



FACULTAD DE INFORMÁTICA
UNIVERSIDAD NACIONAL DE LA PLATA

Una metodología de evaluación de repositorios digitales para asegurar la preservación en el tiempo y el acceso a los contenidos

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo





Índice

I. Objetivos

II. Modelo elegido

III. Caso de estudio

IV. Experimento

- a) Análisis de la información de contenido
 - I. Recomendaciones
- b) Análisis de la información descriptiva de la preservación
- c) Análisis de la información descriptiva

V. Conclusiones generales y trabajos futuros


Objetivos de la tesis



Proponer una metodología de evaluación de repositorios digitales con el fin de asegurar la preservación, el acceso y la comprensión de los objetos digitales a largo plazo.

ISO 14721: 2012: ISO Reference Model of an Open Archival Information System (OAIS)

El modelo del repositorio



“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Preguntas y criterios de evaluación

- Saracevic-Covi: se plantean interrogantes: ¿por qué hay que evaluarlas? ¿con qué objeto? ¿qué se debe evaluar, a qué nivel y con qué criterios?
- La evaluación significa una valoración del desempeño o del funcionamiento de un sistema, o parte del mismo, en relación a cierto objetivo.
- El desempeño puede ser evaluado por ejemplo en relación a la Efectividad: ¿cuán bien desempeña un sistema (o cualquiera de sus partes) aquello para lo que fue designado?
- Fuhr: Su propuesta incluye evaluar todos los aspectos de las BD: colecciones, tecnología y usuarios y realizan una propuesta de criterios de evaluación en cada uno de los aspectos mencionados.

Noción de preservación de UNESCO



“La preservación digital puede definirse como el conjunto de los procesos destinados a garantizar la continuidad de los elementos del patrimonio digital durante todo el tiempo que se consideren necesarios”.

*“La mayor amenaza para la continuidad digital es la desaparición de los medios de acceso. No puede decirse que se han conservado los objetos digitales si, al haber dejado de existir los medios de acceso a ellos, resulta imposible utilizarlos. **El objetivo de la preservación de los objetos digitales es mantener su accesibilidad**, es decir, la capacidad de tener acceso a su mensaje o propósito esencial y auténtico”. (UNESCO, 2003: p. 37)*

Amenazas a los Objetos Digitales

1. Su propia naturaleza los hace efímeros.
2. Siempre están mediados por la tecnología. Obsolescencia.
3. Pérdidas por desastres.
4. Barreras de acceso en los archivos: claves, cifrado, formatos cerrados.
5. Desconocimiento de las responsabilidades por la curatela.
6. Falta de planificación, y de recursos para preservación.
7. Problemas legales: permisos para transformar las obras.
8. Descripción inadecuada: imposibilidad de recuperación.
9. Pérdida de información sobre el contexto, esto es sobre las tecnologías utilizadas para accederlos.

Objeto digital:

Acciones en su ciclo de vida para mantener el acceso

OD Y METADATOS DE PRESERVACIÓN



“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”


Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo


La propuesta metodológica

- Tomar como referencia central el Modelo OAIS de la ISO 14721.
- Utilizar la noción de paquete de información del Modelo OAIS y analizar la presencia de los distintos elementos del IP en los contenidos (items) del repositorio.
- Si los contenidos están bien estructurados en cuanto a los elementos propuestos para el IP significa que el repositorio tiene la funcionalidad recomendada por la norma y por lo tanto puede asegurar la preservación y el acceso a los contenidos en el tiempo.

El paquete de información en el OAIS



Acciones propuestas




Las acciones propuestas están vinculadas justamente a los elementos constitutivos del paquete de información: la información de contenido (CDO), la información sobre la representación de ese contenido (RI), la información descriptiva de preservación (PDI) y la información descriptiva (DI).

¿Qué significan las acciones propuestas?

Revisar los objetos digitales y comprobar la existencia de muchos metadatos

Nombre	Descripción	Formato	Ver	Orden
Bloque: TEXT				
☐ Tesina de Licen ... mazan Maria Belen.pdf.txt	Extracted text	Text	[Ver]	1 (Anterior:1)
☐ presentación.xps).pdf.txt	Extracted text	Text	[Ver]	2 (Anterior:2)
Bloque: ORIGINAL				
☐ Tesina de Licenciatura - Almazan Maria Belen.pdf (principal)	Documento completo	Adobe PDF	[Ver]	1 (Anterior:1)
	Presentación	Adobe		2



Acciones


- Evaluar los objetos del repositorio como paquetes de información.
- Generar un reporte sobre el estado de los objetos del repositorio, considerándolos como paquetes de información.
- Informar si cuentan con todos los elementos que la norma define para el paquete de información.
 - Si los paquetes de información en el repositorio se adecúan a los criterios establecidos, los objetos digitales del repositorio y por tanto el repositorio mismo “pasan” la evaluación porque si el PI está bien formado el repositorio es funcional en sus procesos (ingesta, preservación y entrega).

