

RFC - Workflow Rosetta - Archivematica Migration

Inhaltsverzeichnis

| | |
|---|----|
| Status | 1 |
| Begriffe | 1 |
| Ist Stand | 2 |
| Soll Stand | 2 |
| Migrationsvoraussetzungen | 3 |
| Workflowszenarien | 3 |
| Modulübersicht | 3 |
| Erstingest | 5 |
| MDUpdate | 6 |
| AIPUpdate | 6 |
| Access | 7 |
| Migration | 7 |
| Zustandsdiagramm | 8 |
| Versionierung der AIPs in Archivematica | 9 |
| AIPs in Rosetta | 9 |
| AIPs in Archivematica | 9 |
| Algorithmus zur Versionierung | 10 |
| Abschätzung Implementierung | 11 |
| Erstingest | 11 |
| MDUpdate | 12 |
| AIP-Update | 12 |
| Access | 12 |
| AIP-SIP-Transfer | 12 |
| Steuerung AIP-SIP-Transfer | 13 |
| Offene Fragen | 13 |
| Quellen | 13 |

Status

Proposed (Entwurf)

Begriffe

- IE - intellektuelle Einheit oder digitales Objekt, welches dauerhaft nutzbar gehalten werden soll

- SIP - Einlieferungspaket für die Aufnahme von intellektuellen Einheiten in das SLUBArchiv
- DIP - Auslieferungspaket für die Ausspielung von intellektuellen Einheiten aus dem SLUBArchiv
- AIP - Archivpaket, welches die Aufbewahrung der intellektuellen Einheit sicherstellt
- ErstIngest - erstmalige Einlieferung einer intellektuellen Einheit mittels Einlieferungspaket (SIP) in das SLUBArchiv
- Metadatenupdate - Aktualisierung der (idR.) deskriptiven Metadaten einer intellektuellen Einheit, die bereits im SLUBArchiv als Archivinformationspaket (AIP) gespeichert vorliegt. Es entsteht im SLUBArchiv eine neue Version des Archivinformationspakets.
- AIPUpdate - Ergänzungslieferung einer intellektuellen Einheit, die bereits im SLUBArchiv als Archivinformationspaket (AIP) gespeichert vorliegt. Dabei können Dateien hinzugefügt, gelöscht oder ersetzt werden. Es entsteht im SLUBArchiv eine neue Version des Archivinformationspakets.
- Archivinformationssystem - Software, die eine Implementierung des OAIS-Modells zum Zwecke der Langzeitverfügbarhaltung von intellektuellen Einheiten darstellt.
- Führendes System - System, welches die Datenhoheit über eine intellektuelle Einheit hat. Sobald diese als Archivinformationspakete im SLUBArchiv vorliegen, wird das Archivinformationssystem zum führenden System
- Submission Application - Software, die die Schnittstellen zwischen dem Archivinformationssystem und dem Produzenten, sowie Konsumenten implementiert.
- AIP-AIP-Transfer - Bezeichnet den Austausch von Archivinformationspaketen zwischen Langzeitarchivsystemen unabhängig von notwendigen Zwischenschritten [\[ar27\]](#)

Ist Stand

Die SLUB betreibt Rosetta von Exlibris Group als Archivinformationssystem. Die Submission Application ist in der Lage

- SIPs als BagIt einzulesen und diese in Rosetta SIPs zu transformieren
- Rosetta DIPs einzulesen und diese in BagIt basierte DIPs auszugeben
- mithilfe der API von Rosetta festzustellen, ob Vorgänge bereits im Archiv sind
- zwischen Erstingest, reinem Metadatenupdate und AIPUpdate zu unterscheiden

Es existieren produktive Workflows für Kitodo und Mediathek, sowie für das LfULG und die UBL. Der Workflow für die Fotothek wird nicht auf Rosetta, sondern auf Archivemata basieren.

