

MAPS

Workflow-Tool zur Validierung und Transformation von XML Daten

Karl-Ulrich Becker, Timo Schleier (SUB Göttingen)
KIM Workshop 2019, Mannheim, 2.+3. April

Aufgaben der Fachstelle Bibliothek (METS/Mods)



- Ansprechpartner für die Datenpartner zu Fragen zum Datenformat
- Harvesten von METS/Mods-Daten über OAI
- Validierung und Reporterstellung
- Bereinigung und Anreicherung von Datensätzen
- Lieferung der Datensätze an die DDB
- Erstellung und Pflege des konzeptionellen Mappings für den Ingest in die DDB

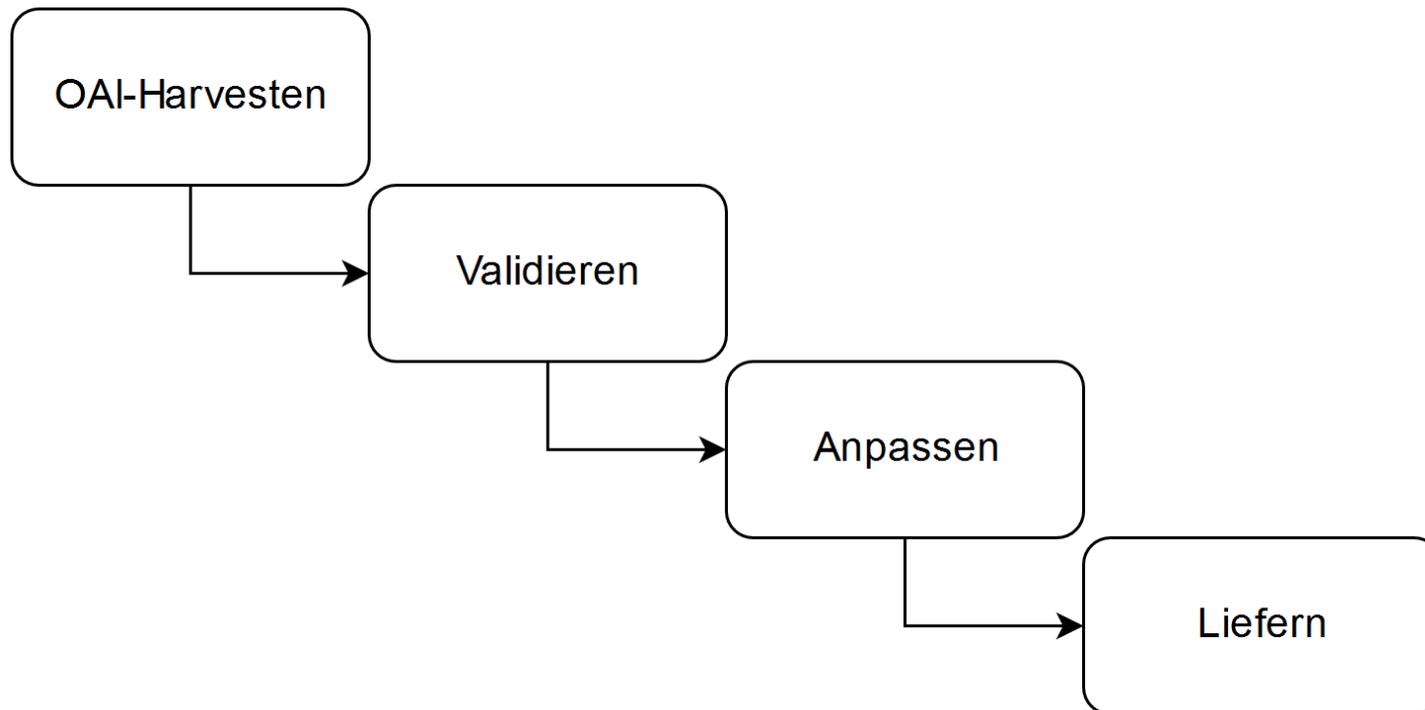
→ Viel "Handarbeit", geht das nicht besser?