Herramientas para llevar a cabo el experimento

- **Perfilamiento automatizado de los objetos del repositorio:** esto involucra al objeto de contenido (CDO) con sus propiedades significativas y a la información de representación de ese objeto (RI). Realizar el perfil con DROID que contrasta con el registro PRONOM y brinda un reporte.
- **Revisión de los metadatos de preservación** que acompañan a los objetos digitales del repositorio y contraste con los metadatos de la PDI de OAIS a través de una herramienta de validación propia.
- **Revisión de la información descriptiva:** revisar los metadatos descriptivos y contrastarlos con las directrices DRIVER 2.0. y algunos metadatos extras.

Organización de los contenidos en DSPACE

Un item en DSPACE está constituido por metadatos, bundles y bitstreams



Identificador de bitstream y organización de carpetas y archivos del assetstore en DSpace


Identificador de bitstream

15716334126944893246380179810720680853



Mientras que el modelo de datos de Dspace (metadatos, workflows, estructura del repositorio, usuarios..) está soportado por la base de datos Oracle o Postgresql, los contenidos de los ítems se almacenan en el sistema de archivos denominado *assetstore*. Cada objeto digital se almacena con un identificador de 38 dígitos. La carpeta de almacenamiento se denomina *assetstore*.

El paquete de información en el OAIS



Primer Experimento

Información de representación:

Item: <http://sedici.unlp.edu.ar/handle/10915/25088>


Estado del ítem	Archivos del ítem	Metadatos del ítem	Visualizar ítem	Aplicar tarea
Archivos				
Nombre	Descripción	Formato	Ver	Orden
Bloque: TEXT				
 Tesina de Licen ... mazan Maria Belen.pdf.txt	Extracted text	Text	[Ver] 1 (Anterior:1)	
 presentación.xps).pdf.txt	Extracted text	Text	[Ver] 2 (Anterior:2)	
Bloque: ORIGINAL				
 Tesina de Licenciatura - Almazan Maria Belen.pdf (principal)	Documento completo	Adobe PDF	[Ver] 1 (Anterior:1)	
 presentación.xps).pdf	Presentación (diapositivas)	Adobe PDF	[Ver] 2 (Anterior:2)	

Se decidió excluir el bundle TEXT para el próximo experimento y corregir el problema de las falsas repeticiones (MD5 idénticos) haciendo el OCR de muchos archivos que eran PDF de sólo imágenes.

Se realizó un primer experimento con toda la estructura de carpetas del *assetstore*, alrededor de 90000 objetos, considerando todos los bitstreams de los distintos bundles de un ítem. Falsas repeticiones detectadas debido al bundle TEXT en los casos de imágenes (extracción idéntica del media filter y mismo MD5).

El caso de estudio SEDICI en números

Un año atrás




- ITEMS EN EL REPOSITORIO: **30.323**
- ITEMS CON BITSTREAM: **19.656**
- ITEMS CON BITSTREAM y FULLTEXT: **18.599**

Experimento final

- De la estructura del assetstore sólo la carpeta donde se encuentra el archivo.
- Sólo el bundle ORIGINAL de cada ítem.
- De los items sólo los que tienen al menos 1 bitstream en el bundle ORIGINAL
- De un assetstore completo de Diciembre de 2013 se analizaron casi 19000 archivos, se caracterizan los archivos por su formato PUID (Persistent Unique Identifier).
- Se analizaron los riesgos de esos formatos.
- Como tarea colateral se verificaron las repeticiones de checksum (MD5).
- Con los casos sospechosos se generan las tareas de análisis, revisión y corrección para que los administradores de SEDICI resuelvan el problema.

