10.1016/S0306-4379(99)00017-4)

Juran, J.; Blanton, A.; Hoogstoel, R.; Schilling, E. (2001). *Manual de calidad de Juran. Volumen I*. McGraw-Hill/Interamericana de España, S.A.U

Kahn, B.; Strong, D.; Wang, R. (2002). Information quality benchmarks: product and service performance. *Communications of the ACM*, 45 (4), 184-192. <https://doi.org/10.1145/505248.506007>

Kitchin, R. (2014). Open and linked data. Dins R. Kitchin. *The Data Revolution: Big data, open data, data infrastructures and their consequences*. (pp. 48-66). SAGE Publications.

Kovac, R.; Lee, Y.; Pipino, L. (1997). *Total Data Quality Management: the case of IRI*. Conference: Second Conference on Information Quality. [Conference paper].
https://www.researchgate.net/publication/220918593_Total_Data_Quality_Management_The_Case_of_IRI

Kroes, N. (2012). *Digital Agenda and Open Data. From crisis of trust to Open Governing*. [SPEECH/12/149].
https://ec.europa.eu/commission/presscorner/detail/en/SPEECH_12_149

Kubler, S.; Robert, J.; Neumaier, S.; Umbrich, J.; Le Traon, Y. (2017). Comparison of metadata quality in open data portals using the Analytic Hierarchy Process. *Government Information Quarterly*, 35 (1), 13-29.
<https://doi.org/10.1016/j.giq.2017.11.003>

Kulikowski, J. (2005). Data quality assessment. Dins L. Rivero i J. Doorn (Ed.) *Encyclopedia of Database Technologies and Applications*. (pp. 116-120). IGI Global, ProQuest Ebook Central.

Leal, F. (2019). *Por qué es importante la prueba de concepto para tu empresa*. El Periódico.

<https://www.elperiodico.com/es/activos/innovadores/20191113/por-que-es-importante-la-prueba-de-concepto-para-tu-empresa-7733441>

Lee, Y.; Strong, D.; Kahn, B.; Wang, R. (2002). AIMQ: a methodology for information quality assessment. *Information & Management*, 40 (2), 133-146.
[https://doi.org/10.1016/S0378-7206\(02\)00043-5](https://doi.org/10.1016/S0378-7206(02)00043-5)

Llinares, X. (2010). Las 10 claves para entender la colaboración en el Modelo Open Government. Dins C. Calderón; i S. Lorenzo (Coord.). *Open government: gobierno abierto*. (pp. 51-74). Algón.

Lollai, S. (2017). Quality Systems. A Thermodynamics-Related Interpretative Model. *Entropy*, 19 (8), 1-20.
<https://doi.org/10.3390/e19080418>

Mahanti, R. (2018). *Data Quality: Dimensions, Measurement, Strategy, Management, and Governance*. ASQ Quality Press.

Mahanti, R. (2019). Data quality and data quality dimensions. *SQP*, 22 (1), 4-8.

Mahecha, J.; López, N.; Velandia, J. (2017). *Assessing data quality in Open Data: a case study*. Congreso Internacional de Innovación y Tendencias en Ingeniería (CONIITI). [Conference].
<http://dx.doi.org/10.1109/CONIITI.2017.8273343>

Marciano, R.; Lemieux, V.; Hedges, M.; Esteva, M.; Underwood, W.; Kurtz, M.; i Conrad, M. (2018). Archival records and training in the age of Big data. Dins J. Percell; L.C. Sarin; P.T. Jaeger; J.C. Bertot (Ed.). *Re-envisioning the MLS: Perspectives on the Future of Library and Information Science Education* (pp. 179-199). Emerald Publishing Limited.

Martín, I. (2014). Transparencia, reutilización y datos abiertos. Algunas reflexiones generales sobre el acceso libre a la información pública. Dins J. Valero Torrijos y M. Fernández Salmerón (Ed.). *Régimen jurídico de la transparencia del sector público: del derecho de acceso a la reutilización de la información* (p. RB-10.1). Cizur Menor: Thomson-Aranzadi.

Mayer-Schönberger, V.; Cukier, K. (2013). *Big data. La revolución de los datos masivos*. Turner Publicaciones S.L.

McDonald, J. (1989). Records management and data management: closing the gap. *Records Management Journal*, 1 (1), 4-11. [Versió original]
<https://doi.org/10.1108/eb027016>

McDonald, J. (2010). Records management and data management: closing the gap. *Records Management Journal*, 20 (1), 53-60.
<https://doi.org/10.1108/09565691011039825>

McGee, R.; Edwards, D. (2016). Introduction: opening governance – change, continuity, and conceptual ambiguity. *IDS Bulletin. Transforming Development Knowledge*, 47 (1), 1-22.

McLeod, M.; McNaughton, M. (2016). Mapping an emerging Open Data ecosystem. *The Journal of Community Informatics*, 12 (2), (Special issue on Open Data for Social Change and Sustainable Development), 26-46.
<https://doi.org/10.15353/joci.v12i2.3220>

Mendo, C.; Ramos, F.; Arquero, R.; Del Valle-Gastaminza, F.; Botezán, I.; Sánchez, R.; Tejada, C.; Peón, J.; Cobo, S.; i Sala, A. (2013). Del acceso a la reutilización, del dato al documento: una visión conceptual de la información pública. *Revista Española de Documentación Científica*. 36 (3), e013.
<https://doi.org/10.3989/redc.2013.3.957>

Mordell, D. (2019). Critical questions for archives as (Big) data. *Archivaria. The Journal of the Association of Canadian Archivists*, 87, 140-161.

Moreno-Luzón, M.; Peris, F.; González, T. (2001). *Gestión de la Calidad y diseño de organizaciones. Teoría y estudio de casos*. Pearson Educación, S.A.

