

La gestió de documents basada en dades

(La gestió de documents i la gestió de dades)

Lluís-Esteve Casellas
Ajuntament de Girona
@lecasellas



La gestió documental:
el futur (és) ara!

**XVI Congrés d'Arxivística
i Gestió de Documents
de Catalunya**

Reus, 4-6 de maig de 2017

Objectiu

- Toc d'atenció a la comunitat professional
 - Polítiques?
 - Metodologia?
- Aproximació metodològica a partir de l'*experiència* de l'Ajuntament de Girona
 - Preservació de dades
 - Preservació de la presumpció d'autenticitat (InterPARES)

Estructura de la presentació

- Gestió de dades: per què
- Estat de la qüestió: on som
- Aproximació metodològica
 1. Identificació del document / registre
 2. Identificació i selecció de dades
 3. Característiques dels registres: la importància del context
 4. Presumpció d'autenticitat: premisses
- Estratègies: com fer-ho
- Reflexions finals i alguna conclusió (o al revés...)

Gestió de dades: per què

Big Data, Open Data, Data Governance, Linked Open Data, (Master) Data Management, Data Science, Research Data, Data Mining, Data Curation...

- Augment exponencial de dades
 - Publicació de dades obertes
 - Sistemes de captura automàtica
 - Internet de les coses
- Gestió de les organitzacions:
 - Automatització de fluxos de treball
 - Tendència a no fixar la informació en *documents* (PDF)

Gestió de dades: per què

(2)

- Rol professional, dades obertes, Big Data:
 - Desajustament entre teoria i pràctica
 - Participació real testimonial en aquests projectes
 - Una qüestió de visibilitat?
- Necessitat real de criteris de retenció i disposició, traçabilitat i autenticitat

Podem tenir un rol rellevant sense una intervenció decidida a l'inici del cicle de vida de la informació?

Estat de la qüestió: on som

- La major part de les iniciatives fins ara s'han centrat en:
 - *Data Management*: explotació directa de dades (TIC)
 - *Research Data Management*: gestió de dades de recerca, principalment per biblioteques universitàries i centres de recerca.
- Perfils: *Data Manager, Data Scientist, Data Curator...*
- Perspectiva professional clàssica: visió *conservacionista*
- Compte: què entenem per *Data*?

[Consortium of European Social Science Data Archive (CESSDA), Digital Curation Centre (DCC), UK Data Archive, Canadian Association of Research Libraries, University of Minnesota Libraries, Data Documentation Initiative (DDI)...]

- Foro Iberoamericano de Evaluación Documental (FIED) -

Estat de la qüestió: on som

(2)

Excepció més alineada amb la perspectiva arxivística:

Canadian GeoSpatial Data Infrastructure

- Sistemes d'informació geogràfica
- InterPARES 2 i OAIS
- Preservació en fase activa

ERPANET (Electronic Resource Preservation Access Network, 2002-2004)

- Arxius nacionals: Anglaterra, Bèlgica, EEUU, França, Holanda, Noruega i Suïssa
- La majoria: extracció +/- sistemàtica en fitxers plans (*snapshots*)
- Principals problemes: accés a còpies de preservació, avaluació de BBDD, relacions entre BBDD i documents i documentació de les BBDD

Estat de la qüestió: on som

(3)

SIARD (Software Invariant Archiving of Relational Databases – Suïssa)

- Processos d'extracció automàtica i posterior *recàrrega*
- Avaluació funcions productor i valor evidencial i informatiu de les dades
- No pren en consideració el 'document' (*vistes*) sinó les funcionalitats del SGBD
- Extracció en 3 fitxers (XML, SQL, text pla)
- Regàrrega de dades: accés mediatitzat per la interfície
- Limitació d'accés extern per a usuaris potencials

Conclusions:

- Perspectiva eminentment tecnològica
- Punt clau: preservació de models relacionals de dades
- *Cal preservar les funcionalitats del SGBD? No...*

Aproximació metodològica

Objectius

- Fixar la informació, sobretot la de sistemes permanentment actualitzables.
- Garantir l'autenticitat de les dades en línia i de les dades extretes.
- Mantenir l'explotabilitat de les dades.

