

11

textos

Associació de Professionals
de l'Arxivística i la Gestió
de Documents de Catalunya

Directrius per
al tractament de
conjunts de dades
als arxius

Edita: Associació de professionals de l'arxivística
i la gestió de documents de Catalunya (AAC)

© del text: Pilar Campos Martínez

© de l'edició: AAC

Maig 2022

DL:B 11471-2022

textos 11

Directrius per al tractament de conjunts de dades als arxius

Pilar Campos Martínez



Associació de Professionals de l'Arxivística
i la Gestió de Documents de Catalunya

PRÒLEG

Francesc Giménez Martín

President de l'Associació de Professionals de l'Arxivística
i la Gestió de Documents de Catalunya (AAC)

Ara fa just deu anys que es va publicar el número 10 de *Textos*. Des d'aleshores, l'Associació de Professionals de l'Arxivística i la Gestió de Documents de Catalunya (AAC) no havia publicat cap altre número d'aquesta col·lecció. Deu anys són suficients per reflexionar sobre el seu valor. I així ho hem fet. La nostra proposta és, com es fa evident, reprendre de nou aquesta publicació. L'AAC ja compta amb un corpus de publicacions consolidat, amb la revista *Lligall* com a publicació científica periòdica per excel·lència, pensada clarament per recollir els principals debats i aportacions sobre la teoria i la pràctica arxivística del país. D'altra banda, disposa des de fa quatre anys de *La DaDa*, un diari digital en obert, que vol ser un mitjà de comunicació de temes d'interès per als i les professionals del sector, però també per a altres públics no experts. És, per tant, evident que hi havia un espai buit, el que ocupava *Textos* com a col·lecció pràctica, com a espai per al desenvolupament d'eines en qüestions d'interès per al col·lectiu arxivístic. L'AAC és conscient d'aquesta vacant en el corpus de les seves publicacions, així com de l'existència del tot necessària de publicacions que cerquin el vessant més pràctic del que en podríem dir la recerca aplicada. I en això, en la recerca elaborada fora de l'entorn i els mecanismes acadèmics, l'AAC és justament on es postula com a ens actor, com a transmissora de coneixement, sempre des d'un vessant pràctic i aplicable pels i les professionals. La participació de l'Associació en fòrums i projectes arxivístics internacionals té sentit potenciar-la si aquest coneixement pot revertir directament en productes que traslladin aquest saber al seu corpus associatiu. I la col·lecció *Textos* justament compleix aquest fi. Aquesta col·lecció ja es va concebre amb aquesta idea, com en són un exemple una bona part dels deu números publicats, i creiem que ha de continuar exercint aquesta funció catalitzadora i conductora de coneixement.

Obrim, doncs, aquest any de nou, la porta d'aquesta publicació. I ho fem amb un projecte formidable presentat per l'arxivera María Pilar Campos Martínez, una proposta d'actualitat candent vinculada a la implicació necessària en la gestió de les dades que la nostra professió ja no pot obviar. Les dades i el nostre

paper en el seu entorn de gestió és una realitat i ens calen eines metodològiques i conceptuals per guiar-nos en com es pot aplicar el nostre coneixement expert a la informació que es transmetrà als nostres sistemes i com se la pot validar amb criteris de qualitat. Com a responsables d'aquest univers informacional, hi hem d'estar preparats. I dins d'aquest entorn, saber com s'han de gestionar amb criteris de qualitat els conjunts de dades (*datasets*) és possiblement el pas inicial més fonamental. La guia que teniu al davant vol justament assentar alguns conceptes bàsics entorn d'aquest concepte, analitzar possibles errors d'ingesta per tal d'evitar-los i, finalment, proposar una eina per a la comprovació de la qualitat prèvia a la transferència a l'arxiu. Un viatge complet per ser capaç de sentir-se segur en la gestió d'aquests actius i en la responsabilitat de la seva preservació.


No podem estar més segurs de l'encaix d'aquest número en la filosofia de praxicitat que impregna l'essència de *Textos*. I no podem estar més convençuts que una eina com aquesta ha de poder facilitar la gestió d'aquests conjunts informatius per la comunitat arxivera. Avui fem renèixer *Textos* i el posicionem en l'entorn de les dades, en un entorn que requereix eines pràctiques per facilitar la gestió i la comprensió del seu ús i les seves implicacions dins el sistema organitzatiu. Avui ens sentim satisfetes de poder-vos oferir aquest reinici, i poder-ho fer a més amb aquest magnífic estudi. Esperem obrir amb aquest text, i d'una manera immillorable, una etapa de continuïtat que serveixi per transferir coneixement i enriquir el col·lectiu amb noves eines pràctiques de recerca.

Finalment, no volíem acabar aquesta introducció al sòlid estudi de María Pilar Campos sense agrair a l'arxiver Sergi Sorribas Bonel la seva col·laboració en l'estructura inicial del treball, així com als membres de la Junta totes les aportacions que hi han fet i, igualment, al Dr. Eloi Puertas Prats la revisió final.



**Directrius per
al tractament
de conjunts de
dades als arxius**

textos **11**



Índex

Presentació	11
--------------------	-----------

Conceptes previs	11
-------------------------	-----------

Conjunts de dades als arxius	13
-------------------------------------	-----------

- Introducció 13
- Origen i usos 13
- Formats 14
- Classificació i descripció 16
- Interoperabilitat 17

Qualitat dels conjunts de dades	18
--	-----------

- Introducció 18
- Comprovacions de la qualitat 18
- Validesa 20
- Exactitud 22
- Integritat 23
- Consistència 25
- Uniformitat 26

Qualitat del contingut de les dades	27
--	-----------

Conclusions	28
--------------------	-----------

Bibliografia	29
---------------------	-----------



Presentació

La generació de dades a les institucions en la gestió diària i l'anàlisi i l'explotació de les dades per a la presa de decisions avui en dia és una realitat. A més, en el cas de les administracions públiques i les empreses és una obligació per al retiment de comptes amb la ciutadania, amb els clients o amb els inversors. Aquest increment en la creació i la recollida de dades fa que els arxius hagin de preveure i planificar com cal fer la ingesta d'aquests conjunts de dades. La dependència que sovint hi ha de sistemes d'informació, i també la diversitat de formats i productors, en dificulta la captura i el control de la qualitat.

Documentar els conjunts de dades o *datasets* és una preocupació cada vegada més gran en la comunitat científica i industrial que ha d'explotar les dades a les quals té accés. Hi ha diverses iniciatives per a la creació d'una estandardització de quina és la informació hauria d'acompanyar els conjunts de dades (Gebru *et al.*, 2020). I és que aquestes metadades podrien ser difícils de registrar en els arxius si en el moment de la ingesta no s'han tingut en compte uns criteris determinats.