Moyano, J. (2015). Gestión documental en un marco de transparencia y reutilización de la información. *Lligall*, (38), 45-61.
<https://raco.cat/index.php/lligall/article/view/340130>

Obama (2011). *Presidential Memorandum – Managing Government Records*. The White House. Office of the Press Secretary.
<https://obamawhitehouse.archives.gov/the-press-office/2011/11/28/presidential-memorandum-managing-government-records>

Observatorio Nacional de las Telecomunicaciones y de la Sociedad de la Información (ONTSI) (2014). *Informe Final - Estudio de Caracterización del Sector Infomediario 2014. Parte I. Análisis Sector Infomediario Público*.
https://www.ontsi.red.es/sites/ontsi/files/estudio_de_caracterizacion_del_sector_infomediario_en_espana_2014_parte_i_publica.pdf

Olson, J. (2003). *Data quality: the accuracy dimension*. EBSCO Publishing: eBook collection.

Open Data Support (2014). *Open Data & Metadata Quality*. European Commission.
https://joinup.ec.europa.eu/sites/default/files/document/2015-05/d2.1.2_training_module_2.2_open_data_quality_v1.00_en.pdf

Orte, A. (2018). La qualitat a l'administració pública moderna. Dins M. Luria; A. Orte. *Gestió del canvi a les administracions públiques*. FUOC.
http://cv.uoc.edu/annotation/c898df79a34ce4f7581bd-7f6ad8b232a/676982/PID_00255925/PID_00255925.html

París, C. (2000). *El animal cultural. Biología y cultura en la realidad humana*. Editorial Crítica, S.L.

Peset, F.; Fernández-López, A. (2014). Carencias informativas de los datos abiertos en España. *Anuario ThinkE-PI*, 8, 318-231.
<https://riunet.upv.es/handle/10251/50381>

Pineda, L. (2020). Aproximación teórica al concepto de calidad y los sistemas de gestión. *SUMMA. Revista disciplinaria en ciencias económicas y sociales*, 2 (1), 41-62.
<https://aunarcali.edu.co/revistas/index.php/RDCES/article/view/110>

Pipino, L.; Lee, Y.; Wang, R. (2002). Data quality assessment. *Communications of the ACM*, 45 (4), 211-218.
<https://doi.org/10.1145/505248.506010>

Prado, M.A (2017). La gestión documental y las políticas de datos abiertos: una confluencia necesaria. *Consultor de los ayuntamientos y de los juzgados: Revista técnica especializada en administración local y justicia municipal*, 7, 890-904.

PwC (2019). *El camino a la transformación digital*. PwC Venezuela.
<https://www.pwc.com/ve/es/publicaciones/assets/PublicacionesNew/Boletines/4RI-El-camino-a-la-transformacion-digital.pdf>

Ruiz, V.; Soler, J. (Coord.). (2016) *Model de maduresa en gestió documental per a la transparència i la publicitat activa*. Associació d'Arxivers – Gestors de Documents de Catalunya. <https://arxivers.com/recerca/model-de-maduresa/>

Sanabria, P.; Romero, V.; Flórez, C. (2013). El concepto de calidad en las organizaciones: una aproximación desde la complejidad. *Universidad & Empresa*, 16 (27), 165-213. <https://doi.org/10.12804/rev.univ.empresa.27.2014.06>

Serra, J. (2008). *Los documentos electrónicos. Qué son y cómo se tratan*. Ediciones Trea, S.L.

Serra, J. (2021). *Datos: ¿una amenaza? Gestión de documentos y archivos en la era de los datos*. Conferència realitzada el 14 d'abril de 2021 en el VIII Congreso de Archivos de Castilla y León (Cacyl 2021).

Shapiro, C.; Varian, H. (2000). *El dominio de la información. Una guía estratégica para la economía de la red*. Antoni Bosch Editor, S.A.

Silberschatz, A.; Korth, H.; Sudarshan, S. (2006). *Fundamentos de bases de datos*. (5ª edició). McGraw-Hill/Interamericana de España, S.A.U.

Slibar, B.; Oreski, D.; Klicek, B. (2018). *Aspects of open data and illustrative quality metrics: literature review*. 35th International Scientific Conference on Economic and

Social Development – “Sustainability from an Economic and Social Perspective”, Lisbon, 15-16 November de 2018. [Conference Papers & Proceedings].

<https://www.proquest.com/openview/305fada3d19e46e-2ae5b41f663ce0784/1?pq-origsite=gscholar&cbl=2033472>

Soler, J. (2009). *Del bit al logos. Preservar documents electrònics a l'Administració local*. Col·lecció Estudis, sèrie recursos culturals, 4. Diputació de Barcelona.

Soler, J. (2018). De la gestió documental a la governança de la informació: un debat tècnic, una qüestió política. *Lligall*, (41), 12-15.

<https://raco.cat/index.php/lligall/article/view/360057>

Strong, D.; Lee, Y.; Wang, R. (1997). Data quality in context. *Communications of the ACM*, 40 (5), 103-110.

<https://doi.org/10.1145/253769.253804>

Thomas (1993). La teoría general de sistemas. *Cuadernos de Geografía: Revista colombiana de Geografía*, 4 (1-2), 111-137.

<https://revistas.unal.edu.co/index.php/rcg/article/view/70711/64920>

Thurston, A. (2012). Trustworthy Records and Open Data. *Special Issue: Community Informatics and Open Government Data*, 8 (2), 1-6.

<https://doi.org/10.15353/joci.v8i2.3047>

Torres, M.; Vásquez, C. (2010). La Calidad: evolución de su significado y aplicación en servicios. *Publicaciones en Ciencias y Tecnología*, 4 (2), 25-32.

<https://dialnet.unirioja.es/servlet/articulo?codigo=6505356>

Ubaldi, B. (2013). Open Government Data: Towards Empirical Analysis of Open Government Data Initiatives. *OECD Working Papers on Public Governance No. 22*.

<https://dx.doi.org/10.1787/5k46bj4f03s7-en>

Universidad Nacional Autónoma de México (s.d). *Cifras significativas y su manejo*. Facultad de Química.

https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwjlgAOD_P_5AhUG-xoKH-doYDh0QFnoECAYQAQ&url=https%3A%2F%2Famyd.quimica.unam.mx%2Fmod%2Fresource%2Fview.php%3Fid%3D2685&usg=AOvVaw02vy0fn3-8xOer5DIW69k-

Vale, S. (2008). *Accessibility and clarity: the most neglected dimensions of quality?* Committee for the Coordination of Statistical Activities. Conference on Data Quality for International Organizations, Rome, Italy, 7-8 July 2008.