Soll Stand

Die SLUB betreibt Archivemata von Artefactual als Archivinformationssystem. Das Archivinformationssystem Rosetta von Exlibris Group ist abgeschaltet. Die AIPs aus diesem System sind per Verzeichnispfad erreichbar.

Es existieren produktive Workflows für Kitodo, Mediathek und Fotothek, sowie für das LfULG und

die UBL.

Migrationsvoraussetzungen

Es gelten folgende Voraussetzungen:

- Der Produktivbetrieb von Archivemata ist gesichert.
- Die bestehende Submission Application wird weiterhin verwendet.
- Es existiert eine Datenbank, die alle AIPs des Rosetta-Systems kennt und Abfragen darüber möglich macht. Dies ist via *Exit-Strategie*[\[es\]](#) gewährleistet.

Workflowszenarien

Modulübersicht

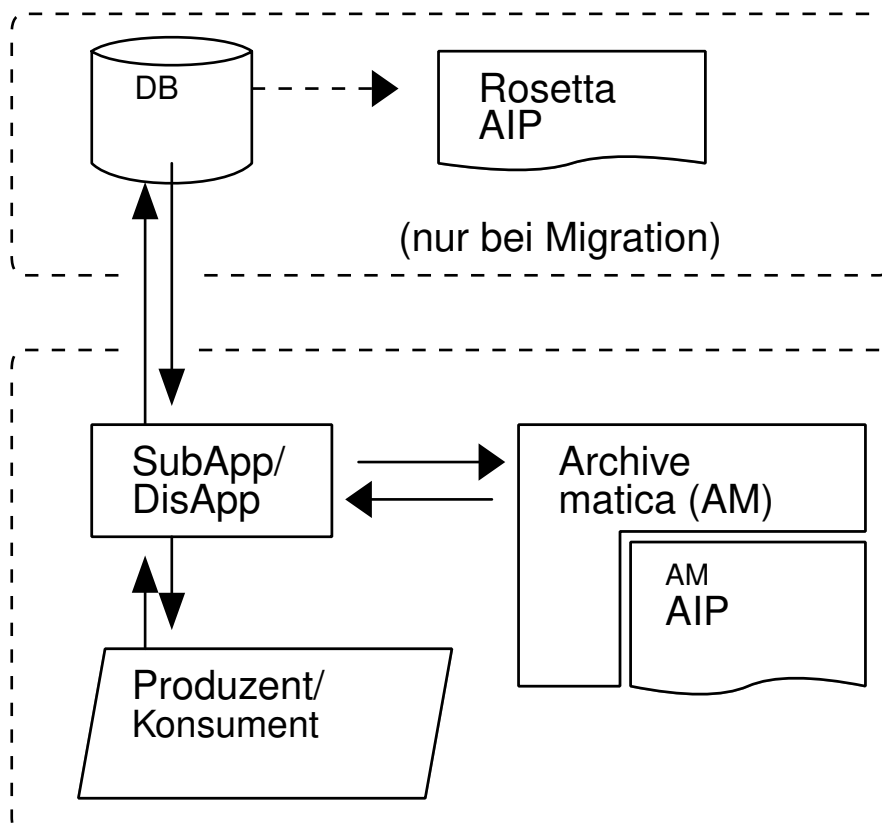


Abbildung 1. Zusammenwirken der Module

HINWEIS

Für den Workflow Fotothek entfällt der Zugriff auf die DB für Zugriff auf Rosetta-AIP.

Im folgenden die Ablaufpläne innerhalb der SubApp.