Die MAPS-Idee



Anforderungen an MAPS

- Datenaggregation und Lieferung so weit automatisiert wie möglich und so flexibel wie nötig
- GUI statt Kommandozeile
- Datenbank statt Dateisystem

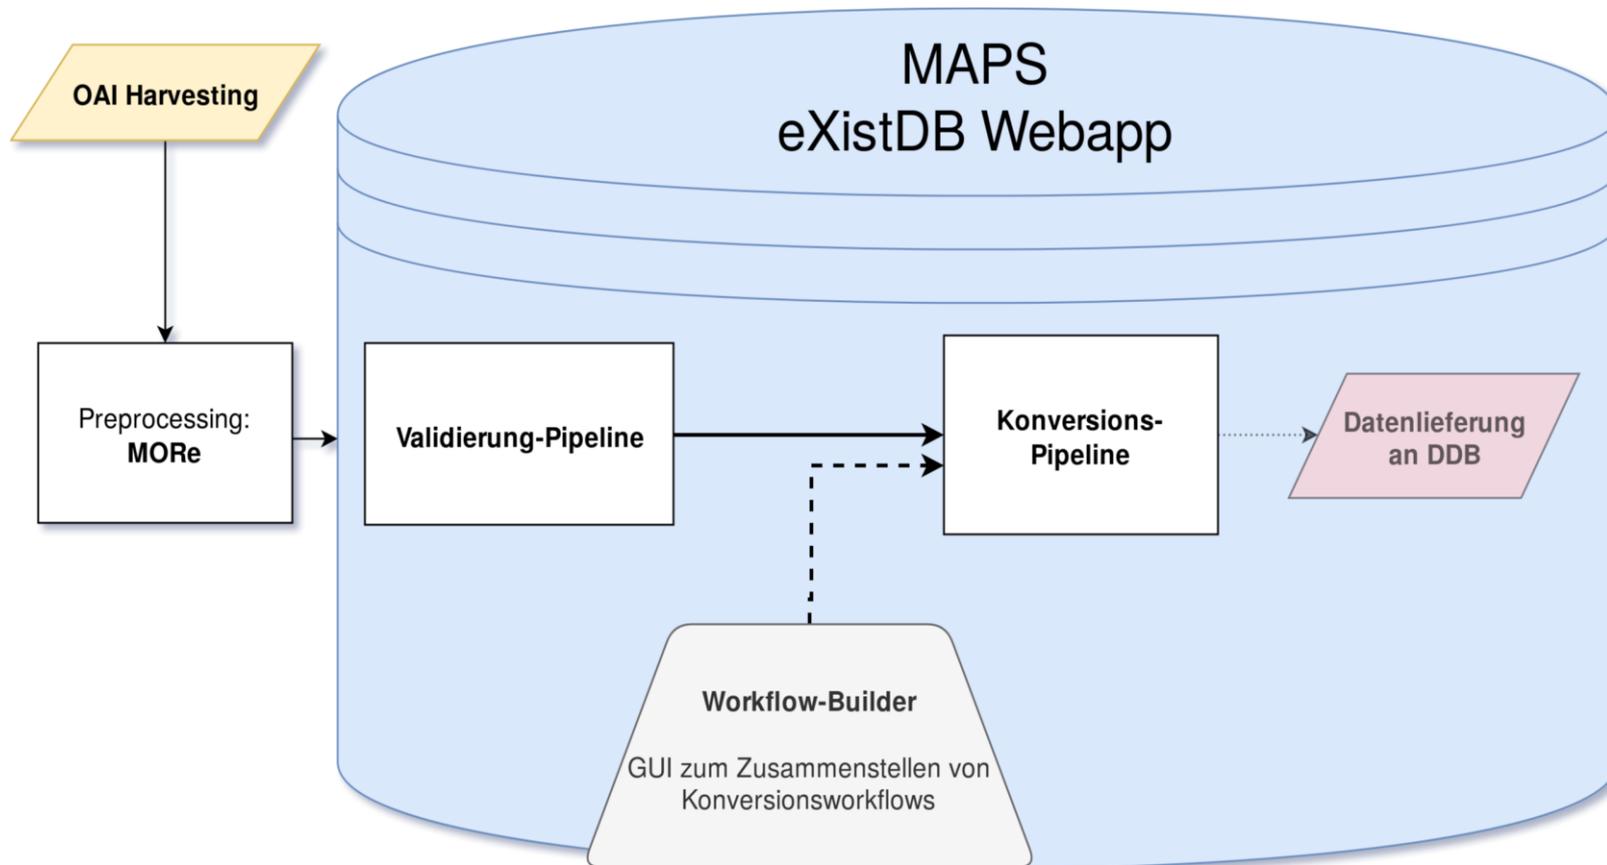


Das MAPS-System



MAPS

- Das MAPS-System besteht aus einer eXist-XML Datenbank, einer Webapp und einem externen Vorbereitungs-Tool
- Eingesetzte Technik: xQuery/XSLT/JavaScript/LaTeX

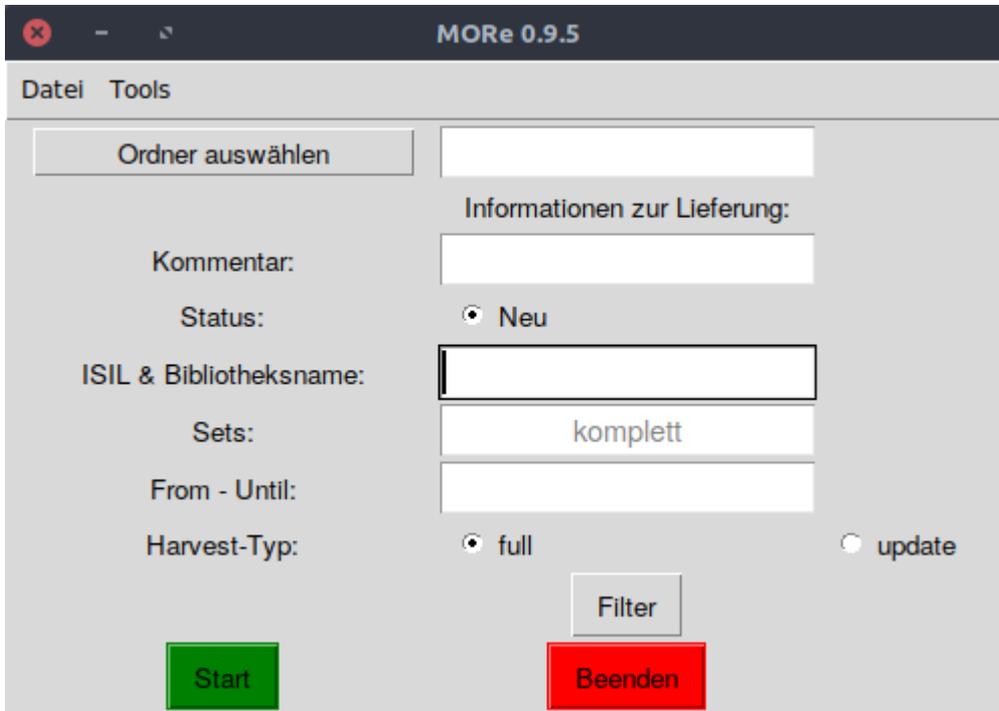


OAI Harvesting

- Harvesting schwierig: Keine zufriedenstellende Lösung (für unsere Daten)
- Vorgehen Aktuell: Harvesting mit an der SUB entwickelten Tools (erst per ListRecords, dann harvesting einzelner Dateien per GetRecord)
- z. T. spezielle Anpassungen an einzelne Schnittstellen
 - **Ziel für die Zukunft von MAPS:** OAI Harvesting (auch für große Datensätze) zuverlässig umsetzen (und in Infrastruktur einbinden)

Preprocessing: MORE

- Renamer & Ingesttool für geharvestete XML Dateien
- geschrieben in Python, mit GUI (plattformunabhängig)



The screenshot shows the MORE 0.9.5 application window. The title bar reads "MORE 0.9.5". Below the title bar, there are two tabs: "Datei" and "Tools". The main interface is a form with several fields and buttons. On the left side, there are labels for "Kommentar:", "Status:", "ISIL & Bibliotheksname:", "Sets:", "From - Until:", and "Harvest-Typ:". On the right side, there are input fields and radio buttons. The "Informationen zur Lieferung:" label is positioned above the "ISIL & Bibliotheksname:" field. The "Sets:" field contains the text "komplett". The "Harvest-Typ:" field has two radio buttons: "full" (selected) and "update". At the bottom of the form, there are three buttons: "Start" (green), "Filter" (grey), and "Beenden" (red).