L'objectiu d'aquesta publicació és establir alguns conceptes bàsics sobre la gestió de conjunts de dades als arxius, analitzar els possibles errors en la ingesta de dades i proposar una eina per a la comprovació de la qualitat de les dades prèvia a la transferència a l'arxiu.

Conceptes previs

En aquest text s'utilitzen els termes següents amb el significat que s'indica. En alguns casos, per tal d'evitar errors, s'han separat termes que són pràcticament sinònims de *dada* però que tenen un matís diferenciat.

base de dades (angl. *database*). 1. Col·lecció de dades amb una estructura per ingerir, emmagatzemar, proveir o demanar dades per múltiples usuaris. 2. Col·lecció de dades interrelacionades organitzades segons un esquema de bases de dades per donar servei a una o més aplicacions. (Butterfield *et al.*, 2016)

dades (angl. *data*): Representació interpretable d'informació de manera adequada per a la comunicació, la interpretació o el processament. (ISO/IEC, 1993).

dada (angl. *data item*): Ítem que es considera indivisible en un context concret. És una unitat de dades per a la qual la definició, la identificació, la representació i els valors permesos s'especifiquen mitjançant un conjunt d'atributs (metadades). (ISO/IEC, 1994)
dataset o conjunt de dades: Conjunt estructurat de dades creades per a un propòsit específic. Els conjunts de dades es poden emmagatzemar, administrar i publicar en una varietat de formats i tecnologies. (The National Archives, 2011) La diferència amb la base de dades és que la primera inclou lògiques internes d'execució, explotació, cerca i interrelació de dades que no hi ha en el *dataset*; sovint, els *datasets* són taules exportades de la base de dades.

diccionari de dades (angl. *data dictionary*): Repositori centralitzat d'informació sobre dades com ara el significat, les relacions amb altres dades, l'origen, l'ús i el format. Dona suport a la gestió, als administradors de bases de dades, als analistes de sistemes, als programadors d'aplicació i a la planificació, el control, l'avaluació, l'emmagatzemament i l'ús de les dades. (IBM, 2001).

dades enllaçades (angl. *linked data*): Solució tecnològica que ofereix un conjunt de bones pràctiques per a la publicació de dades i la seva interconnexió, fent possible la interoperabilitat i la reutilització de la informació disponible al web. (Bizer *et al.*, 2009) (Quílez, 2017).

Conjunts de dades en els arxius

Introducció

En els arxius històricament s'ha treballat per intentar normalitzar i codificar la documentació que hi havia en llenguatge natural per fer-ne agrupacions amb descriptors, classificacions i punts d'accés que facilitessin la recuperació de la informació. Així, les guies, els inventaris i els catàlegs han esdevingut les eines amb les quals s'ha treballat amb l'objectiu d'organitzar els fons i donar-hi accés. Aquesta estructura passa del món analògic al món digital mitjançant la creació de bases de dades i, en termes d'explotació de dades, l'estructuració de les taules i de les consultes per extreure aquests *datasets* dels fons. Una vegada estan en format de dades estructurades, es pot valorar la possibilitat d'oferir les descripcions i les eines arxivístiques com un nou producte d'arxiu o posicionar-les a portals de dades obertes, com ja es fa amb les taules dels quadres de classificació.

De la mateixa manera que els arxius evolucionen, també ho fan les oficines i els processos de negoci, que cada vegada treballen més amb aplicacions i amb dades que, quan ha transcorregut un quant temps, és possible que sigui necessari passar a l'arxiu.

Origen i usos

Els orígens dels conjunts de dades poden ser múltiples, tants com ho són els orígens dels documents. En els sistemes de gestió documental la procedència habitual és l'activitat de la mateixa organització que genera les dades com a fruit de les seves funcions. Per tant, la captació d'aquests conjunts per part de l'arxiu s'hauria de fer de manera natural, sigui una transferència que tingui com a objectiu la conservació permanent o relacionada amb la continuïtat del negoci (The National Archives, 2011), però aquesta situació encara no és habitual.

Actualment als arxius electrònics ja arriben, a part de documents textuais (habitualment en format PDF o editables, procedents de processadors de textos) documents estructurats en format XML o JSON. Aquests documents poden ser el resultat de formalitzar un registre de la base de dades o un document en

un format concret o un expedient. Per exemple, el resultat d'una consulta via el portal de transparència o l'evidència de la notificació.

Una situació cada vegada més habitual és la transferència periòdica d'extraccions de bases de dades (per exemple, els registres d'entrada anuals); o, en el moment d'una migració d'un programari o d'actualitzacions, la transferència a l'arxiu dels conjunts de dades obsoletes que no es considera rellevant tenir en el nou entorn pel fet de ser de tramitacions finalitzades.

Altres orígens poden ser donacions de fons personals o privats, que cada vegada seran més digitals i que poden tenir associades bases de dades pròpies o dels programes que utilitzaven, com, per exemple, el fons històric de publicacions d'una xarxa social o la comptabilitat d'una empresa sobre un determinat programa.

L'ús dels conjunts de dades és divers i, en ser més fàcilment explotable que els fons documentals analògics o en llenguatge natural, no ha quedat restringit a la recerca històrica. Per exemple, els professionals de l'anàlisi de dades hi treballen directament per tal de fer la identificació de patrons, extrapolacions i donar suport a la presa de decisions. A més, pel que fa a la ciutadania, és una eina directa de rendició de comptes per les administracions.

L'arxiu ha de poder facilitar aquestes dades i a més d'assegurar-ne la integritat i l'autenticitat i n'ha de poder explicar el significat i el context de creació per tal d'evitar errors en la interpretació i, per tant, en les conclusions que mostrin.

Formats

Segons l'origen de les dades i les necessitats del creador dels *datasets*, les dades es poden trobar en diversos formats. Establir la política de formats, decidir si se'n fa la migració i analitzar els riscos d'aquesta migració és responsabilitat de l'arxiu.

Un dels formats que es fa servir més extensivament per representar dades és el full de càlcul organitzat en files i columnes (amb extensions com *xls*, *xlsx*, *xltx*, *ods*, *ots* o *csv*). Les columnes poden estar separades per tabuladors, comes o altres caràcters i les files habitualment estan separades per caràcters de línia nova.

