

El full de ruta per al disseny d'un projecte de digitalització

ANTONI M. RENDÉ VIDAL. Director de DOCTODATA, SL

Què entenem per *digitalització*? La digitalització és el procés de conversió de la informació de l'estat original analògic a digital per tal d'obtenir avantatges relacionats amb el processament, l'emmagatzematge, l'enviament, la recuperació, l'accés, la seguretat, etc.

La digitalització no és una acció sinó un flux d'activitats que afecten dos processos: l'analògic, que comporta el mostreig del suport físic, i el digital, que inclou la incorporació posterior dels fitxers resultants i de les metadades, als dipòsits de conservació i accés.

La digitalització implica el desenvolupament d'un projecte global que s'origina amb la selecció de materials i que requereix el disseny d'un full de ruta que consta de quatre fases. La primera estableix els criteris de selecció i les pautes de preparació de la documentació. La segona cerca l'obtenció de la imatge digital d'acord amb els paràmetres condicionats per l'ús que se'n vulgui fer. La tercera és la fase de processament digital. I finalment, la darrera fase s'ocupa de

la transferència i de l'allotjament de les imatges electròniques i les metadades corresponents.

Per tal de reflexionar sobre els diferents aspectes que poden condicionar el bon resultat d'un projecte de digitalització —sobretot per a fons històrics—, per valorar-los i tenir-los ben presents a l'hora de definir i executar el projecte, proposem seguir el full de ruta següent:

1. Fase prèvia

a) Criteris de selecció del material

1. Drets d'autor i protecció de dades personals

- › Els materials no han d'estar lligats a restriccions de drets d'explotació.
- › Quan els materials estiguin protegits, però els drets siguin o puguin ser assumits per la institució, cal gestionar la llicència corresponent i assumir-ne el cost pertinent.
- › Si no és viable obtenir els permisos, aleshores els materials no podran ser reproduïts i s'haurà de replantejar el projecte.

2. Contingut intel·lectual

- › El material ha estat prèviament descrit? (Vegeu el punt 3.a.)
- › És prou rellevant per justificar el cost de la digitalització?
- › És considerat un bon exemple del període que representa?
- › Quin és el grau d'interès atemporal?
- › És un material original o es tracta d'una còpia?
- › La col·lecció està completa?
- › ...

3. Demanda

- › Quins són els documents més consultats?
- › Qui és l'usuari potencial? Estan dispersos els usuaris?
- › Les condicions físiques del document en dificulten la consulta?
- › Els materials estan tan dispersos que és difícil estudiar-los de manera disgregada?
- › ...

4. Estat físic

- › Resistirà l'estat físic el procés de digitalització?
- › Quins tractaments preparatoris s'hauran d'aplicar?
- › Hi ha una altra còpia en millors condicions?
- › Quin cost pot implicar una restauració/manipulació?
- › ...

b) Preparació de la documentació

1. Inventari

Inicialment és convenient elaborar un inventari del material per digitalitzar, extret del mateix quadre de classificació o d'una llista creada en la fase de selecció. Això comportarà una inspecció més o menys exhaustiva del material lliurat i ens permetrà conèixer l'estat dels documents en tot moment i, per tant, podrem controlar la qualitat del procés de producció.

2. Tractament físic

- › Extracció d'elements aliens al suport documental (clips, grapes, adhesius, etc.).
- › Neteja superficial del document i detecció de patologies.
- › Protecció del document en cas que estigui malmès.
- › Restauració parcial del document.
- › Restauració total del document.

3. Agrupació dels materials abans de començar el tractament

Depenent de les característiques físiques i organitzatives dels documents i a fi d'automatitzar al màxim el procés d'escaneig i indexació, es recomana agrupar-los i ordenar-los seguint tres criteris —que caldrà valorar en cada situació— que no són necessàriament excloents:

- › Segons el suport de la informació en l'estat analògic.
- › Segons la tipologia documental.
- › Segons els expedients que agrupen els diversos tipus simples.

Els documents dins el procés de digitalització es gestionen agrupats en «lots de producció». Un lot comporta uns determinats maquinaris i tractaments al llarg del calendari de treball.

4. Codificació del lot de captura

Es recomana identificar cada lot de captura amb un codi per tal de garantir la traçabilitat, controlar-ne la qualitat i la ubicació física, a més d'esbrinar la causa i la resolució de possibles incidències.