Aproximació metodològica

(2)

1. Identificació del *document / registre*

Augment de formularis en línia:

- Interns o externs
- Dades = document o a registre?
- Fixables (paper o PDF) o no, per tant amb dades residents als sistemes

Bases de dades:

- 1 BBDD = 1 document?
- BBDD = generador de documents?
- BBDD = contenidor de documents?
- *BBDD* o *SGBD*?

Aproximació metodològica

(3)

Model Docucèntric

- La unitat d'informació mínima és un fitxer (objecte digital), cadascun dels quals pot tenir un format diferent.
- La comprensió i explotació individual de cada fitxer no depèn d'un gestor de bases de dades, sinó de l'aplicació específica capaç de representar la informació en el continguda.

Model Datacèntric

- Informació estructurada en el qual la unitat d'informació mínima és la dada.
- Les dades tenen el mateix format i depenen sempre d'un gestor de bases de dades per a la seva comprensió i explotació.

Aproximació metodològica

(4)

Documents en un model docucèntric, característiques:

- La unitat mínima d'informació és un fitxer o un objecte digital, no necessàriament en el mateix format.
- Els documents es fixen de forma individual, ja sigui com un sol objecte o vinculats a més d'un.
- L'autenticitat es basa principalment en algun tipus d'autenticació basat en signatura digital.
- La gestió dels objectes digitals està vinculada a una base de dades, però no integrada a la base de dades.
- L'explotabilitat estructurada d'aquests documents no és una funció requerida, tot i que les dades utilitzades per crear els documents puguin pertànyer a un registre formalment definit.

Aproximació metodològica

(5)

Documents en un model datacèntric, característiques:

- La unitat d'informació mínima és la dada, sempre en el mateix format.
- Les dades no s'extreuen necessàriament del sistema.
- Les dades es creen i s'acumulen de forma seqüencial i poden constituir **registres**.
- La seva comprensió és únicament possible a partir de les relacions entre les dades i les **plantilles o vistes prèviament definides**.
- Els registres gestionats en les bases de dades **poden ser formalment definits, identificats i declarats com a documents**.

Aproximació metodològica

(6)

2. Identificació i selecció de dades

- **Registres existents:**

- Regulació legal.
- Precedents en paper.

- **Registres de nova creació:**

- Necessitat d'evidència: què, qui, quan, com (QQQC)
- Dades qualitatives (ex: dades d'obres)
- Procés de gestió: QQQC de les accions derivades a partir de les dades bàsiques dels documents de l'expedient (ex: registre d'activitats econòmiques i règim de comunicació prèvia)

Aproximació metodològica

(7)

3. Característiques dels registres: importància del context

Què documenten:

- **Registres que documenten accions:** l'objectiu d'una acció és la seva validació mitjançant l'entrada al registre, que pot implicar l'assumpció de drets o obligacions. (ex: padró municipal d'habitants)
- **Registres que controlen altres documents:** l'assentament fa referència a un document però el fet de ser registrat no substitueix el seu valor o el de l'acció que documenta (ex: registre de factures). A priori, podrien ser considerats com a registres secundaris, però no 'sempre'

Aproximació metodològica

(8)

Relació entre assentaments i delimitació temporal

- **Registres continus:** acumulació seqüencial d'assentaments independents i no delimitada formalment en el temps, la validació individual dels quals produeix els efectes immediats o condicionats derivats de la funció de registre. L'assentament assumeix el valor dels documents aportats com a prova de suport. (ex: registre d'activitats econòmiques)
- **Registres discontinus:** acumulació seqüencial d'assentaments en un període predefinit i concret de temps, el conjunt dels quals constitueix una unitat documental simple. Un assentament individual generalment no assumeix el valor dels documents que el justifiquen sinó que únicament pren raó d'ells per al seu control administratiu i per a la formalització final del registre. El valor legal resideix en el conjunt dels assentaments i en els documents de prova que els suporten. (ex: registres de comptabilitat)

Aproximació metodològica

(9)

4. Presumpció de l'autenticitat: premisses

- **Securització dades en línia**
- **Duplicació per extracció periòdica (incremental) i regulada de dades**

Criteris descartats en l'autenticitat de les dades en línia:

- Signatura (forta, en registres continus)
- Incorporació i control de Hash, o fins i tot Hash encadellat
- Sistema redundat de dades