Perfil en DROID

A partir del perfil se revisó el registro PRONOM para ver los riesgos de los formatos



Resource	Extension	Size	Last modif...	Ids	Format	Version	Mime type	PUID	Method
Folder: D:\Inf...			02/01/14 22...						
Folder: 100			02/01/14 21...						
63...	⚠	810,2 KB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	1,4 MB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	1 MB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	848,3 KB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	1,6 MB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	79,4 KB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	210,6 KB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	166,3 KB	20/12/13 12...	⚙	Acrobat PDF...	1.6	application/pdf	fmt/20	Signatur
63...	⚠	108 KB	20/12/13 12...	⚙	Acrobat PDF...	1.1	application/pdf	fmt/15	Signatur
63...	⚠	108 KB	20/12/13 12...	⚙	Acrobat PDF...	1.1	application/pdf	fmt/15	Signatur
Folder: 1000			02/01/14 21...						
15...	⚠	172,3 KB	20/12/13 12...	⚙	Acrobat PDF...	1.5	application/pdf	fmt/19	Signatur


“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Perfil exportado con MD5 para detección de duplicados

1801	15757	3328885	ead803a90d5b190fd4b4935e6a852fc3	1	fmt/17	applic		nt Format	1.3
1802	6355	175675	4564d6e8bc2f282435429c9560e841b1	1	fmt/17	applic		nt Format	1.3
1803	6354	180887	cc0601b8518aa7d0addc22bab2925e1	1	fmt/17	applic		nt Format	1.3
1804	6356	260190	6402659c609ce5bb4d22d585a596517	1	fmt/17	applic		nt Format	1.3
1805	6361	105889	6b4f05561604f71946f3814ed2a313ee	1	fmt/17	applic		nt Format	1.3
1806	6359	105889	6b4f05561604f71946f3814ed2a313ee	1	fmt/17	applic		nt Format	1.3
1807	6360	105889	6b4f05561604f71946f3814ed2a313ee	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1808	15834	5596903	0d02c816f3b71e08c270dc332fc580a9	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1809	6362	196539	c45cc1c6dd997d059e318859ae77ee8	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1810	6363	169421	6aa3fe9e89bce079595fad164a99424	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1811	6364	165625	c25df5f2549f1de3f8082152e5f2c8bc	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1812	6367	120563	9c1db44a3a75b067398aac160c247	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1813	6365	491302	b8769fc53e969d10e37a3a40af15f672	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1814	6366	1089885	ae988ddc448cfe7b526ca79a0cab8bd0	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1815	6372	71355	283535028f1300c050d62da17d520372	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1816	15874	503792	d2adf4cf28a2331e3fc8034a241251a0	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1817	15875	877958	1d2c9cf09361cee408def76b4cf2a4d	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1818	15877	825731	c1c6d475af3dd9c6ae887741b44ba6cc	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1819	15880	218787	a59e7f27ba35490150c4b530d25a509c	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1820	15888	631271	c1c1e03084b4bdf06a91c19d56e68fcd	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1821	15892	151251	c1788870df8b8e0defddea522a065357	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	
1822	15891	246622	28a30b03071aed0478ba12e8a6e0a68	1	fmt/17	application/pdf	Acrobat PDF 1.3 - Portable Document Format	1.3	



File count and sizes

Report field		Grouping fields	
FILE_SIZE			
Filter fields:			
Field	Operator	Values	
RESOURCE_TYPE	NONE_OF	"Folder"	

Profile	Count	Sum	Min	Max	Average
perfil	18522	26863674031	1120	701906423	1450365
Profile totals	18522	26863674031	1120	701906423	1450365

File sizes per extension

Report field		Grouping fields	
FILE_SIZE		FILE_EXTENSION	
Filter fields:			
Field	Operator	Values	
RESOURCE_TYPE	NONE_OF	"Folder"	

Profile	Count	Sum	Min	Max	Average
perfil	18522	26863674031	1120	701906423	1450365
Profile totals	18522	26863674031	1120	701906423	1450365

Group totals

Count	Sum	Min	Max	Average
18522	26863674031	1120	701906423	1450365

File sizes per PUID

Report field		Grouping fields		
FILE_SIZE	PUID	FILE_FORMAT	FORMAT_VERSION	MIME_TYPE

Reporte
en DROID
exportado

Interpretación del reporte de DROID:


SÓLO ALGUNOS ARCHIVOS

El perfil elaborado por DROID queda plasmado en el reporte adjunto en la tesis denominado "Comprehensive Breakdown", una síntesis del mismo muestra:

- **47 archivos Macromedia Flash 5**, formato que se corresponde con el PUID fmt/108 de PRONOM.
- **4 archivos Windows Bitmap 3.0**, formato que se corresponde con el PUID fmt/116 de PRONOM.
- **5 archivos MS PPT 1997-2002**, correspondiente al PUID fmt/126 de PRONOM.
- **583 archivos MPEG ½ Audio Layer 3**, correspondiente al PUID fmt/134 de PRONOM.
- **17660 archivos PDF**, de los cuales:
 - 1 archivo Acrobat PDF 1.0, formato que se corresponde con el PUID fmt/14 de PRONOM...hasta Acrobat PDF 1.7 que se corresponde con el PUID...
- **188 archivos JPEG**, formato que se corresponde con el PUID ...

Formatos-Mime Types

El gráfico representa de manera simplificada el perfil elaborado por DROID



Generación de tickets para mejora de calidad

Vistazo
Actividad
Planificación
Peticiones
Nueva petición
Calendario
Noticias
Wiki
Foros

Tarea #2649
Modificar
Monitorizar
Copiar


Depuración de ítems repetidos: Relaciones de la Sociedad Argentina de Antropología--TMDG
« Anterior | 35/64 | Siguiente »

Añadido por [Marisa Raquel De Giusti](#) hace 9 meses. Actualizado hace 7 meses.

Estado:	Resuelta	Fecha de inicio:	11 Febrero 2014
Prioridad:	Normal	Fecha fin:	
Asignado a:	 Analía Pinto	% Realizado:	100%
Categoría:	Mejora de calidad		
Versión prevista:	-		

Descripción
Citar

Repetidos: 25709 y 25710
 El 25709 tiene el artículo del 25710 y debiera tener

<http://sedici.unlp.edu.ar/handle/10915/25709>

Revistas
 →
 Relaciones de la Sociedad Argentina de Antropología
 →
 tomo 37-2
 Prácticas de consumo del alcohol entre los grupos indígenas de la frontera del sur (S. XVIII-XIX) desde la arqueología histórica

“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITORIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Tickets para items sin bitstream ni LE

items sin bitstream SeDiCI-Docs ☒ Todas las palabras ☐ Buscar

☒ Peticiones ☐ Noticias ☐ Páginas Wiki ☐ Mensajes

Aceptar

Resultados (16)

-  **Tarea #2757 (Resuelta): Completar consulta**
 A la consulta que se realizó sobre los **items** que no tienen NI **bitstream** NI link. Habría que agregarle en la respuesta ... ar las ta
 hace antes de pedir la tesis a alguien.
 29 April 2014 09:25 AM
-  **Tarea #2705 (Resuelta): Items con LINK y sin Bitstream Departamento de Economía FCE ---TMDG**
 Adjunto un archivo con todos los **items** que tenemos el LINK al departamento de Econo ... asi todos del CEDLAS. Ponerle Licenc
 07 March 2014 02:03 PM
-  **Tarea #2704 (Resuelta): Items sin Bitstream ni link --Cuestiones de Sociología--TMDG**
 Adjunto la planilla de los **items** en que nos falta PDF, pero al buscar en titu ... en la hoja de adelante que habría que sacar.*
 07 March 2014 10:22 AM
-  **Tarea #2703 (Resuelta): Items sin Bitstream ni link --Cuadernos de Lenguas Modernas--TMDG**
 Nuevamente en el conjunto adjunto hay problem ... turas Modernas (como está en el resto de los **items**) pero el item 13025 tie
 07 March 2014 10:03 AM
-  **Tarea #2702 (Resuelta): Items sin Bitstream ni link --Boletín del Instituto de Investigaciones Literarias--TMDG**
 Adjunto archivo con todos los números que nos ... ciones explicado por Lira. Corregir entonces.
 07 March 2014 09:15 AM
-  **Tarea #2700 (Resuelta): Items sin Bitstream ni link --Auster--TMDG**
<http://hdl.handle.net/10915/10214> Artículo Ce ... Poner la misma Licencia: CC By No comercial **Sin** obra derivada.
 07 March 2014 07:22 AM

Generación de tickets para mejora de calidad

SeDiCI >> SeDiCI-Docs

Búsqueda:

Vistazo Actividad Planificación **Peticiones** Nueva petición Calendario Noticias Wiki Foros

 Modificar  Monitorizar  Copiar

Tarea #2786



Migración de item con PDFs de versiones 1.0 hasta 1.3 inclusive ---TMDG

« Anterior | 7/62 | Siguiente »

Añadido por [Marisa Raquel De Giusti](#) hace 6 meses. Actualizado hace 6 meses.