Pel que fa als models de dades obertes, normalment es fan servir documents en formats oberts i etiquetats. Són habituals els formats següents:

FORMAT	DESCRIPCIÓ
XML	Format obert que permet representar les dades de manera estructurada i jeràrquica mitjançant etiquetes.
JSON	Format d'intercanvi de dades entre aplicacions informàtiques basat en la notació d'objectes usada pel llenguatge de programació JavaScript.
RDF/XML	Format que permet estructurar les dades en tripletes, en la forma subjecte-atribut-valor, que fa possible incorporar informació semàntica a les dades.
RSS	Format del llenguatge XML que permet la distribució de continguts de pàgines web.
KML/KMZ	Format que és una notació específica d'XML per a la representació de dades geogràfiques. Els fitxers KML o KMZ permeten representar diverses geometries (punts, polígons, models 3D, etc.) expressades en latitud, longitud i, opcionalment, altitud.
SHP	Format vectorial d'emmagatzematge digital en el qual es guarda la localització d'elements geogràfics i els atributs associats a aquests.
GeoJSON	Format obert per representar diferents estructures de dades geogràfiques conjuntament amb atributs no geogràfics basat en el format JSON.

El Govern espanyol, amb el desenvolupament de la Norma Tècnica d'Interoperabilitat de Reutilització de Recursos de la Informació (NTI), estableix unes pautes per als formats de publicació dels conjunts de dades de les administracions públiques. En aquesta norma indica que les dades s'han de facilitar en diversos formats, especialment en formats oberts i estàndard d'ús general per a la ciutadania, i que només se'n poden utilitzar de més restringits en casos concrets que ho justifiquin. També indica que s'han d'escollir preferentment formats que permetin fer representacions semàntiques de la informació (RDF) per tal de millorar la comprensió de la informació representada i el seu tractament automatitzat.

Classificació i descripció

La classificació i la descripció dels conjunts de dades no ha de ser diferent de la que s'aplica a altres documents i suports tradicionals. Els *datasets* es generen en un context determinat i tenen una funció concreta, sigui el retiment de comptes per a la transparència, el resultat de la comunicació de la institució (com en el cas de l'extracció de dades de les xarxes socials d'una institució), els padrons de la gestió d'uns impostos, etc.

Tanmateix, de vegades no és tan senzill, perquè són agrupacions de dades que responen a diverses funcions o sèries documentals, com, per exemple, extraccions de bases de dades que contenen informació de diversos plans d'estudis, les llicències d'obres menors i majors d'un districte, etc. En aquests casos es pot valorar fer la separació funcional de les dades i no mantenir el conjunt o considerar-los documents recapitulatius, com és el cas dels llibres de registre d'entrada i sortida d'un organisme (que contenen la informació d'inici o resposta de molts dels tràmits administratius). En aquest aspecte, estàndards com el model conceptual Records in Context (RiC-CM), del Consell Internacional d'Arxius (ICA), es pot adaptar bé a les necessitats de flexibilitat de la descripció de *datasets*, així com d'altres conjunts documentals (Pastor Sánchez, Llanes Padrón, 2017).

La forma que pot agafar la descripció d'un *dataset* és mitjançant els esquemes de metadades associades al fitxer, amb descripcions amb estructures multinivell, amb jerarquies més flexibles, o bé amb la vinculació a la funció i als registres d'autoritat. No hauria de ser diferent de les descripcions que es fan de documents digitals o electrònics. Revisant diferents arxius nacionals, es detecta que no utilitzen sistemes de descripció diferents per a les dades que per a la resta de documents dels seus fons (Niu, 2016).

La mateixa norma de descripció ISAD(G) (International Council on Archives, 2001) permet la descripció de *datasets*, i és la utilitzada per la Secció de Datasets Governamentals (National Digital Archive of Datasets, NDAD) dels Arxius Nacionals del Regne Unitat (The National Archives) ja des de l'any 2000. La proposta de funcionament que proposa l'NDAD és l'ampliació del quadre de classificació en dos nivells per sota de sèrie documental: el nivell d'«expedient», que seria la captura concreta del conjunt de dades, i un nivell

múltiple anomenat «ítem», en el qual es descriurien les diferents taules que componen el conjunt de dades si estan desvinculades entre elles partint d'un model relacional (Shepherd, Smith, 2000).

Interoperabilitat

Si es parla de la classificació dels *datasets*, s'ha d'esmentar la Norma Tècnica d'Interoperabilitat de Reutilització de Recursos de la Informació (Ministerio de Hacienda y Administraciones Públicas, 2013) que hem citat anteriorment. Aquesta norma està molt vinculada a la possibilitat d'interoperar amb conjunts de dades de diverses administracions i el *linked open data*, i en l'apartat cinc estableix unes directrius de descripció de la informació i en fixa la classificació temàtica. En els casos en què la ingesta prové de dades administratives, aquesta classificació l'hauria d'haver establert en el diccionari de dades el departament d'origen que fa la transferència de dades, però és possible que en dades internes o no publicades no s'hagi fixat la classificació temàtica tal com la norma NTI demana.

Els àmbits temàtics que marca l'NTI són població; territori; ciutat i serveis; administració, i economia i empresa, amb un seguit de subapartats que poden ser fàcilment relacionables amb el quadre de classificació de cada institució. A més, la norma indica que qualsevol informació reutilitzable ha de portar associades unes metadades mínimes per descriure els conjunts de dades per poder-ne fer la reutilització, i que caldria usar els vocabularis i els esquemes de valors que es proposen, mitjançant tecnologies del web semàntic, com ara les ontologies.

A més, pel que fa a la mateixa descripció dels *datasets*, estableix uns esquemes de metadades mínims per descriure'ls que poden servir de base per ampliar l'esquema necessari per establir tot el context.

Qualitat dels conjunts de dades

Introducció

Pel que fa a la qualitat de les dades hi ha una extensa bibliografia, perquè és una qüestió que afecta directament les aplicacions i els negocis que les consulten i utilitzen. El concepte de qualitat és ampli i té diferents dimensions, i quan arriba a l'arxiu cal tenir en compte una sèrie d'aspectes, mentre que d'altres depenen directament de qui ha creat aquestes dades i no es poden corregir. En el moment de la creació o el disseny de les bases de dades o en el moment d'extreure les dades es poden tenir en compte les recomanacions del Consorci World Wide Web (Lóscio *et al.*, 2016) i el vocabulari de qualitat de les dades (DQV) desenvolupat per tenir en compte específicament les mètriques i mesures de cada dimensió (Hyvonen *et al.*, 2020). Aquesta informació hauria d'estar introduïda com a metadades i la definició hauria de formar part de la política de l'organització que genera aquests conjunts de dades, però malauradament no és habitual.

Comprovacions de la qualitat

Es considera que el 80 % de l'anàlisi de dades se centra en el procés de neteja i preparació de les dades (Oni, 2019) i que és en aquest estadi on es detecten els errors i es recopilen noves dades.

En els arxius, la comprovació de la qualitat de les dades seria similar a com es fa amb les transferències de documents no estructurats: es demana que arribin els expedients nets de còpies i esborranys. En el cas de les ingestes automàtiques al gestor documental, s'indiquen metadades i es fan les comprovacions de tipologies documentals o documents obligatoris.