2. Fase de captura

a) Parametrització de les característiques de la imatge digital

1. Resolució

La resolució (mostres —píxels— capturades per polzada) i la profunditat de color determinen la qualitat de reproducció de la imatge digital i permeten retenir un nivell superior o inferior del detall en el document generat. Si l'objectiu és la visualització o la publicació web del contingut, convindrà optimitzar el pes. Si l'objectiu és preservar l'actiu, aleshores el pes no és tan significatiu. En molts casos convé generar una còpia en alta resolució per a la preservació i una en baixa resolució per a l'accés.

2. Dimensió de la imatge

La dimensió determinarà finalment el pes del fitxer electrònic originat. La dimensió de la imatge digital es calcula multiplicant l'amplada i l'alçària de la imatge original en polzades i la resolució en píxels per polzada. Es recomana proporcionar la superfície de captura en les mides del document original.

3. Profunditat de bit

Rang de codificació de cada unitat d'imatge o píxel (nombre de bits). Es distingeixen tres tipus d'imatge digital:

- › Imatge bitonal.
- › Imatge en escala de grisos o paleta de color.
- › Imatge en color real.

En general, es desaconsella utilitzar la imatge bitonal ja que la reducció de pes que aporta no justifica la pèrdua de detall i qualitat del document electrònic resultant.

4. Rang dinàmic

És l'interval de diferència tonal entre la part més clara i la més fosca d'una imatge. Com més alt sigui més capacitat tindrà de representar els matisos de la imatge. Altrament la imatge sortirà «empastada».

5. Volum de la imatge digital

Per determinar el volum s'ha de multiplicar l'àrea de superfície del document que es vol digitalitzar (amplada × alçària en polzades) per la profunditat de bit (bit/píxel) i pel quadrat de la resolució (en punts per polzada o ppp).

El volum condicionarà l'emmagatzematge necessari i l'amplada de banda de l'accés als continguts. Convé calcular l'espai de disc necessari en la fase inicial sobredimensionant en un determinat percentatge el requeriment teòric a fi de considerar futures ampliacions i una bona gestió de manteniment de servidors i discs durs.

6. Compressió

Els formats digitals admeten dos grups d'algorismes de compressió de la imatge capturada:

- › Sense pèrdua d'informació (*lossless*).
- › Amb pèrdua d'informació (*lossy*).

S'aconsella comprimir només el fitxer de consulta (per exemple amb compressió JPEG).

7. Format de sortida

Els formats generats es defineixen segons els paràmetres establerts en el procés (resolució, profunditat de bit, etc.), el sistema de compressió aplicable —en cas que es faci servir—, i la possibilitat d'agregar-hi metadades.

Els formats recomanats són TIF (preservació) i JPEG o PDF (consulta).

8. Proposta de parametrització

D'acord amb les característiques que es vulguin obtenir en la imatge digital, es recomana crear una taula específica de paràmetres i associar-la a cada lot de documents per tractar.

b) Indexació

Es recomana descriure les imatges digitals mitjançant termes significatius que les identifiquin (per exemple, la unitat de catalogació de l'original) per tal de facilitar als programaris la gestió dels continguts de manera ràpida i eficaç. Aquesta indexació ha de permetre incorporar, de manera més o menys automàtica, els elements descriptius propis de l'activitat arxivística ja obtinguts sobre la mostra analògica. La indexació ha de quedar vinculada a les imatges corresponents a través d'un fitxer de «càrrega», com per exemple un full Excel.

c) Processament gràfic de la imatge digital

Cal preveure que s'hauran de fer correccions. Les més habituals són:

- › Tractaments de neteja i supressió de soroll.
- › Eliminació del moaré (*descreening*).
- › Correcció del color.
- › Eliminació de punts (*despeckling*).
- › Optimització de la lluminositat, el contrast i la gamma.
- › Eliminació de contorns.
- › Enquadrament (*cropping*).
- › Eliminació d'obliquïtat (*deskewing*).
- › Refosa (*merging*) i separació (*split*).

d) Inspecció

És un dels aspectes de control de qualitat que cal dur a terme en temps de procés per verificar que la digitalització s'executa correctament. Consisteix a comprovar que la captura de cada document s'ha dut a terme segons els paràmetres preestablerts.