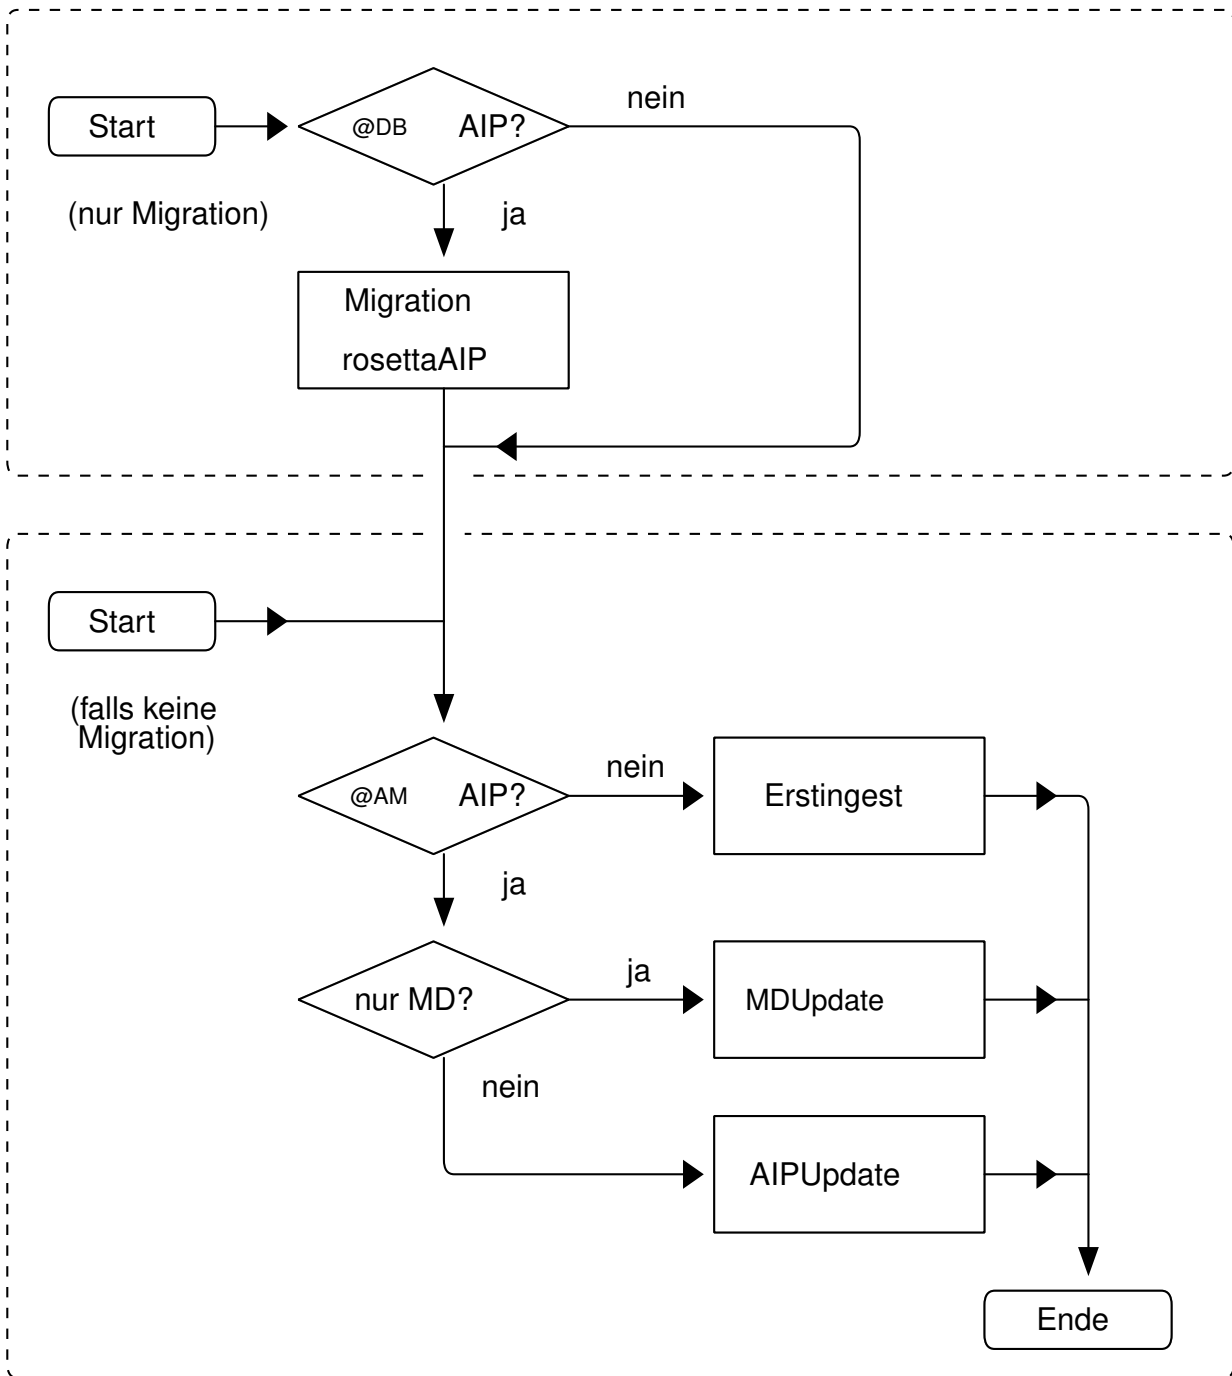


Abbildung 2. Ablaufplan Ingest

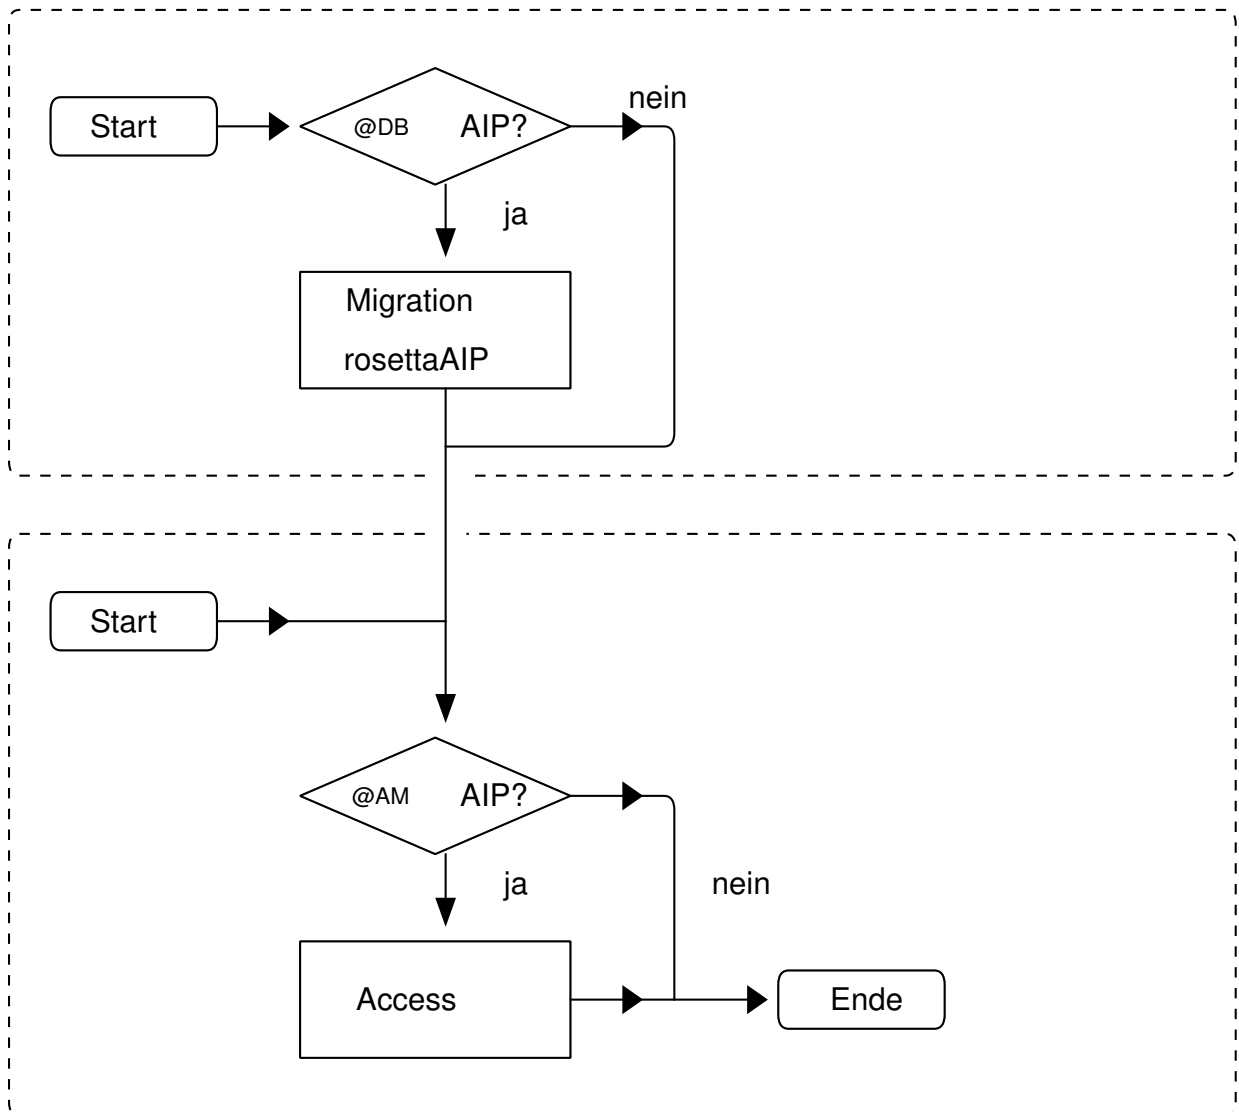


Abbildung 3. Ablaufplan Access

Erstingest

Vorbedingungen im Falle der Rosetta-Archivematica-Migration

- SubApp fragt DB, ob Rosetta AIP zu *externalID* existiert
 - Wenn ja, dann siehe [\[Migration\]](#), danach weiter mit 1.

Vorbedingungen

- SubApp fragt Archivematica, ob AIP zu *externalID* existiert
 - Wenn ja, dann siehe [\[MDUpdate\]](#) oder [\[AIPUpdate\]](#)
 - Wenn nein, es existiert kein AIP zu *externalID*

Folgende Schritte sind notwendig

1. SubApp erstellt Archivemata spezifisches SIP
2. SubApp löst Ingestierung dieses SIPs aus

Nachbedingungen

- Es existiert in Archivemata ein AIP mit *externalID*

MDUpdate

Vorbedingungen im Falle der Rosetta-Archivemata-Migration

- SubApp fragt DB, ob Rosetta AIP zu *externalID* existiert
 - Wenn ja, dann siehe [\[Migration\]](#)

Vorbedingungen

- SubApp fragt Archivemata, ob AIP zu *externalID* existiert
 - Wenn nein, dann siehe [\[Erstingest\]](#)
- SubApp bestimmt die letzte Version des AIP
- SubApp gleicht Dateien der IE im SIP mit dieser AIP in Archivemata ab
 - Wenn Unterschiede, dann siehe [\[AIPUpdate\]](#)
- Es existieren keine Unterschiede in Dateien des IEs der SIP

Folgende Schritte sind notwendig

1. SubApp löst MDUpdate in Archivemata aus

Nachbedingungen

- Es existiert in Archivemata ein AIP mit *externalID* und geänderten Metadaten.