<https://unstats.un.org/unsd/accsub/2008docs-CDQIO/Ses3-Pap3.pdf>

Van Schalkwyk, F.; Willmers, M.; McNaughton, M. (2016). Vis-uous Open Data: The roles of intermediaries in an Open data Eco-system. *Information Technology for Development*, 22 (1), 68-83.

<http://dx.doi.org/10.1080/02681102.2015.1081868>

Varona (1996). *Métodos clásicos de resolución de ecuaciones diferenciales ordinarias*. Servicio de Publicaciones, Universidad de La Rioja.

<https://www.unirioja.es/cu/jvarona/downloads/LibroED.pdf>

Wand, Y.; Wang, R. (1996). Anchoring data quality dimensions in ontological foundations. *Communications of the ACM*, 39 (11), 86-95.

<https://doi.org/10.1145/240455.240479>

Wang, R. (1998). A product perspective on total data quality management. *Communications of the ACM*, 41 (2), 58-65.

<https://doi.org/10.1145/269012.269022>

Wang, R.; Storey, V.; Firth, C. (1995). A Framework for analysis of data quality research. *IEEE Transactions on knowledge and data engineering*, 7 (4), 623-640.

Wang, R.; Strong, D. (1996). Beyond Accuracy: what data quality means to data consumers. *Journal of Management Information Systems*, 12 (4), 5-33.

http://mitiq.mit.edu/Documents/Publications/TDQM-pub/14_Beyond_Accuracy.pdf

Wiener, N. (1986). *Cibernètica o control i comunicació en l'animal i la màquina*. Edicions Científiques Catalanes.

Webgrafia

Wilkinson, M., Dumontier, M., Aalbersberg, I. et al. (2016). The FAIR Guiding principles for scientific data management and stewardship. *Scientific Data*, 3, 1-9.

<https://doi.org/10.1038/sdata.2016.18>

Wilson, A. (2007). *InSPECT: Significant Properties Report*. [Draft/Version: V2]

https://figshare.com/articles/journal_contribution/InSPECT_Significant_Properties_Report_WP2_2_/7137812

Wing, J.M. (2006). Computational Thinking. *Communication of the ACM*, 49 (3), 33-35.

<https://www.cs.cmu.edu/~15110-s13/Wing06-ct.pdf>

World Health Organization (2019). Guideline on data integrity. *WHO Drug Information*.

<https://apps.who.int/iris/handle/10665/330818>

Yeo, G. (2018). *Records, information and data: exploring the role of record-keeping in an information culture*. Facet Publishing.

Yeo, G. (2020). ¿Podemos mantenerlo todo? El futuro de la valoración en un mundo de profusión digital. *Tábula*, (23), 153-171

Zuiderwijk, A.; Janssen, M.; Davis, C. (2014). Innovation with open data: essential elements of open data ecosystems. *Information Polity*, 19, 17-33.

<https://doi.org/10.3233/IP-140329>

Abella, A.; Ortiz-de-Urbina-Criado, M.; De-Pablos-Herero, C. (s.d). *MELODA5 Evaluation form. Meloda a metric for data reusable*. Meloda.

<https://www.meloda.org/>

Banco Bilbao Vizcaya Argentaria (BBVA) (2016). *API REST: qué es y cuáles son sus ventajas en el desarrollo de proyectos*. BBVA API_Market.

<https://www.bbvaapimarket.com/es/mundo-api/api-rest-que-es-y-cuales-son-sus-ventajas-en-el-desarrollo-de-proyectos/>

Berners-Lee, T. (2010). *5 estrellas de Datos Abiertos*. 5stardata

<https://5stardata.info/es/>

Cabinet Office (2013). *Policy paper. G8 Open Data Charter and Technical Annex*. GOV.UK

<https://www.gov.uk/government/publications/open-data-charter/g8-open-data-charter-and-technical-annex>

Casellas, Ll. (2020, desembre 10). *Transformación digital: ¿a pelo o con sistema de gestión de documentos?* [Video]. YouTube.

<https://www.youtube.com/watch?v=WptlCz8kFoE>

Centre de Telecomunicacions i Tecnologies de la Informació (2021). *Gestió tècnica de dades*. Generalitat de Catalunya.

<https://canigo.ctti.gencat.cat/dadesref/gestiodades/>

Centre de Telecomunicacions i Tecnologies de la Informació (2021). *Dades de referència*. Generalitat de Catalunya.
<https://canigo.ctti.gencat.cat/dadesref/dadesref/>

Centre de Telecomunicacions i Tecnologies de la Informació (s.d). *Mètriques d'eficiència*. Solucions TI de la Generalitat de Catalunya.
<https://qualitat.solucions.gencat.cat/guies/metriques/eficiencia/>

Consorci Administració Oberta de Catalunya (Consorci AOC) (s.d). *Dades Obertes i reutilització de la informació*. Suport Govern Obert.
<https://suport-governobert.aoc.cat/hc/ca/articles/4412214503825-Dades-Obertes-i-reutilitzaci%25C3%25B3-de-la-informaci%25C3%25B3>

Diputació de Barcelona (s.d). *Estructura de les dades*. Portal de dades obertes de la Diputació de Barcelona.
<https://dadesobertes.diba.cat/dades-obertes/documentacio-tecnica/api/estructura-de-les-dades>

Eaves, D. (2009). *Las tres leyes de los datos abiertos*. Eaves.ca
<https://eaves.ca/2009/12/11/las-tres-leyes-de-los-datos-abiertos/>

Escola d'Administració Pública de Catalunya (2015). *Unitat 1. Què és la transparència?* Formació oberta EAPC.
https://formaciooberta.eapc.gencat.cat/contingutsdels-cursos/taip/010_quequicom/inici.html

Esteva, M. (2021, març 3). *Desde la teoría y la práctica tradicionales hacia la Archivística Computacional: Nuevos conceptos y enormes posibilidades para el avance de nuestra disciplina*. [Video]. YouTube.
<https://www.youtube.com/watch?v=1K8wf7E-IYo>