El concepte de «dada errònia» és ampli. Les dades errònies són dades inexactes, sigui per manca de dades o bé per la inclusió de dades inapropiades (per exemple, dades en columnes incorrectes), dades duplicades o dades incorrectes (errors ortogràfics, tipogràfics, de format, etc.). Detectar i reduir aquests errors disminueix el marge d'error d'explotacions posteriors i millora la comprensió del context de creació de les dades.

Els problemes de qualitat de les dades són presents en conjunts, col·leccions i bases de dades úniques. La integració de múltiples fonts de dades és complexa, atès que les fonts sovint contenen dades redundants o errònies, sobretot si hi ha grans volums de dades involucrats.

Per tal de valorar la qualitat dels conjunts de dades s'han desenvolupat diversos criteris que han de complir els conjunts de dades (Olson, 2003):

- Validesa: les dades són correctes si serveixen per a la finalitat per a la qual s'han recollit. Garantir la validesa és complicat especialment en l'ús de fulls de càlcul, per la dificultat d'establir controls en les dades que hi aboquen els usuaris.
- Exactitud: grau de conformitat d'una mesura amb un valor estàndard.
- Integritat: grau en què es coneixen totes les mesures que es requereixen.
- Consistència: grau en què un conjunt de mesures és equivalent en tots els sistemes. La inconsistència té lloc quan dos elements de dades en el conjunt de dades es contradiuen entre elles.¹
- Uniformitat: grau en què s'especifiquen les mesures d'un conjunt de dades utilitzant les mateixes unitats de mesura en tots els sistemes.

A l'apartat que ve a continuació es proposa una llista de possibles errors de forma i contingut que es poden comprovar ràpidament en el moment de la ingesta, sigui manualment amb extraccions dels mateixos sistemes o per mitjà de tercers agents en un context de donació o recopilació d'arxius socials.

La llista recull, en forma de taules agrupades segons els criteris de qualitat dels conjunts de dades, la definició, la forma de detecció, la forma de correcció i exemples o casos en els quals s'ha trobat o es pot trobar aquest error. En els casos en què és un error que afecta diverses propietats, s'ha incorporat només en una.

Per a l'elaboració de la llista s'han recollit exemples de bones pràctiques i errors comuns de treball en *datasets* i revisió de bibliografia, especialment basada en l'article «The Quartz guide to bad data» (Graskopf, 2015), en el qual hi ha una primera llista, i s'ha organitzat seguint els criteris anteriors.

¹ L'eina OpenRefine's per agrupar textos pot ajudar en el procés de comprovació de la consistència i en la correcció, suggerint coincidències entre valors inconsistents en una columna (per exemple, relacionant Los Angeles amb Los Angeles). Cal documentar els canvis de manera que puguis garantir l'origen de les dades.

Validesa

PROBLEMA	DEFINICIÓ	EXEMPLES	ACCIÓ
L'origen de les dades no està documentat	No se sap el context de creació del <i>dataset</i> .	<p>Malgrat que l'arxiu pugui ser el receptor final de tot tipus de <i>datasets</i>, l'arxiu ha de poder:</p> <ul style="list-style-type: none"> – Identificar el productor: no és el mateix si és la mateixa institució, un grup seguidor de teories de la conspiració, un grup polític, un lobby amb interessos comercials o una ONG. – Saber la forma de recollida: la fiabilitat també la marca el fet de si el <i>dataset</i> s'ha recollit mitjançant sensors, recollida automatitzada, enquestes i entrevistes, transcripcions manuals, etc.; un sensor pot no estar ben calibrat, però és més precís que un mesurament manual. – Saber si la captació del <i>data set</i> s'ha fet en el mateix moment a mà o amb una tauleta tàctil o un ordinador (<i>typed, tapped or scribbled</i>), per detectar els errors tipogràfics o d'uniformitat. <p>Conèixer el context de captació: les dades geogràfiques preses en temps de guerra poden no ser precises, les dades d'un govern poden tenir biaixos ideològics o no ser exhaustives, etc.</p>	<p>Detecció: abans de la transferència, recollida de les dades de context.</p> <p>Solució: tenir una política ben definida de transferències en què sòbligui a informar de totes les dades de producció i captació dels <i>datasets</i>.</p>
Les categories han estat mal seleccionades	No s'han inclòs totes les categories possibles o bé les categories estan mal definides.	<p>Camps verdader/fals que no ho són realment. Pot passar en enquestes en què es rebutja respondre algunes preguntes o en què no se sap la resposta d'algunes preguntes, fets que també són dades significatives.</p> <p>Exemple: L'ús de la categoria «Altres» en llistes tancades; per exemple, en una llista de països, «altres» pot significar que és un país desconegut, que no és un país reconegut, que es tracta d'aigües internacionals..., o si es tracta de persones, pot fer referència a persones refugiades o expatriades, que no saben la resposta, o que no s'identifiquen amb cap país de la llista, etc.</p>	<p>Detecció: revisar les llistes de les categories.</p> <p>Solució: és un error en la captura de dades, només es pot documentar el sentit de les categories definint-les bé per evitar els errors d'interpretació.</p>
Les categories són massa àmplies	Les categories agrupen conjunts massa àmplis perquè siguin representatius.	S'han agregat dades per províncies i per als conjunts seria bo tenir-les separades per comarques o municipis, o es donen les dades anuals però no disgregades en mesos o dies. És possible que les dades estiguin així per motius de confidencialitat (per exemple, no identificar l'únic resident nepalès d'un municipi), però altres vegades s'ha així fet per reduir l'extensió del <i>dataset</i> .	<p>Detecció: revisar les llistes de les categories.</p> <p>Solució: com que una vegada s'han agregat les dades (cosa que pot interessar de fer per motius de confidencialitat, però se'n perd el detall) ja no es poden tornar a separar, cal demanar a la font si té els conjunts desagregats.</p>