Estado:	Comentarios	Fecha de inicio:	21 Mayo 2014
Prioridad:	Normal	Fecha fin:	
Asignado a:	 Carlos J. Nusch	% Realizado:	30%
Categoría:	archivos y formatos		
Versión prevista:	-		

Descripción

 Citar

Dado que las versiones 1.0, 1.1, 1.2 y 1.3 de PDF no se pueden interpretados correctamente por versiones más nuevas.

Se plantea la conversión a PDF/A1-a a través de ABBYY e incluso con la verificación y validación de Acrobat.

Se sugiere la lectura del archivo: Conversión de archivos PDFs para realizar las acciones de manera correcta. El archivo fue compartido en DRIVE a todos los del SEDICI por Paula

Se adjunta el listado total de ítems que deben ser sometidos a este proceso.

Priorizando los que tienen fulltext del listado adjunto en EXCEL.

El handle es el numerito que está antes del _ y despues de la última/

Agrego al resto de la gente que va a hacer esta tarea

 [Archivos PDFs versiones viejas.xlsx](#) (311,36 KB)  [Marisa Raquel De Giusti](#), 21 Mayo 2014 11:24 AM

 [Procedimiento de conversión de archivos a PDFa.pdf](#) (1,112 MB)  [Analia Pinto](#), 23 Mayo 2014 09:19 AM

“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Análisis de los formatos existentes

- Portable Document Format (PDF) es el mayoritario de SEDICI.
- Se realizó un análisis de los subconjuntos estandarizados de PDF.
- Se realizaron pruebas con pdfaPilot para la conversión a PDF/A.
- Se perfiló también con otras herramientas abiertas como Jhove.


Recomendaciones

- Recomendación: migrar a PDF/A1-a en su defecto PDF/A1-b.
- En el caso de los libros, la opción de optimización es sumamente importante, ya que incide en numerosos aspectos (correcta recuperación del texto en búsquedas a texto completo, óptima visualización en web, por ejemplo), por lo que debe encontrarse la mejor manera de cumplimentar ambos objetivos: que el archivo cumpla con el estándar y que quede correctamente optimizado.
- Recomendaciones sobre qué hacer en el caso de tener que generar PDF a partir de documentos de texto: DOC,DOCX,ODT,RTF.

Recomendaciones

- Tras la digitalización y generación de documentos PDF/A con OCR evitar la edición mediante Acrobat Writer .
- Utilizar estándares abiertos siempre que sea posible.
- Aplicar transformaciones en archivos de imagen, texto, audio y video.
- Almacenar y preservar por lo menos tres versiones de cada uno de los archivos ingresados al repositorio: la versión original tal y como ha sido subida, un nuevo formato normalizado y una posible migración a nuevas versiones, o a formatos abiertos.
- Generar un bundle de preservación.
- Extraer automáticamente los metadatos técnicos (FITS) y guardarlos en la base de datos acompañando al bitstream correspondiente.

El paquete de información en el OAIS




La Información descriptiva de la preservación

- La PDI de la norma OAIS está compuesta por información de procedencia, de contexto, de referencia, de integridad y de derechos.
- Esta información, de estar presente:
 - es generada por el software del repositorio (ej. procedencia)
 - se incorpora a través de tareas del flujo de trabajo de la administración.
- Para verificar la corrección de la PDI:
 - observar si estos metadatos están presentes
 - verificar que los valores son adecuados.
- Evidentemente es necesario automatizar esta tarea.

Metodología propuesta

- Desarrollo de un validador que tome la forma de una tarea de curación.
- Las tareas de curación añaden funcionalidad a DSpace.
- Se relacionan con la gestión de los objetos del repositorio, de ahí el término “curación” utilizado, homologable a “preservación”.
- Una tarea de curación en DSpace puede aplicarse a nivel ítem, colecciones o comunidades e incluso al repositorio completo.
- El propósito de las tareas de curación planteadas es efectuar el mantenimiento de ítems en el tiempo y a lo largo de todo su ciclo de vida.