Fuente, O. (2018). *¿Qué es la Transformación Digital y cómo crear Digital Business?* Innovation & Entrepreneurship Business School.
<https://www.iebschool.com/blog/que-es-transformacion-digital-business/>

Generalitat de Catalunya (s.d). *Què són les Dades Obertes*. Portal de dades obertes de la Generalitat de Catalunya, Govern Obert.
https://governobert.gencat.cat/ca/dades_obertes/dades-obertes/que-son-dades-obertes/

Generalitat de Catalunya (s.d). *Informació per a desenvolupadors*. *Arquitectura tecnològica del servei de dades obertes de la Gencat*. Portal de dades obertes de la Generalitat de Catalunya, Govern Obert.
https://governobert.gencat.cat/ca/dades_obertes/reutilizacio-dades/informacio-desenvolupadors/

Govern Basc (2010). *Qué es RDF*. Open Data Euskadi.
https://opendata.euskadi.eus/contenidos/informacion/opendata_rdf_euskadi/es_info/adjuntos/RDF.pdf

IGI Global (s.d). *What is Distance Function*.
<https://www.igi-global.com/dictionary/distance-function/7998>

Instituto de Ingeniería del Conocimiento (IIC) (2016). *Las 7 V del Big data: Características más importantes*. Blog del IIC.
<https://www.iic.uam.es/innovacion/big-data-caracteristicas-mas-importantes-7-v/>

Instituto Nacional de Estadística (2021). *Relación de municipios y sus códigos por provincias*.
https://www.ine.es/dyngs/INEbase/es/operacion.htm?c=Estadistica_C&cid=1254736177031&menu=ultiDatos&idp=1254734710990

Logan, D. (2010). *What is information governance? And why is it so hard?* Gartner Blog Network.
https://blogs.gartner.com/debra_logan/2010/01/11/what-is-information-governance-and-why-is-it-so-hard/

McCandless, D. (2010). *The beauty of data visualization*. TED Global.
https://www.ted.com/talks/david_mccandless_the_beauty_of_data_visualization

Millar, L. (2021). *Extrayendo ladrillos del muro: Reconsiderando conceptos de archivística*. 18e Congrés d'Arxivística i Gestió de Documents de Catalunya.
<https://arxivers.cat/video/>

Mossos d'Esquadra (s.d). *Ajuda sobre Dades Obertes Mossos*. Generalitat de Catalunya.
https://mossos.gencat.cat/ca/els_mossos_desquadra/indicadors_i_qualitat/dades_obertes/Ajuda-Dades-obertes-Mossos/

Open Data Charter (s.d). *International Open Data charter*.
<https://opendatacharter.net/principles/>

Open Election Data Initiative (s.d). *Sección 2: Principios de los datos electorales abiertos*. Open Election Data.
<https://openelectiondata.net/es/guide/principles/granular/>

Open Knowledge Foundation. (s.d). *The Open Data Handbook (El manual de open data)*.
<https://opendatahandbook.org/>

Perpinyà, R. (2020). *Tema 8. Els valors dels documents d'arxiu*. Associació de professionals de l'arxivística i la gestió de documents.
<https://arxivers.com/mon-laboral/temari-oposicions/tema-8-els-valors-dels-document-darxiu/>

Pollock, R. (2011). *Building the (Open) Data Ecosystem*. Blog Open Knowledge Foundation.
<https://blog.okfn.org/2011/03/31/building-the-open-data-ecosystem/>

PowerData Solutions (2016). *¿Qué son los metadatos y cuál es su utilidad?* Blog PowerData.

<https://blog.powerdata.es/el-valor-de-la-gestion-de-datos/que-son-los-metadatos-y-cual-es-su-utilidad>

Serra, J. (2017). *Tendencias actuales en la gestión documental: la gestión documental orientada a datos.* SlideShare.

<https://es.slideshare.net/jordiserra/tendencias-actuales-en-la-gestin-documental-la-gestin-documental-orientada-a-datos>

Serra, J. (2020, juliol 21). *La gestión documental datificada. Retos profesionales en el contexto de la transformación digital* [Video]. YouTube.

https://www.youtube.com/watch?v=fr6oW_VHhKU

Speth, C. (2016). *El análisis Dafo.* 50Minutos.es.

<https://www.50minutos.es/libro/el-analisis-dafo/>

Soler, J. (2013). *Els riscos de la mala qualitat de les dades [1]*. Diplomática.cat.

<http://diplomaticapuntcat.blogspot.com/2013/08/els-riscos-de-la-mala-qualitat-de-les.html>

Soler, J. (2013). *Sobre la qualitat de les dades obertes.* Diplomática.cat

<http://diplomaticapuntcat.blogspot.com/2013/06/sobre-la-qualitat-de-les-dades-obertes.html>

Soler, J. (2014). *Periodisme de dades. L'arxivística de les dades.* Centre de Cultura Contemporània de Barcelona (CCCB).

<https://www.cccb.org/ca/multimedia/videos/periodisme-de-dades-larxivistica-de-les-dades/210777>

Soler, J. (2020). *Governança de dades, gestió documental o governança de la informació?* EAPC blog.

<https://eapc.blog.gencat.cat/2020/09/29/governanca-de-dades-gestio-documental-o-governanca-de-la-informacio-joan-soler-jimenez/>

Sunlight Foundation (s.d). *Ten principles for opening up government information.* Sunlight Foundation.

<https://sunlightfoundation.com/policy/documents/ten-open-data-principles/>

The Annotated 8 Principles of Open Government Data

(s.d). Open Government Data.

<https://opengovdata.org/>

The InterPARES Project (s.d). *IP Ontologies.* InterPARESTRUST.

http://www.interpares.org/ip2/display_file.cfm?doc=ip2_ontology.pdf

Universitat Oberta de Catalunya (s.d). *Què és i com utilitzar el RSS?* Biblioteca UOC.