<p>Valors anormalment regulars</p>	<p>Es produeixen uns conjunts de valors molt regulars sense cap motiu.</p>	<p>Exemple:</p> <p>La quantitat de metres eliminats d'una sèrie durant molts anys és exactament la mateixa i es van eliminar en el mateix moment. És possible que sigui una mitjana de diversos anys, en tenir prèviament la dada agregada.</p> <p>No s'hauria de dividir la dada en subconjunts (un altre exemple seria una dada anual dividida entre 12 mesos i designada amb el nom de «mitjana mensual»).</p>	<p>Detecció: revisar els valors repetits anormals.</p> <p>Solució: demanar les dades prèvies a la desagregació. Si no és possible, documentar els càlculs que s'hagin fet i informar-ne.</p>
<p>Existència de valors sospitosos</p>	<p>Valors que solen ser erronis, sigui per entrada manual o per errors del sistema de tractament de dades.</p>	<p>Exemples de nombres: 65.535 255 2.147.483.647 4.294.967.295 555-3485 99999 (o qualsevol altra seqüència llarga de nous) 00000 (o qualsevol altra seqüència llarga de zeros)</p> <p>Exemples de dates: 1970-01-01T00:00:00Z 1969-12-31T23:59:59Z January 1st, 1900 January 1st, 1904</p> <p>Exemples de geolocalització: 0°00'00.0"N+0°00'00.0"E o simplement 0°N 0°E Codi postal EEUU 12345 (Schenectady, New York) Codi postal 01001 (Abrevadero, Vitòria, Espanya)</p>	<p>Detecció: revisar els camps per cercar aquests nombres.</p> <p>Solució: comprovar si són correctes i, en cas que no ho siguin, demanar a la font la correcció. Si no té els nombres correctes, cal documentar-ho com a error.</p>
<p>Les dades estan barrejades amb formats i anotacions</p>	<p>Repeticions dels encapçalaments o definicions i anotacions a les taules.</p>	<p>Exemple:</p> <p>Un full de càlcul en què la primera fila és el títol de la taula, la segona és el nom de les columnes i la tercera és la descripció o les anotacions, i les dades comencin a partir de la quarta.</p> <p>També és possible trobar taules en què cada cert nombre de files es repeteix l'encapçalament, sobretot si s'han utilitzat per imprimir-se.</p>	<p>Detecció: revisar si hi ha files extres als encapçalaments.</p> <p>Solució: demanar preferentment les taules en format XML o HTML que permetin veure una separació clara entre les dades i el format.</p>

Exactitud

PROBLEMA	DEFINICIÓ	EXEMPLES	ACCIÓ
No s'especifica el temps de recollida de les dades	Els valors de referència s'han modificat al llarg del temps i no es coneix el moment en què es pren la dada.	Exemple: A causa de la inflació, el sou en euros de l'any 2002 no és equivalent al sou en euros de l'any 2021, malgrat que és la mateixa unitat de mesura. Un altre cas és quan s'indica que el subjecte cobra «el salari mínim interprofessional», perquè és un valor que va variant al llarg dels anys. Fins i tot si ho diu, hi ha unitats que han canviat el significat amb el temps. Un dòlar de l'any 2010 no té el valor d'un dòlar actual, o una tona curta no és una tona imperial ni una tona. ²	Detecció: mirar si els camps tenen mesures fixes (científiques) o variables al llarg del temps. Si hi ha rangs de molts anys al llarg del <i>dataset</i> , és més habitual que hi hagi aquest problema. Solució: indicar l'any de presa de les dades i informar del fet que hi ha camps que no són comparables directament.
Diferències de quants decimals admet	En files o columnes diferents s'admeten més decimals o menys, i alguns estan arrodonits i d'altres són més exactes.	En alguns camps monetaris s'han admès fins a tres decimals i d'altres només n'admeten dos o cap. A l'hora de fer càlculs (com l'IVA repercutit), pot variar l'import final i donar errades que no són reals.	Detecció: mirar les configuracions del camp i fer la comparació entre files. Solució: demanar a la font el <i>dataset</i> net i més exacte o passar totes les dades a un únic format.
Els noms dels camps són ambigus	Els noms del camps no especifiquen el significat de la dada i es poden interpretar de maneres diferents.	Un camp anomenat «Residència» pot significar el lloc on es viu habitualment, el lloc on es paguen els impostos, la ciutat, la comarca o el país.	Detecció: fer una lectura detallada dels noms dels camps. Solució: demanar a la font la definició del diccionari de dades.

² Tona anglesa, imperial o llarga: 1.016,0469088 quilograms. Tona americana o tona curta: 907,185 quilograms. Tona: 1.016,047 quilogram

Integritat

PROBLEMA	DEFINICIÓ	EXEMPLES	ACCIÓ
Valor en blanc o nul	Dades no introduïdes.	Es donen dades anuals i hi ha un any està en blanc: cal saber si és perquè no es van recollir dades aquell any o per algun altre motiu. En el cas de les enquestes, saber si el valor blanc és perquè l'entrevistat no sap la resposta o ha refusat contestar-la, o si és possible que no trobin la resposta a la llista controlada (per exemple, per la qüestió del gènere home/dona en les persones que es defineixen com a no binàries).	Detecció: cercar els valors en blanc i veure si tenen una explicació. Solució: preguntar a la font el significat i descriure-ho en el diccionari de dades.
Les dades en blanc es reemplacen per zeros	Ús de valors arbitraris per substituir els valors en blanc o nuls.	Un valor fals per expressar la data s'acostuma a trobar com a «1970-01-01-01T00:00:00Z» o «1969-12-31T24:59:59ZZ», que és on comença el registre temporal Unix o Unix epoch for timestamps. Un fals 0 per a la localització es pot representar com a 0° 00'00"N+ 0° 00'00"E o simplement com a 0°N 0°E, que és el punt de l'oceà Atlàntic just al sud de Ghana conegut com a Null Island.	Detecció: cercar els valors 0, -1, «false» i «null» i comprovar si són coherents. Cercar si apareix la data del registre temporal Unix o la geolocalització de Null Island. Solució: preguntar a la font el significat.
Manquen dades que hi haurien de ser	Falta de dades que per la temàtica el o concepte hi haurien de ser.	Dades geogràfiques: tots els municipis, comunitats autònomes, països o estats han d'estar representats, o ha d'haver-hi alguna raó per tal que no hi siguin. Si es treballa amb un <i>dataset</i> sobre les empreses de l'IBEX35, s'ha de comprovar que no en manca cap.	Detecció: tenir el coneixement del conjunt de dades. Solució: si hi ha mancances, demanar a la font el <i>dataset</i> complet o l'explicació dels buits per poder-ho documentar.
El dataset té 65.536 o 1.048.576 registres	El màxim de files que admetien les versions antigues de l'Excel eren 65.536. Actualment són 1.048.576.	Si es vol fer una transferència d'un <i>dataset</i> amb aquest nombre exacte de registres és possible que s'hagi tallat en alguna migració a un Excel i hi manquin dades.	Detecció: revisar el total de files. Solució: demanar a la font el <i>dataset</i> complet.
El dataset té 255 columnes	L'aplicació Numbers d'Apple només admet 255 columnes i retalla les files que en tenen més sense avisar l'usuari.	Si es vol fer una transferència d'un <i>dataset</i> amb aquest nombre exacte de columnes és possible que s'hagin tallat en alguna migració o que s'hagin obert en algun moment amb l'aplicació Numbers d'Apple.	Detecció: revisar el total de files Solució: demanar a la font el <i>dataset</i> complet.
El dataset té unes dates anormals	Alguns programes tenen unes dates per defecte i, si es detecten, és possible que s'hi hagin incorporat automàticament i que no responguin a una data real.	L'Excel té com a referència per comptar les dates l'1 de gener de 1900, excepte si s'obre amb un Mac, que és l'1 de gener de 1904. És possible que errors en càlculs de dates acabin deixant la data per defecte i que sigui alguna d'aquestes. Si apareix sovint, o si és una data que resulta incoherent amb la resta, es tractaria d'un error. Altres bases de dades i aplicacions generen la data 1970-01-01T00:00:00Z o 1969-12-31T23:59:59Z, agafada com a data mostra quan un sistema intenta entrar un valor 0 o buit a un camp de data obligatori.	Detecció: revisar els camps de data per comprovar si apareixen aquests valors. Solució: demanar a la font el <i>dataset</i> sense errors o revisar els camps calculats per trobar l'errada. Si no se'n disposa, eliminar aquestes dates, documentant el motiu de l'any que està buit.