Directrius InterPARES 2:

- *Requisits de referència per a la presumpció d'autenticitat (8+)*
- *Requisits per al suport a la producció de còpies autèntiques (3+)*

Aproximació metodològica

(10)

Recomanacions: estudi de cas de l'Ajuntament de Girona al projecte InterPARES 3

Identitat i integritat

1. Identificació i definició del registre.
2. Robusta gestió general dels usuaris.
3. Actualització per addició de dades, no substitució.
4. Fixació periòdica per extracció sistemàtica de dades.
5. Integració en el Sistema de Gestió de Documents.
6. Descripció de l'estructura de dades, formularis i la funció dels documents.
7. Signatura digital sobre les dades extretes.
8. *Verificació de signatura digital per l'Autoritat de Certificació.*

Confiançabilitat

9. Formalització precisa de la gestió del registre.
10. Definició de les responsabilitats de gestió.
11. *Preservació de logs de creació d'acord amb els períodes de retenció definits.*
12. Regulació institucional dels procediments.

Autenticitat

13. Compliment dels criteris d'identitat i confiança.
14. Assegurament de la no alteració de les dades a llarg termini.
15. Identificació d'altres documents relacionats amb la base de dades: traçabilitat implícita.
16. Extracció periòdica, sistemàtica i regulada de dades (incremental, quan calgui)
17. Assignació de responsabilitats per a l'extracció de dades al Servei d'Arxiu.
18. Continuitat en el temps de la funció.

Usabilitat

19. Formats de preservació apropiats.
20. Garantia sobre la explotabilitat de les dades.

Estratègies: com fer-ho

Preservació de **dades**

Seguretat de **dades**

Dades obertes

Protecció de **dades** personals

Un estratègia concurrent?

Per què?

- Ser més efectius i eficients mitjançant polítiques cooperatives
- Promoure el nostre rol professional (no *-només-* la visibilitat)

Estratègies: com fer-ho

(2)

Qui fa què

Departament (* grau d'influència)	Instrument	
Transparència ***	Catàleg de Dades Obertes (Datasets)	
Gestió de Documents *	Catàleg d'Aplicacions Informàtiques	→ Quadre de Classificació de Documents
Protecció de Dades (GD) **	↓ Catàleg de Fitxers amb Dades Personals (GD)	
	↓ Registre de Fitxers Declarats amb Dades Personals	
Tecnologies de la Informació ***	Registre d'Actius d'Informació (TIC)	→ Catàleg de Fitxers (GD)
	Inventari d'Aplicacions Informàtiques	→ <i>Catàleg d'Aplicacions Informàtiques</i>

Estratègies: com fer-ho

(3)