<http://biblioteca.uoc.edu/ca/com-funciona/faqs/com-es-fa-servir-lrss>

World Wide Web Foundation (2017). *The Open Data Barometer*.
https://opendatabarometer.org/?_year=2017&indicator=ODB

Legislació

Europea

Directiva (UE) 2007/2/CE del Parlamento Europeu i del Consell, de 14 de març de 2007, per la qual s'estableix una infraestructura d'informació espacial a la Comunitat Europea (Inspire), DOUE núm.108 § 80587 (2007).
<https://www.boe.es/buscar/doc.php?id=DOUE-L-2007-80587>

Reglament (CE) 1205/2008 de la Comissió, de 3 de desembre de 2008, pel qual s'executa la Directiva 2007/2/CE del Parlament Europeu i del Consell en el que es refereix a les metadades, DOUE núm. 326 § 1205 (2008).
<https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=CELEX%3A32008R1205>

Directiva (UE) 2016/2102 del Parlament Europeu i del Consell, de 26 d'octubre de 2016, relatiu a l'accessibilitat dels llocs web i aplicacions per a dispositius mòbils dels organismes del sector públic, DOUE núm.327 § 2102 (2016).
<https://eur-lex.europa.eu/legal-content/es/ALL/?uri=CELEX:32016L2102>

Reglament (UE) 2016/679 del Parlament Europeu i del Consell, de 27 d'abril de 2016, relatiu a la protecció de les persones físiques pel que fa al tractament de dades personals i a la lliure circulació d'aquestes dades i pel qual es deroga la Directiva 95/46/CE (Reglament general de protecció de dades), DOUE núm.119 § 679 (2016).
<https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=celex%3A32016R0679>

Directiva (UE) 2019/1024 del Parlament Europeu i del Consell, de 20 de juny de 2019, relativa a les dades obertes i la reutilització de la informació del sector públic, DOUE núm.172 § 1024 (2019).
<https://eur-lex.europa.eu/legal-content/ES/ALL/?uri=CELEX%3A32019L1024>

Estatal

Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic, BOE núm. 276 § 19814 (2007).
<https://www.boe.es/buscar/doc.php?id=BOE-A-2007-19814>

Reial decret 1720/2007, de 21 de desembre, de protecció de dades de caràcter personal, BOE núm. 17 § 979 (2008) [Aplicable en allò que no s'oposi al Reglament (UE) 2016/679]
<https://www.boe.es/buscar/act.php?id=BOE-A-2008-979>

Reial Decret 3/2010, de 8 de gener, pel qual es regula l'Esquema Nacional de Seguretat en l'àmbit de l'Administració electrònica, BOE núm. 25 § 1330 (2010).

<https://www.boe.es/buscar/act.php?id=BOE-A-2010-1330>

Reial Decret 4/2010, de 8 de gener, pel qual es regula l'Esquema Nacional d'Interoperabilitat en l'àmbit de l'Administració electrònica, BOE núm. 25 § 1331 (2010).

<https://www.boe.es/buscar/act.php?id=BOE-A-2010-1331>

Reial Decret 1495/2011, de 24 d'octubre, pel qual es desenvolupa la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic, per a l'àmbit del sector públic estatal, BOE núm. 269 § 17560 (2011).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2011-17560>

Resolució de 19 de juliol de 2011, de la Secretaria d'Estat per a la Funció Pública, per la que s'aprova la Norma Tècnica d'Interoperabilitat de requisits de connexió a la xarxa de comunicacions de les Administracions Públiques espanyoles, BOE núm. 182 § 13173 (2011).

<https://www.boe.es/buscar/act.php?id=BOE-A-2011-13173>

Resolució de 28 de juny de 2012, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Relació de models de dades, BOE núm. 178 § 10050 (2012).

<https://www.boe.es/buscar/act.php?id=BOE-A-2012-10050>

Resolució de 28 de juny de 2012, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Protocols d'intermediació de dades, BOE núm. 178 § 10049 (2012).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2012-10049>

Resolució de 3 d'octubre de 2012, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Catàleg d'estàndards, BOE núm. 262 § 13501 (2012).

<https://www.boe.es/buscar/act.php?id=BOE-A-2012-13501>

Resolució de 28 de juny de 2012, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Política de gestió de documents electrònics, BOE núm. 178 § 10048 (2012).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2012-10048>

Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos de la informació, BOE núm. 54 § 2380 (2013).

https://www.boe.es/diario_boe/txt.php?id=BOE-A-2013-2380

Correcció d'errors de la Resolució de 19 de febrer de 2013, de la Secretaria d'Estat d'Administracions Públiques, per la que s'aprova la Norma Tècnica d'Interoperabilitat de Reutilització de recursos de la informació, BOE núm. 132 § 5858 (2013).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2013-5858>

Llei 19/2013, de 9 de desembre, de transparència, accés a la informació pública i bon govern, BOE núm. 295 § 12887 (2013).

<https://www.boe.es/buscar/act.php?id=BOE-A-2013-12887>

Llei 40/2015, d'1 d'octubre, de Règim Jurídic del Sector Públic, BOE núm. 236 § 10566 (2015).

<https://www.boe.es/buscar/act.php?id=BOE-A-2015-10566>

Llei 39/2015, d'1 d'octubre, del procediment administratiu comú de les administracions públiques, BOE núm. 236 § 10565 (2015).

<https://www.boe.es/buscar/act.php?id=BOE-A-2015-10565>

Llei 18/2015, de 9 de juliol, per la qual es modifica la Llei 37/2007, de 16 de novembre, sobre reutilització de la informació del sector públic, BOE núm. 164 § 7731 (2015).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2015-7731>

Reial Decret 1112/2018, de 7 de setembre, sobre accessibilitat dels llocs web i aplicacions per a dispositius mòbils del sector públic, BOE núm. 227 § 12699 (2018).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2018-12699>

Llei Orgànica 3/2018, de 5 de desembre, de Protecció de Dades Personals i garantia dels drets digitals, BOE núm. 294 § 16673 (2018).

<https://www.boe.es/buscar/doc.php?id=BOE-A-2018-16673>

Autonòmica

Decret 320/2011, de 19 d'abril, de reestructuració del Departament d'Interior, DOGC núm. 5864 (2011).