<p>Els espais al final de la línia estan mal codificats</p>	<p>Els arxius amb text i dades, com és el cas dels <code>.csv</code>, utilitzen caràcters invisibles per representar una nova línia.</p>	<p>Windows, Mac i Linux han tingut un desacord històric sobre quins haurien de ser els caràcters que marquin el salt de línia.</p> <p>Obrir un fitxer amb un programa que prèviament s'ha desat amb un altre sistema operatiu pot provocar que l'Excel o altres aplicacions fallin a l'hora d'identificar el salt de línia.</p> <p>Fins a l'any 2018, l'editor de text tenia algunes incompatibilitats en la interpretació. (López, n.d.)</p>	<p>Detecció: revisar la formació del CSV i del <i>dataset</i> per veure si els salts de línia estan ben interpretats.</p> <p>Solució: parametritzar correctament els salts de línia.</p>
<p>Falla la llei Benford³</p>	<p>Sistema de detecció de possibles mancances de dades.</p>	<p>Es pot utilitzar aquest sistema per fer una comprovació per si hi ha sospites que el <i>dataset</i> és incomplet o s'ha modificat.</p> <p>A les adreces és habitual que hi hagi més registres amb números baixos de carrers que amb números alts, ja que no tots els carrers tenen la mateixa longitud, i passa igual amb els pisos. De la mateixa manera, també hi ha més població amb estudis primaris que superiors, etc.</p>	<p>Detecció: revisar els camps numèrics que són incrementals.</p> <p>Solució: demanar a la font si hi ha alguna raó per la qual no es compleix la llei Benford i, si no és així, <i>demanar</i> el <i>dataset</i> complet.</p>
<p>El text s'ha convertit en nombres</p>	<p>No tots els numerals són nombres, però és possible que en migracions la definició de la cel·la s'hagi agafat per defecte i els hagi transformat.</p>	<p>Els codis postals identifiquen geogràficament i tenen una longitud determinada. Així, 01007 és el codi postal d'Armentia, Àlaba (Espanya), no és el 1007, que és Buenos Aires (Argentina).</p> <p>L'Excel i altres fulls de càlcul assumeixen que els numerals són nombres i esborren els zeros inicials.</p>	<p>Detecció: revisar les configuracions dels camps i comprovar si són coherents amb el contingut.</p> <p>Solució: demanar a la font la correcció. Si no és possible, documentar l'error.</p>
<p>Els nombres s'han desat com a text</p>	<p>La configuració dels camps s'ha passat a text, cosa habitual quan s'ha optimitzat per presentar les dades en comptes de per fer-lo reutilitzable.</p>	<p>En comptes d'escriure un milió d'euros amb el nombre 1000000, la cel·la pot contenir comes 1,000,000, espais 1 000 000 o text: «euros».</p> <p>El fet de ser text el fa poc reutilitzable i no comparable amb altres dades.</p>	<p>Detecció: revisar les configuracions dels camps i comprovar si són coherents amb el contingut.</p> <p>Solució: demanar a la font la correcció i la neteja de les dades. Una bona pràctica és desar els nombres sense format i després incloure informació de suport en el nom de la columna o en les metadades.</p>
<p>El full de càlcul ha interpretat malament el format dels camps</p>	<p>Els camps s'han obert en un full de càlcul i s'han desat amb el format erroni.</p>	<p>Un camp de data que s'ha interpretat com una fórmula i divideix o resta els nombres, un camp textual que es converteix en numèric... Cal repassar l'origen i les possibles migracions.</p> <p>Exemple de 2020:</p> <p>Es van reanomenar per error 27 gens humans perquè s'havia obert amb Excel el <i>dataset</i> que els contenia i els va confondre per dates (Jacobson, 2020).</p>	<p>Detecció: tot i que és complicada, fer una comprovació prèvia obrint una còpia del <i>dataset</i> en un full de càlcul i veure si interpreta correctament els camps.</p> <p>Solució: demanar a la font una extracció directa de la font i utilitzar formats com CSV.</p>

³ Llei Benford o llei del primer dígit: teoria segons la qual els dígits petits (1, 2, 3...) apareixen molt més sovint que els dígits grans (7, 8, 14...).