Validador



Validaciones de la PDI

- **Referencia:** se evalúa validando los identificadores persistentes; para el caso de DSpace se evalúa el handle.
- **Integridad:** se evalúa utilizando el checksum; para el caso de DSpace debe validarse que el algoritmo MD5 sea correcto y que no tenga el valor que está por defecto.
- **Procedencia:** se evalúa el metadato provenance, comenzando por ejecutar una consulta que muestre el contenido de ese metadato.
- **Contexto:** se evalúa el contexto según OAIS. La información de contexto tiene como objetivo principal documentar las relaciones de la información de contenido con su medioambiente (por qué fue creada esa información de contenido y su relación con otra información de contenido).
- **Acceso:** se evalúa a partir de las licencias.

Ejemplo de regla

Un año atrás

```


/home/nelson/workspace_indigo_2/dspace-sedici/install/bin: sudo
Archivo  Editar  Ver  Marcadores  Preferencias  Ayuda

El Handle del ítem: 24688 es válido, el ítem fue evaluado con 1
La puntuación total del ítem procesado es: 1.0
El ítem: 24688 se finalizó de procesar con éxito

Procesando Ítem con id: 24719
El Handle del ítem: 24719 es válido, el ítem fue evaluado con 1
La puntuación total del ítem procesado es: 1.0
El ítem: 24719 se finalizó de procesar con éxito

Procesando Ítem con id: 24722
El Handle del ítem: 24722 es válido, el ítem fue evaluado con 1
La puntuación total del ítem procesado es: 1.0
El ítem: 24722 se finalizó de procesar con éxito

Procesando Ítem con id: 24726
El Handle del ítem: 24726 es válido, el ítem fue evaluado con 1
La puntuación total del ítem procesado es: 1.0
El ítem: 24726 se finalizó de procesar con éxito
  
```



Enfoque: DSpace

Nombre: “Verificar validez de handle”

Restricciones: el handle siempre existe en DSpace, puede ser el handle predefinido

Regla: El ítem contiene un handle válido y no se trata del handle por defecto de (123456789)


Metadato(s) asociado(s):
dc.identifier.uri
(sedici.identifier.handle)

Respuesta esperada:

✓ True → Válido

✗ False → Inválido

Ejemplo de resultados y acciones



Error #2767

Actualizar Monitorizar Copiar



Metadato sedici.rights.license ---TMDG

« Anterior | 3/140 | Siguiente »

Añadido por Marisa Raquel De Giusti hace 7 días. Actualizado hace menos de 1 minuto.

Estado:	Nueva	Fecha de inicio:	07 May 2014
Prioridad:	Normal	Fecha fin:	
Asignado a:	Ariel Lira	% Realizado:	0%
Categoría:	curation-tasks		
Versión prevista:	-		
Actualización Pendiente:	No	Complejidad:	1 - Fácil
patch:	No aplica		

“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Ejemplo de resultados y acciones

Error #2767

 Actualizar  Monitorizar  Copiar



Metadato sedici.rights.license ---TMDG

« Anterior | 3/140 | Siguiente »

Añadido por Marisa Raquel De Giusti hace 7 días. Actualizado hace menos de 1 minuto.

Estado:	Nueva	Fecha de inicio:	07 May 2014
Prioridad:	Normal	Fecha fin:	
Asignado a:	 Ariel Lira	% Realizado:	0%
Categoría:	curation-tasks		
Versión prevista:	-		
Actualización Pendiente:	No	Complejidad:	1 - Fácil
patch:	No aplica		


De los 19.946 ítems, no todos tienen el nombre correcto de la licencia, es decir, el metadato sedici.rights.license. Se encontraron 788 ítems con errores en el nombre de la licencia, problema que no se resuelve sólo con corregir esos ítems.

Items sin licencia

En relación a los 12.368 ítems sin licencia:

- Existen ítems que tienen asociada una licencia en papel (el archivo digital de éstas aún no fue realizado y/o no se ha incorporado al flujo de trabajo).
- Las licencias de distribución de SEDICI, previas a la versión 1.4 (de mayo de 2012), no obligaban a los autores a elegir licencias de uso Creative Commons, sino que solamente incluían la autorización del autor para la transformación de su obra con fines de preservación y el permiso de difusión.
- Como hoy en día se considera que todos los ítems deben tener una licencia de uso, se ha generado un ticket para corregir el problema.