<https://portaljuridic.gencat.cat/eli/es-ct/d/2011/04/19/320>

Llei 19/2014, del 29 de desembre, de transparència, accés a la informació pública i bon govern, DOGC núm. 6780 (2014).

<https://portaljuridic.gencat.cat/eli/es-ct/l/2014/12/29/19>

Decret 76/2020, de 4 d'agost, d'Administració digital, DOGC núm. 8195 (2020).

<https://portaljuridic.gencat.cat/eli/es-ct/d/2020/08/04/76>

Acord GOV/6/2021, de 19 de gener, pel qual es crea el Comitè Ètic de les Dades, DOGC núm. 8322 (2021).

<https://cido.diba.cat/legislacio/11185868/acord-gov62021-de-19-de-gener-pel-qual-es-crea-el-comite-detica-de-les-dades-departament-de-politiques-digitals-i-administracio-publica>

Decret 8/2021, de 9 de febrer, sobre la transparència i el dret d'accés a la informació pública, DOGC núm. 8339 (2021).

<https://portaljuridic.gencat.cat/eli/es-ct/d/2021/02/09/8>

Resolució PRE/2023/2021, de 29 de juny, per la qual es dona conformitat al canvi de nom del municipi de Bigues i Riells, que passa a denominar-se Bigues i Riells del Fai, DOGC núm. 8448 (2021).

<https://cido.diba.cat/legislacio/11963360/resolucio-pre20232021-de-29-de-juny-per-la-qual-es-dona-conformitat-al-canvi-de-nom-del-municipi-de-bigues-i-riells-que-passa-a-denominar-se-bigues-i-riells-del-fai-de-partament-de-la-presidencia>

Annex. Taula resum dels criteris de mesura

Dimensió ODQ	Element ODQ	Forma de càlcul	Puntuació màxima	Font
Autenticitat	Definició / Documentació	A escollir segons nivell	3 punts	Adaptació norma UNE 178301:2015
	Conformitat	<p>Tres fórmules segons nivell: Conformitat % = (Nombre de valors vàlids a nivell de dades en el dataset, s'exclouen els valors perduts x 100) / Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts. Conformitat del registre % = (Nombre de registres o files vàlides en el dataset x 100) / Nombre total de registres o files en el dataset. Conformitat de les metadades % = (Nombre de metadades vàlides x 100) / Nombre total de metadades</p>	<p>Percentual (100%) Suma de tots els nivells = 300%</p>	<p>Mahanti (2018) La mesura de conformitat de les metadades és d'elaboració pròpia (2021), a partir de Mahanti (2018)</p>
	Credibilitat	$(A + B + C + D) / 4$	1 punt	Elaboració pròpia (2021) a partir de diverses fonts (Open Data Support, 2014; ISO/IEC 25012:2008; Mahanti, 2018)
Fiabilitat	Primigènia	A escollir segons nivell	3 punts	Adaptació norma UNE 178301:2015
	Exactitud	<p>Dues fórmules segons nivell: Exactitud % = (Nombre de valors exactes a nivell de dades en el dataset, s'exclouen els valors perduts x 100) / Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts. Exactitud del registre % = (Nombre de valors exactes a nivell de dades en el dataset, s'exclouen els valors perduts x 100) / Nombre de valors a nivell de dades en el dataset, s'exclouen els valors perduts.</p>	<p>Percentual (100%) Suma de tots els nivells = 200%</p>	Mahanti (2018)
	Precisió	Aplicació de les regles per a determinar el número de xifres significatives i també de les regles d'operació de les xifres significatives. Posteriorment aplicació de les regles d'arrodoniment.	1 punt	Elaboració pròpia (2021)

Dimensió ODQ	Element ODQ	Forma de càlcul	Puntuació màxima	Font
Fiabilitat	Granularitat	$(A + B + C) / 3$	1 punt	Elaboració pròpia (2021)
	Rellevància	<p>Dues fórmules per un mateix nivell: Cobertura de les dades % = $(\text{Nombre de registres de la població actual definits per l'abast} \times 100) / (\text{Nombre de registres estimats no disponibles de la població d'interès} + \text{Nombre de registres de la població actual definits per l'abast})$.</p> <p>Rellevància de les dades % = $(\text{Nombre d'elements de dades rellevants} / \text{Nombre total d'elements de dades necessaris per a la finalitat prevista}) \times 100$</p>	Percentual (100%)	Mahanti (2018)
Integritat	Traçabilitat	$(A + B + C + D + E + F) / 6$	1 punt	Mahanti (2018), més ampliació amb paràmetres d'elaboració pròpia (2021)
	Completesa	<p>Quatre fórmules segons nivell: Completesa % = $((\text{Nombre total de valors que s'han de completar per a cada dada} - \text{Nombre total de valors nuls} - \text{Nombre total d'espais} - \text{Nombre total de valors en blanc}) / \text{Nombre total de valors que s'han de completar per a cada dada}) \times 100$</p> <p>Completesa del registre % = $(\text{Nombre de registres que contenen valors crítics no perduts} \times 100) / \text{Nombre total de registres que contenen valors crítics}$.</p> <p>Completesa del dataset % = $(\text{Nombre de registres presents en el dataset} \times 100) / \text{Nombre de registres del dataset de referència}$.</p> <p>Completesa de les metadades = $(\text{Nombre de metadades obligatòries que s'informen} \times 100) / \text{Nombre total de metadades obligatòries a informar}$</p>	<p>Percentual (100%) Suma de tots els nivells = 400%</p>	<p>Mahanti (2018) La mesura de completesa de les metadades és d'elaboració pròpia (2021), a partir de Mahanti (2018)</p>