AIPUpdate

Vorbedingungen im Falle der Rosetta-Archivemata-Migration

- SubApp fragt DB, ob Rosetta AIP zu *externalID* existiert, wenn ja
- Erstingest alter AIP, siehe [\[Migration\]](#)
- anschliessend AIPUpdate via SIP

Vorbedingungen

- SubApp fragt Archivemata, ob AIP zu *externalID* existiert

- Wenn nein, dann siehe [\[Erstingest\]](#)
- SubApp bestimmt die letzte Version des AIP
- SubApp gleicht Dateien der IE im SIP mit dieser AIP in Archivemata ab
 - Wenn keine Unterschiede, dann siehe [\[MDUpdate\]](#)

Folgende Schritte sind notwendig

1. SubApp löst AIPUpdate in Archivemata aus

Nachbedingungen

- Es existiert in Archivemata ein weiteres AIP mit *externalID*.
- Dieses AIP enthält einen Verweis auf seinen Vorgänger

Access

Vorbedingungen im Falle der Rosetta-Archivemata-Migration

- DisApp fragt DB, ob Rosetta AIP existiert
 - Wenn ja, dann siehe [\[Migration\]](#)

Vorbedingungen

- Es existiert eine AIP zu *externalID* in Archivemata

Folgende Schritte sind notwendig

1. DisApp löst Access in Archivemata aus

Nachbedingungen

- Es existiert ein DIP mit *externalID*

Migration

Basis der Migration ist das Modell "AIP → SIP → AIP" Transfer[\[ar\]](#). Dazu werden alle relevanten Teile der rosetta-AIP als IE betrachtet:

IE mit Dateien der Rosetta AIP, Variante "gepackt"

```
|— V1-FL194620.tif
|— V1-FL194621.tif
|— V1-FL194622.tif
|— V1-FL194623.tif
|— V1-FL194624.tif
|— V1-FL194625.xml
|— V1-FL194626.xml
|— V1-FL194627.xml
```

```
├─ V1-FL195611.tif
├─ V1-FL195612.tif
├─ V1-FL195613.tif
├─ V1-IE194618.xml ①
├─ V2-IE194618.xml
├─ V3-IE194618.xml
├─ V4-IE194618.xml ②
```

① Erste Version des Rosetta AIPs

② Vierte Version des Rosetta AIPs

HINWEIS

In der Fachsitzung vom [2021-07-28](https://intranet.slub-dresden.de/display/LZA/LZA+Fachsitzung+2021-07-28) [<https://intranet.slub-dresden.de/display/LZA/LZA+Fachsitzung+2021-07-28>] wurde sich darauf verständigt, dass im Falle des Nachweises aller rosetta-AIP-Versionen diese alle vollständig als eine IE zusammengepackt nach Archivematica migriert werden.

Für die Variante "Zusammenpacken" spricht die mögliche Deduplizierung von Dateien.

Vorbedingungen

- Es existiert eine Rosetta AIP zu *externalID*
- Es existiert keine AIP zu *externalID* in Archivematica

Folgende Schritte sind notwendig

1. SubApp bereitet SIP für AIP-AIP-Transfer vor
2. SubApp löst Erstingest in Archivematica aus
3. SubApp löscht AIP in DB