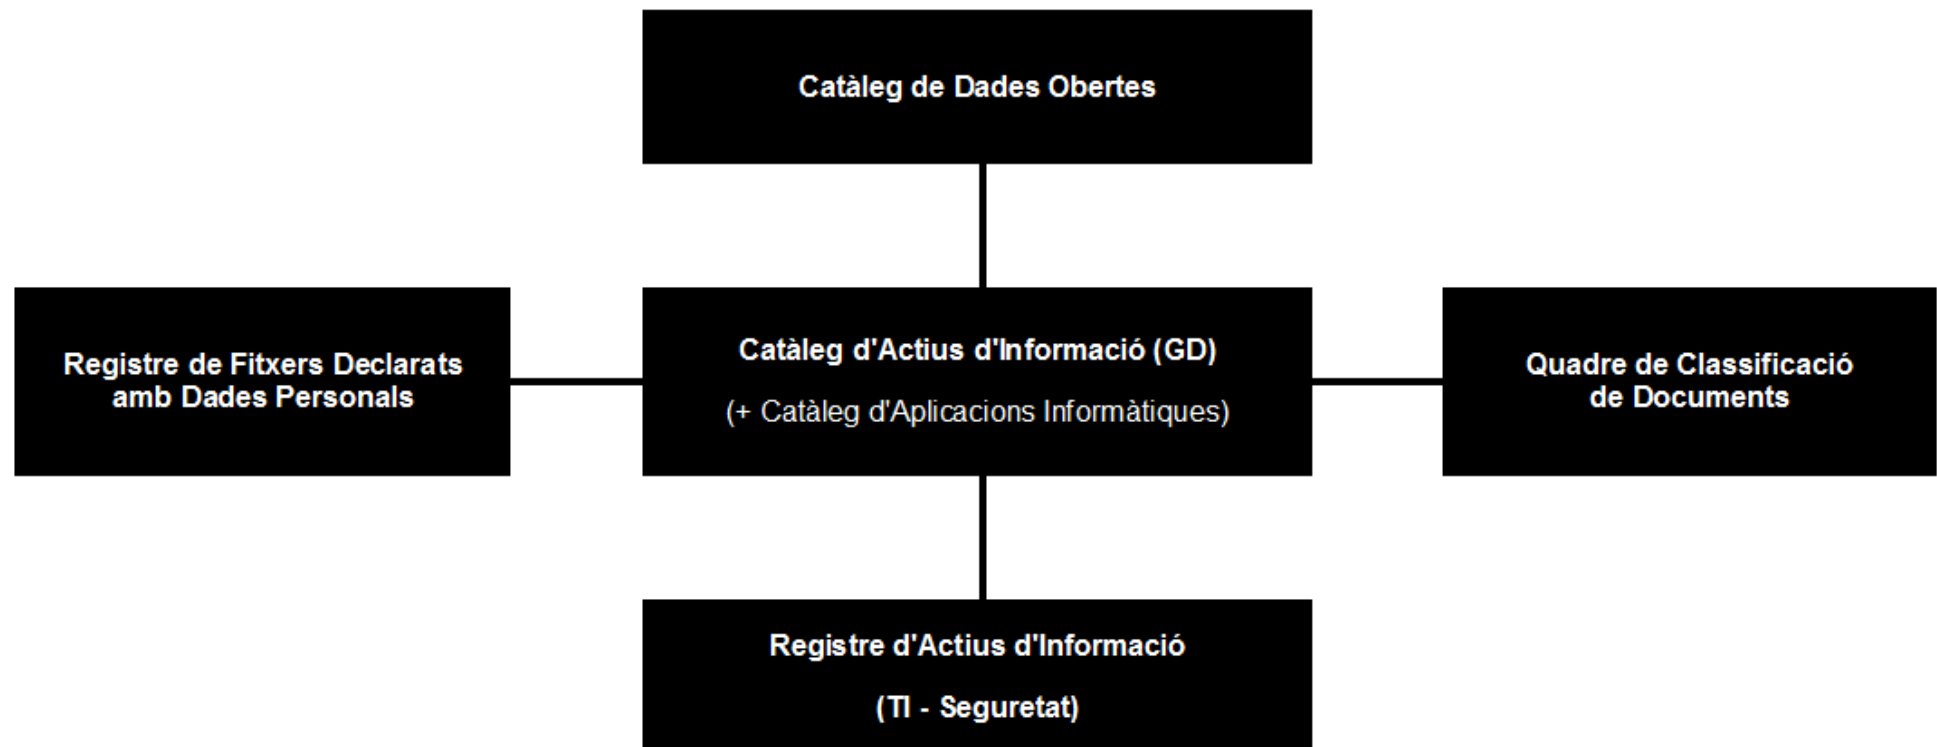
Necessitats compartides

- Identificació i mapeig d'actius d'informació.
- Coneixement i descripció de l'estructura de dades dels fitxers.
- Identificació i selecció de les dades de valor per a la seva reutilització com a dades obertes i la preservació com a documents.
- Aplicació de l'*Avaluació d'Impacte de Privacitat (PIA)* per a definir procediments de dissociació.
- Requisits de confiança, exactitud i autenticitat de les dades en línia i fora de línia (extretes).

Estratègies: com fer-ho

(4)

L'escenari desitjable



Estratègies: com fer-ho

(5)

Gestionar el **cicle de vida** dels actius d'informació

1. **Identificar els actius d'informació** mitjançant el Catàleg d'Aplicacions.
2. **Avaluar els actius d'informació** mitjançant l'anàlisi de les funcions i activitats que generen les dades.
3. **Preservació de l'autenticitat** mitjançant procediments i requisist que documentin i assegurin el context, la identitat i la integritat dels conjunts de dades definits (declarats) com a documents.
4. **Extracció de dades** sota la forma documental de *registre* i la seva incorporació al SGD.