Dimensió ODQ	Element ODQ	Forma de càlcul	Puntuació màxima	Font
Integritat	Consistència	<p>Quatre fórmules segons nivell:</p> <p>Consistència % = (Nombre de valors combinats i consistents en un mateix dataset x 100) / Nombre total de valors combinats en un mateix dataset.</p> <p>Consistència del registre % = (Nombre de registres consistents en el dataset x 100) / Nombre total de registres en el dataset.</p> <p>Consistència de registres creuats % = (Nombre de registres consistents en el dataset x 100) / (Nombre de registres consistents en el dataset + Nombre de registres inconsistents en el dataset).</p> <p>Inconsistència del dataset % = Valor absolut de ((Nombre de registres a la font d'origen - Nombre de registres en el sistema de destinació - Nombre de registres rebutjats) x 100) / Nombre de registres a la font d'origen.</p>	<p>Percentual (100%)</p> <p>Suma de tots els nivells = 400%</p>	Mahanti (2018)
		Llegibilitat / Interpretabilitat	$(A + B + C + D + E) / 5$	1 punt
Usabilitat	Comprensibilitat	$(A + B + C) / 3$	1 punt	Elaboració pròpia (2021)
	Georeferenciació	A escollir segons nivell	3 punts	Adaptació norma UNE 178301:2015
	Obertura	Esquema cinc estrelles	5 punts	Berners-Lee (2010)
	Recuperabilitat	A/B	1 punt	ISO/IEC 25012:2008
	Localització	$(A + B + C + D) / 4$	1 punt	Elaboració pròpia (2021) a partir dels ítems proposats per Wilkinson <i>et al.</i> (2016) en relació als principis FAIR.

Dimensió ODQ	Element ODQ	Forma de càlcul	Puntuació màxima	Font
Usabilitat	Eficiència	A escollir en funció dels segons de transacció. Després, aplicació de fórmula per a calcular mitjana del nombre de peticions: $(N_1 + N_2 + \dots + N_n) / \text{nombre de peticions}$	5 punts	Centre de Telecomunicacions i Tecnologies de la Informació (CTTI)
	Comparabilitat	$(A + B + C + D + E) / 5$	1 punt	Elaboració pròpia (2021) a partir de diverses fonts (Carta Internacional de Dades Obertes, 2015; Núria Espuny, 2020)
Disponibilitat	Pertinència temporal	$\{\text{màx.} [(1 - (\text{actualitat} / \text{volatilitat}))], 0\}$ Posteriorment, aplicació pregunta amb resposta tipus booleà.	1 punt	Ballou, Wang, Pazer & Tayi (1998)
	Actualitat	Pregunta amb resposta tipus booleà a partir de l'anàlisi de les metadades "data última actualització" i "freqüència d'actualització".	1 punt	Elaboració pròpia (2021)
	Volatilitat	A escollir segons nivell	4 punts	Elaboració pròpia (2021)
	Accessibilitat	$(A + B + C + D + E) / 5$	1 punt	Elaboració pròpia (2021) a partir d'aspectes extrets de la normativa d'aplicació (RD 1112/2018; UNE 178301:2015; WCAG 2.1 del W3C, etc.).
	Reutilització	Meloda 5	61 punts	Abella, Ortiz-de-Urbina & De-Pablos-Heredero (2019). Pàgina web de meloda: https://www.meloda.org/
	Seguretat / Privacitat	Qüestionari	45 punts	Elaboració pròpia (2021) a partir d'aspectes extrets de la normativa d'aplicació (ENS) i de Ruiz & Soler (Coord.) (2016)
	Portabilitat	$(A + B + C + D + E + F + G + H + I + J + K) / 11$	1 punt	Elaboració pròpia (2021) a partir d'aspectes extrets de la normativa d'aplicació (ENI, NTIs, guia d'auditoria del compliment de l'ENI i guia d'adequació a l'ENI)

Taula 18. Resum dels criteris de mesura dels elements ODQ. (Font: Elaboració pròpia, 2021).

Acrònims i abreviatures

270



API: *Application Programming Interface* (Interfície de Programació d'Aplicacions).

DCAT: *Data Catalog Vocabulary* (Vocabulari de Catàleg de Dades).

DCAT-AP: *Data Catalog Vocabulary Application Profile* (Perfil d'aplicació del Vocabulari de Catàleg de Dades o Perfil d'aplicació del Vocabulari de catàleg de Dades per a portals de dades europeus).

DQ: *Data Quality* (Qualitat de dades).

ENI: Esquema Nacional d'Interoperabilitat.

ENS: Esquema Nacional de Seguretat.

FAIR: *Findable, Accessible, Interoperable, Reusable* (Localitzables, accessibles, interoperables, reutilitzables).

ISO: *International Organization for Standardization*.

JSON: *JavaScript Object Framework* (Format lleuger per a l'intercanvi de dades).

N3: Notation3.

NTI: Norma Tècnica d'Interoperabilitat.

NTI-RISP: Norma Tècnica d'Interoperabilitat de Reutilització de recursos d'informació.

ODQ: *Open Data Quality* (Qualitat de dades obertes).

RDF: *Resource Description Framework* (Infraestructura de Descripció de Recursos).

RISP: Reutilització de la informació del sector públic.

Turtle: *Terse RDF Triple Language*.

UNE: Una Norma Espanyola.

URI: *Uniform Resource Identifier* (Identificador de Recurs Uniforme).

URL: *Uniform Resource Locator* (Localitzador de Recurs Uniforme).

WAI: *Web Accessibility Initiative* (Iniciativa per a l'Accessibilitat Web).

W3C: *World Wide Web Consortium* (Consorti World Wide Web).

XML: *eXtensible Markup Language* (Llenguatge de marques extensible).