Consistència

PROBLEMA	DEFINICIÓ	EXEMPLES	ACCIÓ
Files duplicades	Files o parts de files que apareixen duplicades sense cap motiu.	En <i>datasets</i> financers, és possible que apareguin dues files gairebé idèntiques i que utilitzen els mateixos identificadors que la transacció original, però una és l'original i l'altra és la correcció. Cal tenir-ho en compte per no eliminar-la com a duplicat, però se n'ha d'informar per evitar càlculs erronis.	Detecció: cercar valors duplicats en diverses files. Solució: preguntar a la font el significat dels valors duplicats i documentar-ho. Treballar amb identificadors únics.
Ortografia inconsistent	Error tipogràfic.	Noms amb errors de picatge, faltes d'ortografia o abreviatures. Exemple: Santa Coloma / Sta. Coloma / Sta Coloma / Santa Culoma / Sta Coloam... Són molt habituals en processos automàtics de lectura i reconeixement de caràcters, en processos manuals de captura de dades (enquestes, entrevistes al carrer), en gravacions de dades manuals i en transcripcions de textos.	Detecció: cercar camps controlats (com els noms de països, ciutats, etc.). Solució: documentar que la recollida és manual i, per tant, pot contenir errades en els camps no controlats. Fer la correcció dels camps si es poden confrontar amb la font i documentar-ho.
L'ordre de les paraules és inconsistent	En expressions o noms, les dades estan separades amb diferents criteris.	En <i>datasets</i> que tenen noms i cognoms amb orígens ètnicament diversos, la unificació de «nom de pila (<i>first name</i>)» «segon nom (<i>middle name</i>)» «cognom 1» i «cognom 2» no sempre és la correcta perquè no s'ha seguit el mateix criteri de concatenar. Per tant, si hi ha un <i>dataset</i> amb noms i cognoms units, cal comprovar que sigui correcte.	Detecció: cercar noms que es coneixen dins el <i>dataset</i> , noms compostos i d'orígens diferents i comprovar si són correctes. Solució: demanar el <i>dataset</i> sense els camps concatenats o fer una revisió a partir de taules controlades de noms.
Els formats de dates són inconsistents	Les dates no segueixen el mateix format.	Si algunes dates es van escriure seguint el sistema europeu, i altres pel sistema nord-americà, les dates són inconsistents. AnyMesDia Hores:Minuts DiaMesAny Hores:Minuts MesDiaAny Hores:Minuts:Segons	Detecció: comprovar la configuració dels camps i mirar si hi ha dates impossibles en els diferents formats. Solució: preguntar-ho a la font i fer la conversió a un format únic.
Els formats dels decimals són inconsistents	La separació entre els milers i els decimals utilitza de manera indistinta el punt (.) i la coma (,).	Per exemple: 1,000 > 1.000, o 1,000 < 1.000? Si la parella de xifres va ser escrita per un americà, la primera és un miler i és més gran que la segona, que és u; en canvi, si va ser escrita per un europeu, la primera és u i és més petita que la segona, que és un miler. Tot i així, en general es parla de la coma decimal més que del punt.	Detecció: comprovar la configuració dels camps i mirar si hi ha xifres impossibles. Solució: preguntar-ho a la font i fer la conversió a un format únic.
El text s'ha descodificat amb un codi diferent de l'original	Un text té un conjunt de caràcters que no es poden interpretar.	Textos en què per causa de l'efecte <i>mojibake</i> no és possible interpretar alguns caràcters. Les dades apareixen com si fossin brossa o amb aquests símbols:◆◆◆◆. Pot succeir en casos amb alfabetos o fórmules no habituals. Es recomana utilitzar per defecte la codificació UTF-8.	Detecció: comprovar el contingut del <i>dataset</i> . Solució: en la majoria de casos, l'editor de textos detecta quina és la codificació. La font ha d'indicar quina és la codificació de les seves dades.

Uniformitat

PROBLEMA	DEFINICIÓ	EXEMPLES	ACCIÓ
No s'especifiquen les unitats	Els camps numèrics sense valors absoluts no especifiquen la mesura de referència.	Una columna que es digui «pes» o «cost» no aporta cap informació sobre en quina unitat està mesurat, no es pot assumir si és en quilos, en lliures, en euros o dòlars. Les dades científiques habitualment s'expressen mitjançant el sistema mètric decimal i, de la mateixa manera, alguns preus estrangers es poden expressar en la moneda local, o una tona curta no és el mateix que una tona imperial.	Detecció: mirar els camps que necessiten especificar la unitat de mesura. Solució: Preguntar a la font el significat.
Els símbols monetaris són insuficients	El nom i el símbol de la moneda no és únic en l'àmbit mundial i cal informar del país al qual fa referència.	Per exemple, 10\$ són 10 dòlars, però hi ha diversos països que utilitzen el mateix nom per a la seva moneda, malgrat que tenen valors diferents. En alguns casos, com els dòlars australians, s'indica A\$10 per diferenciar-los dels dòlars dels altres països, però és possible que si s'han fet simplificacions pensant que seria un <i>dataset</i> d'ús local, s'hagin tret.	Detecció: mirar els camps monetaris i detectar si hi ha orígens diferents. Solució: preguntar-ho a la font i completar les unitats amb la informació de la moneda a la qual es fa referència.
Els valors de les categories són variables al llarg del temps	La categorització agrupa diferents valors al llarg del temps. Això pot fer que no siguin comparables.	La mala categorització o una categorització que agrupi diferents conceptes que són convencions socials, pot excloure dades artificialment. Per exemple, en les estadístiques de crims el significat de «violència de gènere» ha canviat de definició al llarg del temps. Això pot fer que al llarg del temps un delictes d'agressió sexual estigui en categories diferents o que hi hagi períodes en què simplement no s'hagi comptat.	Detecció: revisar els camps amb categories que tendeixen a ser arbitràries o canviants segons la legalitat, especialment amb conjunts de dades sobre ètnies o policials. Solució: preguntar-ho a la font i informar de les categories que agrupen, si cal, en cada moment. Documentar la data de la captura de dades i la categorització.

Qualitat del contingut de les dades

Hi ha diverses pràctiques per revisar si el contingut de les dades respon a una realitat o si les dades poden ser esbiaixades o errònies, però l'objectiu de les directrius que s'han donat no és l'auditoria de les dades quant al contingut, de la mateixa manera que tampoc no ho és en els arxius textuais establir la veritat del que contenen els documents. Els arxius han d'assegurar la traçabilitat, la integritat del contingut i l'autenticitat de les dades, i per fer-ho és necessari recollir el context.

L'arxiu ha de recollir, en la transferència dels conjunts de dades, el context ampli de captura i creació per tal que qui consulti els documents ho pugui fer amb el màxim de coneixements. Igualment, ha d'establir polítiques clares respecte a què i com s'acceptarà com a dades, amb pautes i informació sobre els aspectes següents:

- Marge d'error de les dades.
- Marge d'aleatorietat de la mostra: idiomes disponibles en les enquestes, llocs de publicació, sistemes de publicitat, etc.
- Edicions posteriors: correccions d'errades del procés de captura (per exemple, normalitzacions errònies de cognoms, com «Peres» per «Pérez», que provoquen confusions, canvis massius per anonimització de dades personals, etc.) i si s'han documentat.
- Preguntes de les enquestes per aconseguir les dades: la manera de fer la pregunta pot influir en la resposta, i també qui la respon. El fet de conservar les plantilles dona una part del context de captura.
- Format original de les dades: si provenen de bases de dades, de documents escanejats amb reconeixement òptic de lletra manuscrita o mecanoscrita, o si provenen de fitxers PDF, etc

Conclusions

Aquest document ha presentat un seguit de conceptes i una proposta metodològica per a la comprovació de la qualitat formal dels conjunts de dades en el moment de la ingesta a l'arxiu. En un món en què la producció de dades és una realitat diària, cal estar preparats per establir a les organitzacions les polítiques d'acceptació d'aquests conjunts de dades i traduir la metodologia d'arxiu, una vegada més, a un nou format.

Els arxius s'han adaptat als documents digitals ofimàtics i han preparat gestors documentals, estratègies de descripció amb els esquemes de metadades i polítiques de preservació. Fins que s'arribi, però, a tenir una visió de tot el sistema, cal treballar per saber conviure amb un entorn híbrid, amb documents en diferents formats i formes.