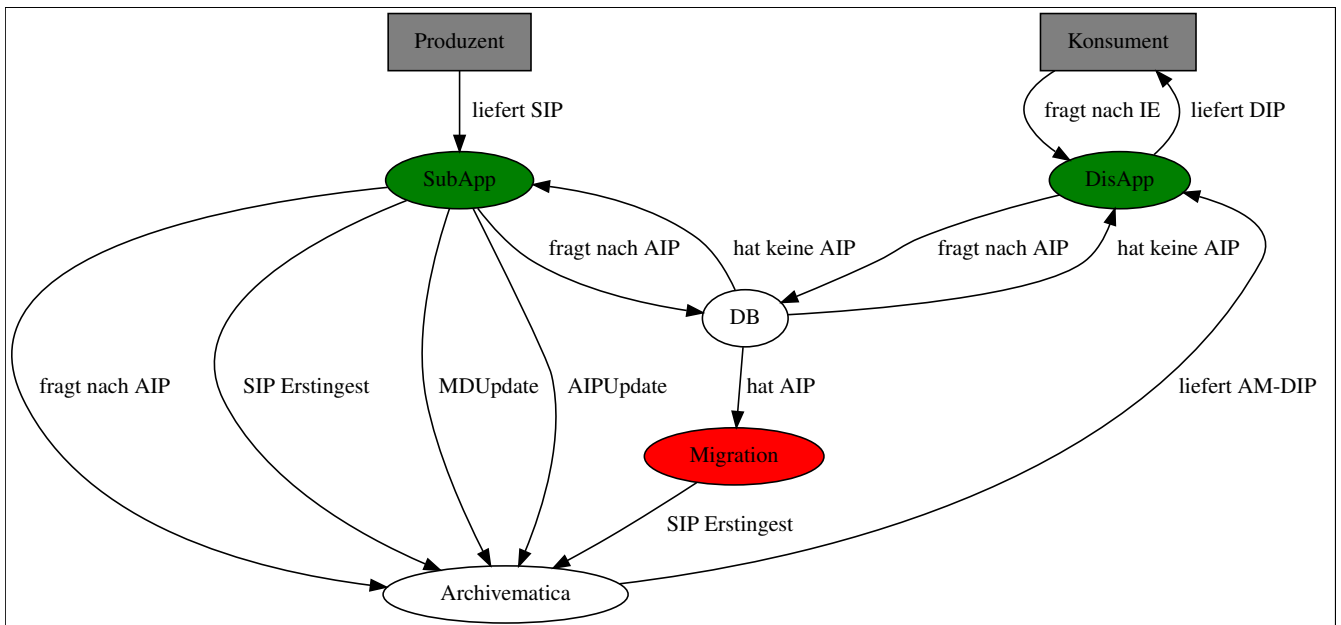
Nachbedingungen

- Es existiert ein AIP mit *externalID* in Archivematica
- Dieses AIP enthält einen Verweis auf seine Migration
- Es gibt in DB keinen Eintrag mehr für AIP mit external ID

Zustandsdiagramm

HINWEIS

Das Zustandsdiagramm ist ohne Fehlerzustände dargestellt.



Der Zustand "Migration" ist ebenfalls Teil der SubApp.

Versionierung der AIPs in Archivemata

Archivemata verfolgt ein anderes Konzept als Rosetta, was die Speicherung von AIPs betrifft.

AIPs in Rosetta

[rosettaaip] | /home/romeyke/git/Richtlinien-und-Spezifikationen-SLUBArchiv/rosettaaip.svg

Abbildung 4. Aufbau AIP in Rosetta

- ① Versionsinformation und IE PID nach Schema "Vxx-IEyyyyyy.xml", mit xx - Version, yyyyyy - PID
- ② Versionsinformation und File PID nach Schema "Vxx-FLyyyyyy.zzz", mit xx - Version, yyyyyy - PID, zzz - Dateiendung

Rosetta speichert eine IE-XML, die mehrere Repräsentationen enthalten kann. Jede Repräsentation verweist dabei auf mehrere Dateien. Diese entsprechen dem eigentlichen digitalen Objekt, das IE-XML bestimmt dabei, was zum AIP gehört.

Die Versionierung erfolgt in Rosetta so, dass jede neue Version des AIP eine neue IE-XML Datei erhält. Nur wenn neue Dateien zB. bei einem AIPUpdate hinzukommen, dann erhalten diese je eine eigene FILEPID. Bereits bestehende Dateien werden nicht angetastet (siehe [exlibris]).

AIPs in Archivemata

In Archivemata werden AIPs in einer BagIt-Struktur ([bagit]) gespeichert. Dabei enthält das payload-Verzeichnis *data* die eigentliche IE.

Archivemata kennt dieses Konzept der Versionierung nicht.