3. Fase de tractament de la imatge digital

a) Catalogació/descripció

En molts casos, la recomanació seria que la catalogació/descripció s'efectuï prèviament sobre els documents analògics. El perfil concret d'aplicació de metadades ha de donar resposta a les qüestions següents:

- › Quins tipus de metadades s'hi inclouran.
- › Com s'expressaran els tipus de metadades seleccionats.

- › Quins valors podran adoptar els tipus metadades admesos i com s'expressaran els valors.
- › Amb quin llenguatge de marcatge es codificaran les metadades (XHTML, XML, etc.).
- › On s'emmagatzemaran les metadades.

b) Organització i nomenclatura dels fitxers digitals

Es recomana seguir uns estàndards que facilitin la compatibilitat dels diferents sistemes operatius de treball:

- › Els noms dels fitxers no han de ser gaire llargs. La Subdirecció General d'Arxius i Gestió Documental de la Generalitat de Catalunya ha establert unes pautes que preveuen la referència a l'arxiu concret, al fons documental, etc. (Vegeu la *Guia de digitalització de la Xarxa d'Arxius Comarcals*, v 3.0, 09/06/2010, disponible a:

<http://www20.gencat.cat/portal/site/CulturaDepartament/menuitem.9cf6e0ecb7825f175a2a63a7b0c0e1a0/?vgnextoid=20aab946f2e31210VgnVCM1000008d0c1e0aRCRD&vgnnextchannel=20aab946f2e31210VgnVCM1000008d0c1e0aRCRD&vgnnextfmt=detail&contentid=44873ccadbc19210VgnVCM1000008d0c1e0aRCRD>.

- › No barregeu minúscules i majúscules.
- › No col·loqueu caràcters que no formin part del codi ASCII, com la lletra «ñ» o paraules accentuades, o els que s'utilitzen per a les interfícies dels sistemes operatius o que són signes de puntuació (/ \ : * ? " ' < > | . , ;).
- › No deixeu espais buits entre els caràcters.
- › Cada fitxer ha de tenir un nom únic que no es repeteixi en cap altre.

c) Format mestre i formats derivats

El fitxer mestre (també anomenat *màster* o *d'arxiu*) és una versió d'alta qualitat que conté el màxim d'informació de l'original. Es recomana no comprimir-lo (format TIF). Els fitxers derivats són aquells que s'obtenen a partir del fitxer mestre i són els utilitzats per a l'accés a la informació.

d) OCR exhaustiu. Recomanacions:

- › Durant la preparació cal netejar bé el document per evitar que la pols o les taques siguin detectades per l'OCR (sigla anglesa per a reconeixement òptic de caràcters).
- › S'ha de col·locar el document original ben recte a l'hora d'escanejar-lo, sense plecs ni arrugues.

- › Cal escanejar els documents amb escala de grisos i a un mínim de 300 ppp.
- › Com que l'OCR exigeix molt de temps, és aconsellable fer-ho després de la fase de la captura i de manera desatesa.

e) Protecció i autenticació dels fitxers

Si escau, a fi de garantir la integritat dels arxius digitals, s'hauran de dur a terme accions que els protegeixin i impedeixin fer-ne modificacions posteriors. Hi ha diverses tècniques per preservar l'autoria, l'autenticitat i protegir els drets de propietat intel·lectual dels documents digitals:

- › Les marques d'aigua.
- › Els tampons o segells digitals.
- › La signatura electrònica.
- › L'enciptació.

f) Verificació final del material generat

Caldrà determinar:

- › Quin és el percentatge del material per verificar?
- › Quins paràmetres de les imatges es verificaran (captació íntegra de l'original, alineació correcta, equilibri tonal, llegibilitat, etc.)?

4. Fase de transferència i d'allotjament

a) Definició de la política de preservació

La informació que es genera o es rep en suport electrònic ha de complir unes condicions de conservació equivalents a les del suport paper:

- › Garantir la disponibilitat i l'accessibilitat dels continguts:
Amb independència del mitjà físic on s'emmagatzema.
Amb independència del format del document electrònic.
- › Garantir la integritat i l'autenticitat dels continguts:
Preservació de la signatura electrònica o evidència electrònica.

b) Allotjament

Per determinar quin model d'allotjament és el més idoni cal considerar els criteris següents:

- › Objectiu per al qual s'ha creat la col·lecció digital.