Les directrius que es proposen són un primer pas per tal que cada organització les adapti sabent quina és la seva realitat, però són, en tot cas, comprovacions prèvies a la transferència de dades. També caldrà desenvolupar, en segon terme, com es pot fer el tractament de les dades i les possibilitats d'accés que ofereixen els formats de dades estructurats, adaptant-se a les normes de descripció dels documents digitals.

Bibliografia

- BIZER, C.; HEATH, T.; BERNERS-LEE, T. (2009). «Linked data - The story so far». *International Journal on Semantic Web and Information Systems*. Vol. 5, núm. 3. <<https://doi.org/10.4018/jswis.2009081901>>.
- BUTTERFIELD, A.; EKEMBE NGONDI, G.; KERR, A. (ed.) (2016). *A Dictionary of Computer Science*. 7a ed. Oxford University Press. <<https://doi.org/10.1093/acref/9780199688975.001.0001>>.
- DEPARTAMENT DE CULTURA. *Quadre de classificació de la documentació. Dades obertes de Catalunya*. Portal de dades obertes de la Generalitat de Catalunya. <<https://analisi.transparenciacatalunya.cat/Sector-P-blic/Quadre-de-Classificaci-de-la-documentaci-/5t23-dy8y>>. [Consulta: 28, juliol, 2021].
- DEPARTAMENT DE CULTURA. *Què són les dades obertes. Govern obert*. Generalitat de Catalunya. <https://governobert.gencat.cat/ca/dades_obertes/dades-obertes/que-son-les-dades-obertes/>. [Consulta: 28, juliol, 2021].
- GEBRU, T.; MORGENSTERN, J.; VECCHIONE, B.; VAUGHAN, J. W.; WALLACH, H.; DAUMÉ III, H.; CRAWFORD, K. (2020). «Datasheets for Datasets». *Arxiv*. <<https://arxiv.org/abs/1803.09010v7>>.
- GRASKOPF, C. (2015). «The Quartz guide to bad data». *Quartz* (15 de desembre de 2015). <<https://qz.com/572338/the-quartz-guide-to-bad-data/>>.
- HYVONEN, E.; ALBERTONI, R.; ISAAC, A. (2020). «Introducing the Data Quality Vocabulary (DQV)». *Semantic Web*. Vol. 12, núm. 1. <<https://doi.org/10.3233/SW-200382>>.
- IBM. (2001). *Dictionary of computer science, engineering, and technology*. Vol. 38, núm. 10. <<https://doi.org/10.5860/choice.38-5325>>.
- INTERNATIONAL COUNCIL ON ARCHIVES (2001). ISAD(G): Norma Internacional General de Descripció Arxivística = General International Standard Archival Description; adoptada pel Comitè de Normes de Descripció, Estocolm, Suècia, 19-22 de setembre de 1999. Versió catalana a cura de Josep Matas i Jaume Rufí Pagès; amb l'assessorament d'Àngels Bernal et al. 2a ed. Vol. 2a, p. 112. Barcelona: Associació d'Arxivers de Catalunya; Departament de Cultura de la Generalitat de Catalunya. <http://catalogue.ub.edu/record=b1492091~S1*cat>.
- ISO/IEC (1993). *ISO/IEC 2382-1:1993 - Information Technology - Vocabulary - Part 1: Fundamental Terms*. [Consulta: 24, febrer, 2021].
- ISO/IEC (1994). *ISO - ISO/IEC 11179-3:1994 - Information technology - Specification and standardization of data elements. - Part 3: Basic attributes of data elements*. <<https://www.iso.org/standard/19184.html>>. [Consulta: 24, febrer, 2021].
- JACOBSON, D. (2020). «Human genes re2 named as Microsoft Excel reads them as dates - BioNews». *BioNews* (10 d'agost de 2020). <https://www.bionews.org.uk/page_151346>.
- LÓPEZ, M. (2018). «Introducing extended line endings support in Notepad». *Windows Command Line* (8 de maig de 2018). Microsoft. <<https://devblogs.microsoft.com/command-line/extended-eol-in-notepad/>>. [Data de consulta: 26, febrer, 2021].
- LÓSCIO, B. F.; BURLE, C.; CALEGARI, N.; GREINER, A.; ISAAC, A.; IGLESIAS, C.; LAUFER, C. (2016). «Data on the Web Best Practices». *W3C* (gener de 2016). <<https://www.w3.org/TR/dwbp/>>.

MINISTERIO DE HACIENDA Y ADMINISTRACIONES PÚBLICAS (2013). Resolución de 19 de febrero de 2013, de la Secretaría de Estado de Administraciones Públicas, por la que se aprueba la Norma Técnica de Interoperabilidad de Reutilización de recursos de la información. *Boletín Oficial del Estado*. Núm. 54 (4 de març de 2013), p. 17045 a 17071.

NIU, J. (2016). «Organisation and description of datasets». *Archives and Manuscripts*. Núm. 44, p. 73-85. <<https://doi.org/10.1080/01576895.2016.1179585>>.

OLSON, J. E. (2003). «Data Quality: The Accuracy Dimension». Dins: *Data Quality: The Accuracy Dimension*. <<https://doi.org/10.1016/B978-1-55860-891-7.X5000-8>>.

ONI, S.; CHEN, Z.; HOBAN, S.; *et al.* (2019). «A comparative study of data cleaning tools». *International Journal of Data Warehousing and Mining*. Vol. 15, núm. 4, p. 48-65. <<https://doi.org/10.4018/IJDWM.2019100103>>.

PASTOR SÁNCHEZ, J. A.; LLANES PADRÓN, D. (2017). «Records in Contexts y la publicación de conjuntos de datos archivísticos interoperables». Dins: MELO SIMÕES, M. da G.; MANUEL BORGES, M. (ed.). *Tendências atuais e perspectivas futuras em organização do conhecimento*, p. 587-599. Centro de Estudos Interdisciplinares do Século XX - CEIS20. <<https://dialnet.unirioja.es/descarga/libro/719647.pdf>>.

QUÍLEZ, J. (2017). «Integració d'arxius, mueses i biblioteques amb tecnologies del web semàntic: de la modelització conceptual a la iniciativa linked open data». *Lligall*. Núm. 40 (2017), p.16-57. <<https://www.raco.cat/index.php/lligall/article/view/340577/431359>>.

SHEPHERD, E.; Smith, C. (2000). «The application of ISAD(G) to the description of archival datasets». *Journal of the Society of Archivists*. Vol. 21, núm. 1, p. 55-86. <<https://doi.org/10.1080/00379810050006911>>.

THE NATIONAL ARCHIVES (2011). *Managing the Continuity of Datasets*, p. 1-35. <<http://www.nationalarchives.gov.uk/doc/open-government-licence/open-government-licence.htm;orwritet>>

a/e:associacio@arxivers.com · www.arxivers.com