DATEI Tools

Ordner auswählen

Kommentar:

Status: Neu

ISIL & Bibliotheksname:

Sets: komplett

From - Until:

Harvest-Typ: full update

Filter

Start Beenden

MORe: Funktionen

1. Benennt geharvestete METS-Dateien konsistent um, zBsp.:
`DE-3--oai_digitale_bibliothek_uni-halle_de_9994545.xml`
→ Nutzt dafür Informationen aus den Dateien und eine Konkordanzliste für die Zuordnung dv:owner zu ISIL
2. Erstellt eine XML Datei, die Informationen über die aktuell bearbeiteten Dateien enthält → "Lieferungs-XML"
3. Ingestiert in die MAPS-Webapp

In Entwicklung:

- Filterfunktion (Daten nach bestimmten Kriterien schon vor dem Ingest aussortieren)

Das Lieferungs-Konzept

- Identifiziert eine Datenlieferung und alle dazugehörigen Dateien
- Enthält Informationen zum Bearbeitungsstand und zu der Schnittstelle, den geharvesteten Sets usw.

```
<lieferung xmlns="dcg:maps" id="20190307_DE-16_Heidelberg_UB-komplett">
  <status>validiert</status>
  <sets>komplett</sets>
  <oaiUrl>http://digi.ub.uni-heidelberg.de/cgi-bin/digioai.cgi</oaiUrl>
  <fromUntil/>
  <responseDate>2019-01-28T11:23:18Z</responseDate>
  <harvestTyp>full</harvestTyp>
  <creationDate>2019-03-07T06:18:11Z</creationDate>
  <comment>test</comment>
  <supplier>DE-16_Heidelberg_UB</supplier>
  <files>
    <file fatal="no">DE-16--oai_digi_ub_uni-heidelberg_de_10.xml</file>
    <file fatal="yes">DE-16--oai_digi_ub_uni-heidelberg_de_100.xml</file>
    <file fatal="no">DE-16--oai_digi_ub_uni-heidelberg_de_1000.xml</file>
    <file fatal="no">DE-16--oai_digi_ub_uni-heidelberg_de_1001.xml</file>
    <file fatal="no">DE-16--oai_digi_ub_uni-heidelberg_de_1002.xml</file>
    <file fatal="no">DE-16--oai_digi_ub_uni-heidelberg_de_10020.xml</file>
    <file fatal="yes">DE-16--oai_digi_ub_uni-heidelberg_de_10022.xml</file>
    <file fatal="yes">DE-16--oai_digi_ub_uni-heidelberg_de_10023.xml</file>
  </files>
</lieferung>
```

Validierung & Reporterzeugung Anforderungen



- Automatische Generierung des versandfertigen Reports
- Filtern von Datensätzen mit kritischen Fehlern
- Prüfung aller Datensätze

Validierung & Reporterzeugung

Screenshot: Validierung starten

MAPS 0.5 Validierung ▾ Transformation ▾ Sonstiges ▾

Validierung

Lieferung auswählen:

20190308 DE-3 Halle ULB-ulbhalvd18 (40731 Dateien) ▾

Weiter

powered by
e:istdb

Validierung & Reporterzeugung

Screenshot: Validierung starten

MAPS 0.5 Validierung ▾ Transformation ▾ Sonstiges ▾

Validierung

Lieferung:

Schnittstellen URL:

Sets:

Datengeber:

Bearbeiter:

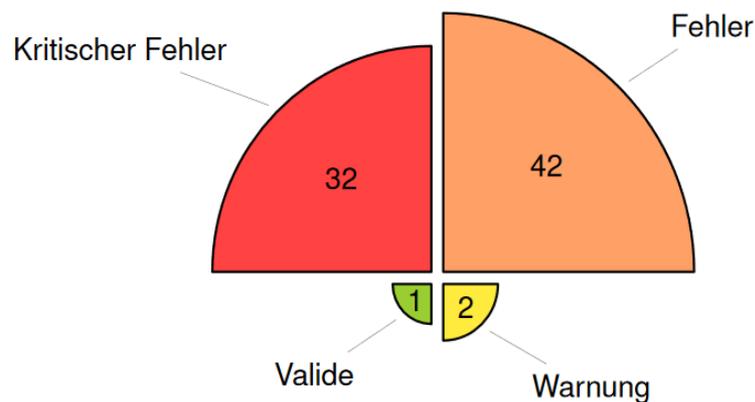
powered by


1 Übersicht

Sehr geehrte Damen und Herren,
hiermit erhalten Sie den aktuellen Analysereport Ihrer Daten. Bitte beachten Sie die aufgelisteten Fehler unter Punkt 2 und korrigieren Sie ggf. Ihre Daten, um sie korrekt und vollständig in der DDB anzeigen zu können.

1.1 Analyisierte Datensätze

- Von der OAI-Schnittstelle [https://nbn-resolving.org/urn:nbn:de:hbz:5:1-63882-p0011-8](#) wurden 77 Datensätze geharvestet.
- Es wurde folgendes Set geharvestet:
("komplett" bedeutet, dass keine Eingrenzung auf ein Set stattgefunden hat)



2.8 Kein gültiger Wert im Attribut `authority` in `mods:classification`

`mods:classification` wird in der DDB nur dann berücksichtigt, wenn es sich um Klassen aus der DDC oder der Systematik der ZDB handelt. Um dies zu kennzeichnen, muss in dem Attribut `authority` entweder "ddc" oder "zdfs" stehen. Ist dies nicht der Fall, wird `mods:classification` bei der Transformation der Daten entfernt. Die folgenden ungültigen Werte

wurden verwendet:

- ZVDD (27)
- GDZ (1)

Dieser Fehler tritt 29 mal auf:

- `oai:gdz.sub.uni-goettingen.de:PPN8876915123 mods:dmdSec = DMDLOG_0001`
- `oai:gdz.sub.uni-goettingen.de:PPN88767769151 mods:dmdSec = DMDLOG_0001`
- `oai:gdz.sub.uni-goettingen.de:PPN8845769151 mods:dmdSec = DMDLOG_0001`

→ *Zur vollständigen Liste*

Die Datensätze werden von der Fachstelle Bibliothek vor dem Einspielen korrigiert ●

2.9 `mods:dmdSec` fehlt

Die `mods:dmdSec` enthält die bibliographische Beschreibung des Werks. Innerhalb eines METS-Datensatzes muss es mindestens eine `mods:dmdSec` geben, die MODS-Daten enthält. Ist dies nicht der Fall, wird der Datensatz nicht in die DDB eingespielt.