Análisis de la información descriptiva



Directrices Driver

Basic element	Status	Encoding schemes
Title	M	None, free text
Creator	M	APA bibliographic writing style as in a reference list . Syntax: surname, initials (first name)
Subject	MA	Choice of keywords and classifications can be free text (preferably in English) and defined by an URI scheme (preferably info:eu-repo/classification)
Description	MA	None, free text. Recommended practice is to include an abstract in English. "Abstract" is the default interpretation to the value for dc:description
Publisher	R	None
Contributor	O	APA bibliographic writing style as in a reference list . Syntax: surname, initials (first name)
Date	M	Date ISO 8601 W3C-DTF - "Published" is the default interpretation to the value for dc:date
Type	M	Publication type and Version type can be free text (preferably in English) and defined by an URI scheme (preferably info:eu-repo/semantics).
Format	R	IANA registered list of Internet Media Types (MIME types)
Identifier	M	URI scheme, linking to persistent identifier (URN, handle, DOI), full text document or human start page.
Source	O	Guidelines for Encoding Bibliographic Citation Information in Dublin Core Metadata as in dcterms:bibliographicCitation
Language	R	ISO 639-3
Relation	O	None
Coverage	O	"Period" is the default interpretation to the value for dc:coverage Encoding: DCMI Period [http://dublincore.org/documents/2000/07/28/dcmi-period/] For more encoding schemas see Chapter 5 Use of vocabularies and semantics.
Rights	R	None
Audience	O	None. "Education level" is the default value for dc:audience.

"UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS"

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Verificaciones

item_export_2014_mar_19_1_2980.zip\1 - archivo ZIP, tamaño descomprimido 93.137 bytes

Nombre	Tamaño	Comprimido	Tipo	Modificado	CRC32
..			Carpeta de archivos		
metadata_sedici2003.xml	4.416	1.345	Documento XML	19/03/2014 02:...	8C53EBAC
metadata_sedici.xml	1.606	616	Documento XML	19/03/2014 02:...	F29F7C61
metadata_mods.xml	217	167	Documento XML	19/03/2014 02:...	0FC129B3
handle	12	14	Archivo	19/03/2014 02:...	62611031
dublin_core.xml	2.044	944	Documento XML	19/03/2014 02:...	23FB374D
contents	116	92	Archivo	19/03/2014 02:...	F1C588AA
all-0001.pdf.txt	21.653	7.132	Documento de texto	19/03/2014 02:...	FD6A39BC
all-0001.pdf	63.073	47.921	Documento Adob...	19/03/2014 02:...	749CAACD

De los metadatos descriptivos, según la sugerencia de DRIVER, son obligatorios: *Título, Creador, Fecha, Tipo e Identificador*. Los elementos *Description* que aparecen en el archivo *dublin_core.xml* y *Subject* en el archivo *metadata_sedici.xml* también serán verificados para conocer qué porcentaje de los objetos del repositorio cuentan con esta información.

Chequeo y resultados

- Todos los ítems del repositorio cumplen con Driver.
- Existen 8 metadatos vinculados a Subject en SEDICI: El único obligatorio es materias. Sólo un archivo no contaba con ninguno.
- En relación al metadato Description, existen dos metadatos en SEDICI: “Notas” y “Resumen” (opcionales). Resumen sólo es obligatorio en el autoarchivo de tesis.
- En la consulta del metadato resumen, se identificaron 4887 ítems sin resumen.

Ticket en relación al metadato resumen

Tarea #2758

 Actualizar  Monitorizar  Copiar



Items sin resumen

« Anterior | 1/52 | Siguiente »

Añadido por [Marisa Raquel De Giusti](#) hace 31 minutos. Actualizado hace 28 minutos.

Estado:	En progreso	Fecha de inicio:	30 April 2014
Prioridad:	Normal	Fecha fin:	
Asignado a:	 Analía Pinto	% Realizado:	30%
Categoría:	Mejora de calidad		
Versión prevista:	-		

Descripción

 Citar

En muchos archivos falta el metadato dc.description.abstract. Hay casi 4500 ítems que no lo tienen. Va un archivo adjunto.

 [Sin metadato resumen.csv](#)  (160 KB)  [Marisa Raquel De Giusti](#), 30 April 2014 08:34 AM

“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Evaluación realizada

- Centrada en el contenido, la representación del contenido (formato), la PDI y la información descriptiva.
- Verificación de muchos metadatos.
- Bajo el paquete de información en sus tres presentaciones (SIP, AIP y DIP) se han recorrido las tres dimensiones subyacentes en los modelos de evaluación de RIs: sistema, datos y usuarios (comunidad designada).