Estratègies: com fer-ho

(6)

Polítiques cooperatives : beneficis i valor afegit

- Control d'actius amb dades personals, **mapeig d'actius reutilitzables** i identificació de **dades sensibles a dissociar**: OD+TIC+GD+PD
- Selecció de dades de valor que constitueixen un **registre administratiu**, aquelles que podrien ser publicades i l'**avaluació del risc de publicació**: GD+OD+PD
- Aplicació de **calendaris de retenció** als fitxers de dades (obertes o no) i el compliment legal en matèria de protecció de dades personals: OD+PD+GD
- **Confiançabilitat de les dades obertes** en base a la preservació de l'autenticitat de les fonts originals i la traçabilitat d'accions: OD+GD
- Processos d'**extracció regulada** per a obtenir fitxers de **dades obertes**: OD+GD+PD
- Processos d'extracció de dades alineats amb els criteris de **Privacitat per Disseny**: OD+PD

Estratègies: com fer-ho

(7)

Dades Obertes: valor afegit

1. QdC = instrument de localització de possibles datasets
2. ApliCAT + QdC: control i descripció estructures de dades
3. Delimitació temporal datasets = rol dels arxius històrics
4. Preservació de Dades *facilita* Dades Obertes *facilita* Preservació de Dades *facilita*...
5. Perspectiva Dades Obertes + Anàlisi Tramitacions = Estalvi de Recursos
6. Avaluació Dades de Tramitació *facilita* identificació de *Registres* potencials
7. GD *facilita* Qualitat de Dades Obertes: l'única opció és el moment de captura
8. GD *facilita* Dissociacions complexes: noves pautes d'entrada de dades en la captura
9. Descripció Contextual *facilita* Comprensió i *reforça* Autenticitat del dataset
10. Transparència = Dades Obertes = nous documents; GD en *facilita* Formalització

*Open data and information: opportunities & challenges for the records profession
Annual Archives Lecture, Dept of Information Science, UNISA, Pretoria, 5 Nov 2015*

universities, has developed such algorithms. Still nascent, these and others under development elsewhere, “will be able to rank sensitivity, prioritizing instances of possibly the highest sensitivity.”³⁹ They illustrate leadership and collaboration. They also have potential application in other contexts and sectors, such as open data and e-discovery and in some way respond to Thurston’s calls for research into risks.⁴⁰

In relation to the sensitivity review work, in two weeks’ time we will be holding a conference called *Threats to Openness in the Digital World* to discuss the issues and identify actions. Amongst a number of leading speakers will be Sir Alex Allan, author of the report for the UK government on a review of the annual release of government records.⁴¹ This is another example of leadership and also education, which is our second important opportunity.

An exemplary demonstration of leadership can be found at Girona City Council where the records management department lead the location of datasets and selection of data to open using records management principles and tools. Why? To “be useful to the organization ... and to reinforce its position in the current trending to data management.”⁴²

Reflexions finals

Preservació de dades: metodologia, més enllà del conjunt de pràctiques aïllades

Metodologia = estabilitat en un context inestable + visibilitat + capacitat d'influir

#posem nos d'acord vs. #fem ho fàcil

Polítiques de preservació de dades: la resiliència de l'estatus de document

Dades Obertes + Protecció de Dades + Seguretat TIC > PRESERVACIÓ

Polítiques cooperatives = valor afegit de l'avaluació i la preservació de l'autenticitat

No busquem l'estratègia: siguem estratègics!

Reflexions finals

La *Datificació* és una realitat, per tant, **ni Docuflautes ni Dataflautes**

Fixar o no fixar, ve't aquí la qüestió... Plantilles vs Formularis?

La gestió documental: el futur (és realment) ara?

El futuro ya llegó, hace un rato” (Los Redondos – Gracias Andrés!)

Estem davant d'un nou escenari?

The Death of ECM and Birth of Content Services

Michael Woodbridge, Director de Recerca de Gartner

Reflexions finals

“La gestió de documents ha mort”

Reflexions finals

Benvinguda sigui

“La governança de la informació”

O alguna cosa força semblant...

Moltes gràcies!



Lluís-Esteve Casellas
lecasellas@ajgirona.cat
@lecasellas
Ajuntament de Girona