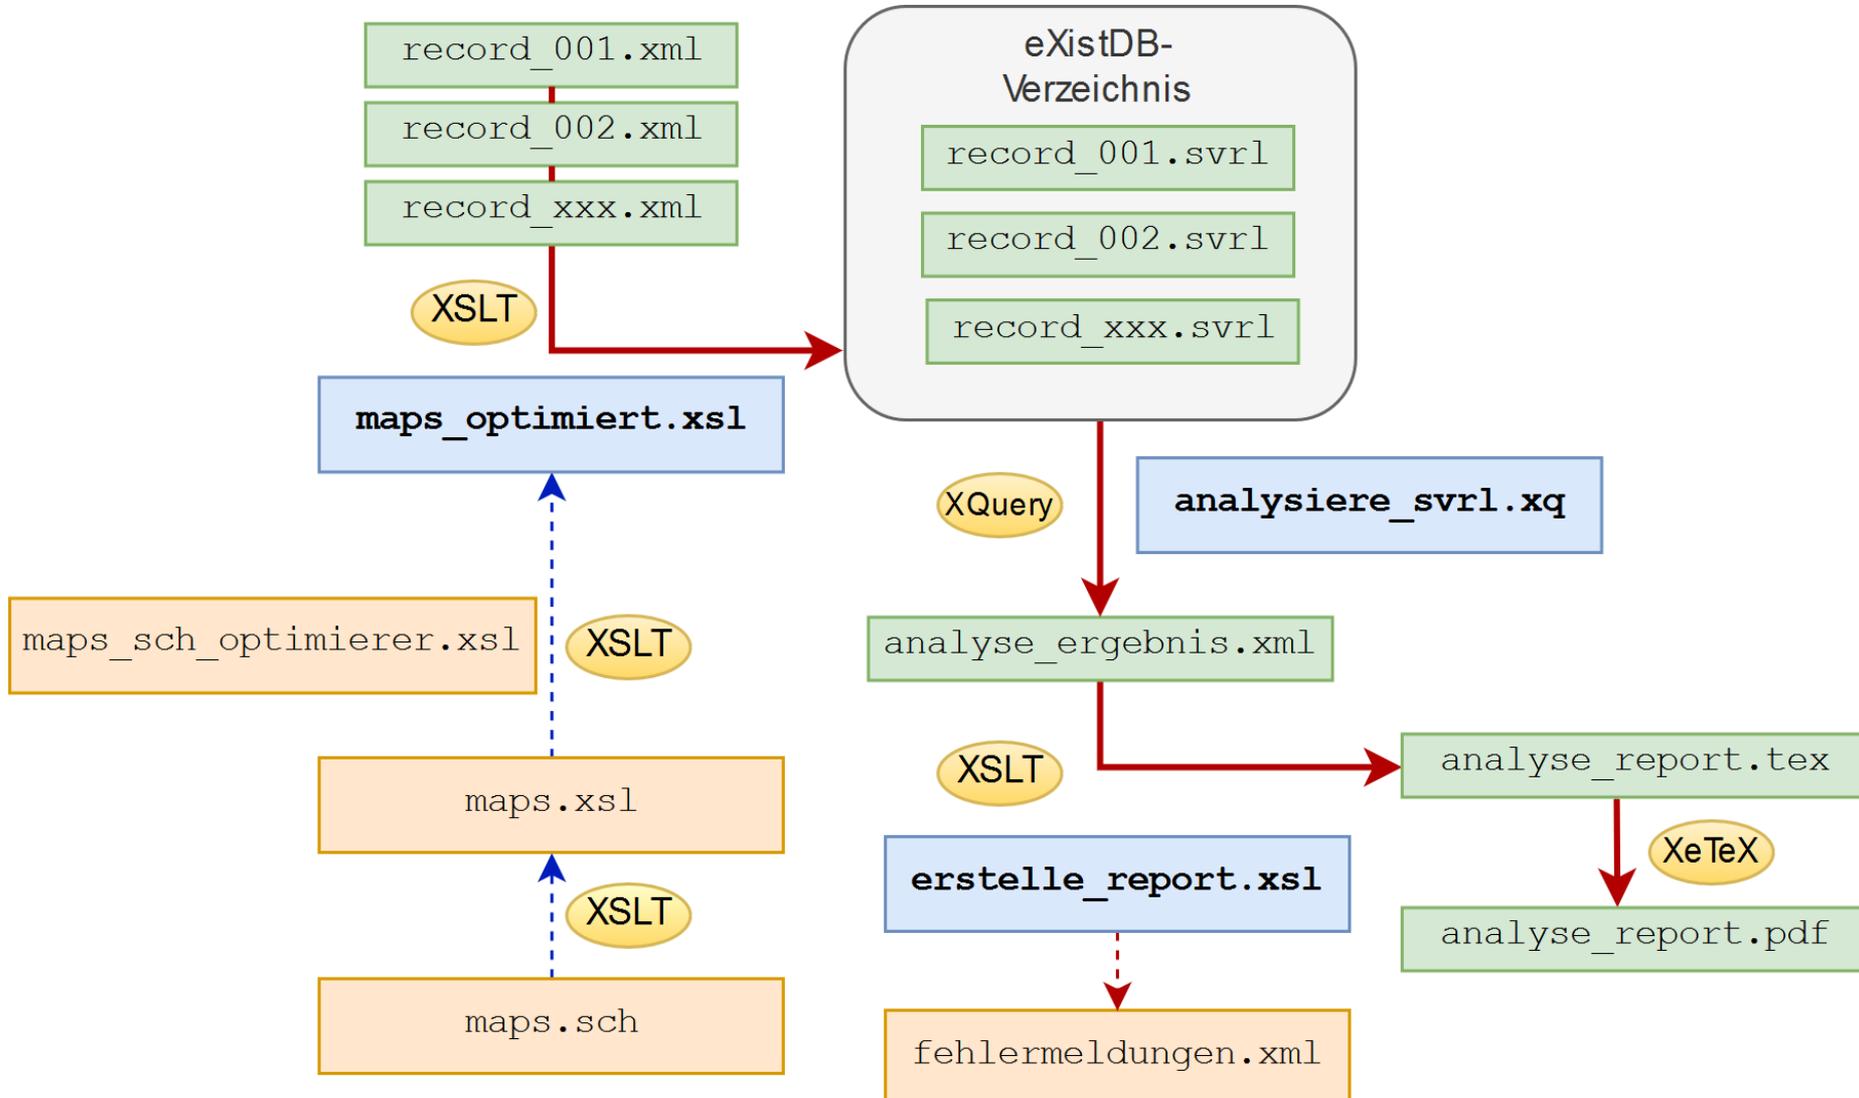
Dieser Fehler tritt 4 mal auf:

- `oai:gdz.sub.uni-goettingen.de:PPN8875569151 mods:dmdSec`
- `oai:gdz.sub.uni-goettingen.de:PPN887691513 mods:dmdSec`

→ *Zur vollständigen Liste*

Die Datensätze werden **nicht** eingespielt ●

Validierung & Reporterzeugung eXistDB-Pipeline



MAPS-Module & MAPS-Workflows

- "Baukasten für die Anpassung von Datensätzen"
 - ein MAPS-Modul...
 - ist ein XSL-Script
 - führt eine möglichst granulare Anpassung durch
 - ist ausführlich dokumentiert
 - zur Nutzung im Workflow Builder
 - "einfach" und "technisch"
 - Abhängigkeiten
 - Typisierungen
 - ein MAPS-Workflow...
 - fasst MAPS-Module geordnet zusammen
 - ist wiederverwendbar und leicht anpassbar
- Vereinfachung des konzeptionellen Mappings durch teilweise Verlagerung des technischen Mappings zur Fachstelle

MAPS-Module & MAPS-Workflows

Screenshot: Workflow Builder

Transformation ▾ Sonstiges ▾

MAPS Workflow Builder

Name des Presets:

Beschreibung:

Bearbeiter:

[Speichern](#) [Duplizieren](#) [Laden](#) [Neustarten](#) [Löschen](#)

general_add_license_metadata 	DE-109_add_license_reproduction 
dwork_remove_relatedItem_dwork_work 	DE-17_add_sponsor 
general_add_name_displayform 	DE-16_copy_license_reproduction 
DE-1_add_license_reproduction 	DE-18_add_sponsor 
	DE-1_add_license_reproduction 
	DE-21_add_sponsor 
	DE-21_copy_license_reproduction 
	DE-38_add_license_reproduction 
	DE-5_add_sponsor 

Lieferung an die DDB

- Validierung vor der Lieferung
- Ziel: Validierte und bereinigte Initial- und Updatelieferungen aus MAPS heraus an die DDB senden
- Redundante Datenhaltung immer des aktuellsten Datenbestands
- Ausblick: DDB holt sich die Daten über unsere zukünftige OAI-Schnittstelle

Zu guter Letzt...



Lessons Learned...

- Warum eXistDB?
 - Beschränkung auf 2 Milliarden nodes in BaseX
 - Einfache Umsetzung von Webapps
- eXistDB Eigenheiten
 - Umständliche Systemupdates (dafür gute App-Updates)
 - mittelmäßiges Taskmanagement
 - Anpassen von Indizes schwierig
 - in der Anfangsphase durchaus viele Abstürze
 - schwieriges Debugging
 - XSLT Unterschiede zu "Saxon"
 - Performance: Mittelmäßig
- (zu) große Tex-Dateien
- Konzeption der Dokumentation der MAPS-Module

Die wichtigste Frage zum Schluss: Was bedeuten eigentlich MAPS & MORE?



- **M**etadata **A**ggregation and **P**rocessing **S**ystem
- **METS OAI Re**namer

Vielen Dank für die
Aufmerksamkeit