- › Volum i taxa de creixement de la col·lecció digital.
- › Complexitat i manteniment de les metadades específiques.
- › Nivell de demanda i rendiment esperat.
- › Infraestructura tècnica i humana necessària.
- › Cost de l'allotjament.

c) Accés

Cal destacar que avui en dia la major part de projectes de digitalització es plantegen amb la possibilitat d'accés remot per tal d'incrementar l'índex de difusió dels objectes digitalitzats. Un aspecte que cal tenir en compte a l'hora de plantejar la creació d'un dipòsit digital és que sigui compatible amb l'OAI-PMH (Open Archives Initiative. Protocol for Metadata Harvesting), un protocol obert per a l'intercanvi de metadades i l'accés obert als continguts d'Internet.

Per aprofundir en el tema:

DOCTODATA. *Pla de digitalització de la cultura a Catalunya. Pautes i recomanacions per a l'elaboració d'un projecte de digitalització*. Maig 2008.

DOCTODATA. *Pla de digitalització de la cultura a Catalunya. Informe Diagnòstic*. Maig 2008.

Jornada: La digitalització de la cultura a Catalunya. [Barcelona, Auditori, 18 de març de 2009]: Generalitat de Catalunya, Departament de Cultura i Mitjans de Comunicació, Direcció General de Cooperació Cultural. Departament de Governació i Administracions Públiques, Secretaria de Telecomunicacions i Societat de la Informació. (Polítiques culturals, presentació d'experiències digitals, opinions expertes).

Trobareu les tres referències a l'adreça següent:

<<http://www20.gencat.cat/portal/site/Biblioteques/menuitem.690b4e2d7-721b5b009671410b0c0e1a0/?vgnextoid=3b6d5b0675e8a210VgnVCM2000009b0c1e0aRCRD&vgnnextchannel=3b6d5b0675e8a210VgnVCM2000009b0c1e0aRCRD&vgnnextfmt=default>>.

RESUM

Els conceptes i les metodologies relacionades amb la digitalització de documents sovint originen dubtes i creen certa confusió. La raó d'aquest fet es troba en la mateixa naturalesa de l'activitat, que comporta relacionar paràmetres i tècniques de tres àmbits diferents: les ciències documentals, el tractament fotogràfic i les tecnologies de la informació i la comunicació.

Molt breument, es proposa un full de ruta que facilita la definició i l'execució d'un projecte de digitalització. Així mateix, es repassen els principals aspectes i paràmetres organitzatius i tècnics que cal tenir en compte per aconseguir uns resultats que s'ajustin als requeriments predefinits.

RESUMEN

Los conceptos y las metodologías relacionadas con la digitalización de documentos a menudo originan dudas y crean cierta confusión. La razón de este hecho radica en la propia naturaleza de la actividad, que implica relacionar parámetros y técnicas de tres ámbitos diferentes: las ciencias documentales, el tratamiento fotográfico y las tecnologías de la información y la comunicación.

Muy brevemente, se propone una hoja de ruta que facilita la definición y la ejecución de un proyecto de digitalización. Asimismo, se repasan los principales aspectos y parámetros organizativos y técnicos que se deben tener en cuenta para conseguir unos resultados que se ajusten a los requerimientos predefinidos.

ABSTRACT

The concepts and methodologies related to the digitisation of documents often raise doubts and create certain confusion. This is due to the very nature of the activity, which involves relating parameters and techniques from three different fields: archival sciences, photography and information and communication technologies.

Here, very succinctly, a roadmap for the definition and execution of a digitisation project is proposed. In addition, the article reviews the main organisational and technical aspects and parameters that must be taken into account in order to achieve results that meet the predetermined requirements.

RÉSUMÉ

Les concepts et les méthodologies ayant trait à la numérisation de documents sont bien souvent à l'origine de doutes et créent une certaine confusion. La raison de ce fait réside dans la nature même des de l'activité, qui implique de mettre en relation des paramètres et des techniques appartenant à trois domaines différents : les sciences documentaires, le traitement photographique ainsi que les technologies de l'information et de la communication.

Très brièvement, l'auteur propose une feuille de route qui facilite la définition et l'exécution d'un projet de numérisation, passe en revue les principaux aspects et paramètres organisationnels et techniques à prendre en compte pour atteindre des résultats correspondant aux exigences prédéfinies.