Taula 1. Beneficis de l'obertura de dades obertes. (Font: Elaboració pròpia, 2021).....36

Taula 2. Barreres de l'obertura de dades obertes. (Font: Elaboració pròpia, 2021).....40

Taula 3. Avantatges de la vinculació entre SGD i polítiques de dades obertes. (Font: Elaboració pròpia, 2021).....48

Taula 4. Diferències entre sistemes oberts i tancats en relació a l'equifinalitat i l'entropia (Font: Elaboració pròpia, 2021. A partir de Bertalanffy, 1968, reimpr. 1989; Thomas, 1993; Arnold & Osorio, 2008).....54

Taula 5. Característiques de l'ecosistema de dades obertes. (Font: Elaboració pròpia, 2021).....60

Taula 6. Comparativa de les característiques de qualitat de les dades i dels components del document (Font: Elaboració pròpia, 2021).....88

Taula 7. Equiparació de dimensions de qualitat de l'anglès al català (Font: Elaboració pròpia, 2021).....91

Taula 8. Comparativa de la literatura analitzada en relació amb les dimensions de qualitat de les dades (Font: Elaboració pròpia, 2021).....93

Taula 9. Dimensions que es citen en les normes ISO 15489 i 30300 (Font: Elaboració pròpia, 2021).....96

Taula 10. Dimensions que es citen en els estudis de Bovee, Srivastava & Mak (2003) i Cai & Zhu (2015) (Font: Elaboració pròpia, 2021).....97

Taula 11. Elements ODQ del Model de qualitat de les dades obertes (Font: Elaboració pròpia, 2021).....99

Taula 12. Vocabulari DCAT aplicat a recursos d'informació (Font: Elaboració pròpia, 2021. A partir de la NTI-RISP, 2013).....120

Taula 13. Vocabulari estàndard de dades obertes de la Generalitat de Catalunya (Font: Elaboració pròpia, 2021. A partir de la Generalitat de Catalunya, 2020).....123

Taula 14. Pes de cada mètrica (Font: Elaboració pròpia, 2021).....189

Taula 15. Correspondència entre valor total i nivells de qualitat open data (Font: Elaboració pròpia, 2021).....190

Taula 16. Resultats del procés de mesurament en les dues mostres seleccionades. (Font: Elaboració pròpia, 2021).....235

Taula 17. Correspondència entre els valors totals i el nivell ODQ. (Font: Elaboració pròpia, 2021).....237

Taula 18. Resum dels criteris de mesura dels elements ODQ. (Font: Elaboració pròpia, 2021).....266

Figura 1. Camps d'estudi de la investigació. (Font: Elaboració pròpia, 2021).....10

Figura 2. Cicle PDCA aplicat a la investigació. (Font: Elaboració pròpia, 2021).....12

Figura 3. Símil de la cèl·lula (Font: Adaptació a partir de Joan Soler, 2014 i 2020).....17

Figura 4. Conceptes relacionats amb el document (Font: Adaptació a partir de la norma UNE-ISO 30300:2021).....18

Figura 5. Les tres lleis de les dades obertes (Font: Elaboració pròpia, 2021. A partir de David Eaves, 2009).....24

Figura 6. Els tres pilars del govern obert o open government (Font: Adaptació a partir de la Comissió Europea, 2013).....26

Figura 7. Els 10 principis rectors de les dades obertes (Font: Elaboració pròpia, 2021).....32

Figura 8. Els 8 principis de les dades obertes a l'ordenament jurídic espanyol (Font: Elaboració pròpia, 2021).....34

Figura 9. Representació de la interacció (Font: Adaptació a partir de Thomas, 1993).....52

Figura 10. Conjunt d'equacions que representen un sistema (Font: Bertalanffy, 1968, reimpr. 1989, 56).....52

Figura 11. Funcionament d'un sistema cibernètic (Font: Elaboració pròpia, 2021. A partir de la Encyclopaedia Britannica, 1996; Acosta, 2000; Lollai, 2017).....56

Figura 12. Perspectives conceptuals de la qualitat (Font: Elaboració pròpia, 2021. Adaptació realitzada a partir de Moreno-Luzón, Peris & González, 2001).....66

Figura 13. Principis de la qualitat de les dades amb perspectiva sistèmica (Font: Elaboració pròpia, 2021).....70

Figura 14. El marc de referència de gestió de dades DAMA DM-BOK2. La Roda DAMA (Font: DAMA International, 2017).....74

Figura 15. Relació entre el cicle TDQM i el cicle PDCA (Font: Elaboració pròpia, 2021).....76

Figura 16. Estructura dels processos i sub-processos de la gestió de la qualitat de les dades (Font: Adaptació a partir de la norma ISO 8000-61:2016).....78

- Figura 17.** Diagrama de context de la gestió de la qualitat de les dades (Font: DAMA International, 2009).....79
- Figura 18.** Els tres mons: el real, el conceptual i el de les representacions (Font: Rafael Camps, 2013).....81
- Figura 19.** Configuració del model ODQ (Font: Elaboració pròpia, 2021).....85
- Figura 20.** Elements que conformen una base de dades relacional (Font: Adaptació a partir de Batini & Scannapieco, 2016).....86
- Figura 21.** Marc de referència de la qualitat de les dades obertes (Font: Elaboració pròpia, 2021).....87
- Figura 22.** Ontologia de la qualitat de les dades obertes (ODQ) (Font: Elaboració pròpia, 2021).....118
- Figura 23.** Dataset Codis postal per municipis de Catalunya. (Font: Elaboració pròpia, 2021).....195
- Figura 24.** Conjunt de dades Codis postal per municipis de Catalunya en format RDF-XML. (Font: Portal dades obertes de la Generalitat de Catalunya, 2021).....207
- Figura 25.** Missatge d'error a l'enllaçar en un URI de registre. (Font: Portal dades obertes de la Generalitat de Catalunya, 2021).....207
- Figura 26.** Dataset Comissaries en format SON. (Font: Portal dades obertes dels Mossos d'Esquadra, 2021).....227
- Figura 27.** Comparativa entre els valors totals. (Font: Elaboració pròpia, 2021).....237
- Figura 28.** Matriu DAFO inicial: abans de la incorporació de millores. (Font: Elaboració pròpia, 2021).....239
- Figura 29.** Matriu DAFO final: després de la incorporació de millores. (Font: Elaboració pròpia, 2021).....240

Publicació conjunta



Associació de Professionals
de l'Arxivística i la Gestió de
Documents de Catalunya

**Arxivística
i Gestió
de Documents**
Escola FUAB
Formació



Aquesta obra està subjecta a llicència Creative Commons Reconeixement-NoComercial-SenseObraDerivada 3.0 Espanya (<http://creativecommons.org/licenses/by-nc-nd/3.0/es/legalcode.ca>). Es permet la reproducció total o parcial i la comunicació pública de l'obra, sempre que no sigui amb finalitats comercials, i sempre que es reconegui l'autoria de l'obra original. No es permet la creació d'obres derivades.