Experimento con SEDICI

- Se ha evaluado la totalidad de los contenidos de SEDICI afectando colecciones de revistas, artículos, tesis, imágenes, etcétera.
- La visión integral de los contenidos ha permitido detectar ítems duplicados, ítems sin localización física o electrónica, ítems sin resúmenes que dieran idea de su contenido, ítems con formatos antiguos, ítems sin licencia, ítems con licencias erróneas, etcétera.
- Se han generado 104 tickets en el gestor de incidencias de SEDICI (algunos involucran cientos y hasta miles de ítems).
- En SEDICI-Docs y en SEDICI-Dspace (p.e. migraciones).

Recomendaciones

Vinculadas a:

- Materiales nacidos digitales.
- Materiales digitalizados.
- Formatos de visualización y formatos de preservación.
- Conveniencia de formatos abiertos.
- Formas de trabajo que aseguran los formatos de preservación, por ejemplo PDF/A.
- Verificación de metadatos de la PDI y de la DI.
- Necesidad de trabajar con herramientas adicionales a DSPACE.
- Necesidad de chequeo y validaciones periódicas de los metadatos.

Trabajos futuros

- Análisis de las migraciones masivas y sus problemas para la administración.
- Selección de herramientas de migración.
- Reporte de los eventos de migración y sus responsables de modo de asegurar la trazabilidad en el ciclo de vida (evento y agente en PREMIS).


Trabajos futuros

- En relación a las posibles “capas” de las reglas, se plantean como trabajos futuros, a llevar adelante por otros integrantes de SEDICI, reglas más abstractas, pensadas más allá de que el repositorio se encuentre implementado en DSpace o en cualquier otro software para repositorios. Es decir, que se estarían considerando reglas a nivel repositorio.
- Extensión de la herramienta de validación: Implementación de un lenguaje que permita a la administración del repositorio, a través de una sintaxis sencilla, realizar controles sobre los items de manera individual, por colección, etcétera y se obtenga un reporte del estado de los items consultados.


Trabajos futuros

Introducción en el flujo de trabajo de herramientas que permitan la verificación y validación de formatos:

En la ingesta: al ingresar el SIP realizar el desempaquetado y que la herramienta de extracción de características realiza la caracterización del objeto digital.



En el AIP, se evalúa si es necesaria la migración, en caso de serlo se reingresa un nuevo AIP y metadatos.



“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITORIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

Trabajos futuros: plan de preservación

Planes de preservación en etapa de inicio del repositorio SEDICI





marisadg

Welcome to Plato 4.4! [M. Kraxner06.03.2014 13:14] X

A copy has been created: *Plan for electronic papers - marisadg's copy of. This is an example plan. The project was created for the DELOS Summer School 2008 and revised afterwards. (originally created by admin)* X
 It is marked as playground. If you want to use it for serious planning, please change this in Plan Settings. [PLATO11.03.2014 12:59]

My Plans

ID	Name	Description	Author	State	Action
506268	SEDICI Draft Preservation Plan	This is a proof related with SEDICI real preservation plan. My target here is only test this feature and after I'll see how to prepare a real preservation plan for our institutional repository SEDICI	Marisa De Giusti	Initialised	 
506321	SEDICI Draft Presevation Plan	This is a proof whose target is only know something about Plato	Marisa De Giusti	Initialised	 
506425	SEDICI Draft Presevation Plan	This is a test for exploratory reasons. The results will be incorporated it the DSPACE- SEDICI Institutional Repository.	Marisa De Giusti	Records Chosen	 
539484	Plan for electronic papers	marisadg's copy of. This is an example plan. The project was created for the DELOS Summer School 2008 and revised afterwards. (originally created by admin)	Christoph Becker, Andreas Rauber	Weights Set	 
653374	SEDICI-UNLP-001	Plan de prueba para entender la herramienta Plato. A futuro será útil para la migración en masa de documentos PDF al formato standard para preservación a largo plazo PDF/A.	Marisa De Giusti	Experiments Performed	 

“UNA METODOLOGÍA DE EVALUACIÓN DE REPOSITARIOS DIGITALES PARA ASEGURAR LA PRESERVACIÓN EN EL TIEMPO Y EL ACCESO A LOS CONTENIDOS”

Autora: Ing. Marisa R. De Giusti

Directora: Dra. Silvia Gordillo

El futuro es  y grande!

GRACIAS

Marisa R. De Giusti

marisa.degiusti@sedici.unlp.edu.ar