[archivemataaip] | /home/romeyke/git/Richtlinien-und-Spezifikationen-

SLUBArchiv/archivematicaaip.svg

Abbildung 5. Aufbau eines AIP in Archivemata (stark vereinfacht)

- ① *bag-info.txt* enthält Metadaten über das Bag
- ② der Ordner *data* enthält die eigentliche IE

Algorithmus zur Versionierung

Verwendete Schlüssel in *bag-info.txt*

- *SLUBArchiv-previous-AIP* - enthält AIP-ID des aktuellen AIS (entspricht: UUID)
- *SLUBArchiv-migrated-AIP* - enthält AIP-ID des vorherigen AIS (entspricht: IE-PID)
- *SLUBArchiv-origin-AIS* - enthält Bezeichner des vorherigen AIS (hier: Rosetta)

Variante verkettete Liste

Als Ansatz wird eine verkettete Liste gewählt.

Es gilt:

- hat ein AIP keinen Vorgänger, so liegt AIP in Version 1 vor (ErstIngest)
- hat AIP einen Vorgänger, so liegt AIP in Version n+1 vor (AIPUpdate)

[versions] | /home/romeyke/git/Richtlinien-und-Spezifikationen-SLUBArchiv/versions.svg

Abbildung 6. Versionsgraph

Die Vorteile liegen darin, dass keine Metadatenupdates für bereits existierende AIPs notwendig werden. Es sind nur wenige Metadaten für die Versionsverwaltung notwendig

Dieses Prinzip kann sowohl für AIPUpdates in Archivemata, wie auch zur Abbildung der Migration aus Rosetta benutzt werden.

Dazu werden in *bag-info.txt* die Schlüssel

- *SLUBArchiv-previous-AIP* für AIPUpdates
- *SLUBArchiv-migrated-AIP* und *SLUBArchiv-origin-AIS* für AIP-AIP-Transfers (Migration)

genutzt.

Beispiel 1. Beispiel AIP Update

1. Frage Archivemata nach AIP mit spezifischer *externalID*
2. Wenn AIP existiert, verwende dessen AIP-ID als Wert für *SLUBArchiv-previous-AIP* in *bag-info.txt*.

Beispiel 2. Beispiel AIP-AIP-Transfer

1. Frage DB nach (Rosetta) AIP mit spezifischer *externalID*
2. Wenn AIP existiert,
 - verwende dessen IE-PID als Wert für *SLUBArchiv-migrated-AIP*
 - setze *SLUBArchiv-origin-AIS* auf *Rosetta*

Da in der Regel nur auf die letzte Version zurückgegriffen wird, reicht obige Angabe aus.

In seltenen Fällen kann es nötig sein, AIPs auf alte Versionen zurückzusetzen.

Beispiel 3. Beispiel Liste aller AIP Versionen

1. Frage Archivemata nach AIPs mit spezifischer *externalID*
2. Wenn AIP nicht existiert, Abbruch
3. Bestimme die AIP ohne *previous-AIP* in *bag-info.txt* → *\$prev*
4. Wiederhole rekursiv bis leere Liste:
 - Bestimme AIP mit *SLUBArchiv-previous-AIP* == *\$prev*

Beispiel Liste aller AIP Versionen (Perl)

```
sub get_all_aip_versions ($external_id) {  
    my @matches = get_aip_ids_matching( $externalid );  
    return if 1 == @matches;  
    return sort { $a->{'previous-AIP'} eq $b->{'AIPid'} } @matches;  
}
```

Beispiel 4. Beispiel Setze auf n-te AIP Version zurück

1. Frage Archivemata nach AIP, merke dessen AIP-ID
2. Aus Liste der AIPs, bestimme AIP auf das zurückgesetzt werden soll
3. Hole AIP
4. Verwende die gemerkte ID als Wert für *SLUBArchiv-previous-AIP* in *bag-info.txt*

Abschätzung Implementierung

Erstingest

Abfrage DB

Die Abfrage der DB ist trivial. Die DB steht als SQLite-DB zur Verfügung. Es wird nur auf Existenz der AIP durch Abfrage von ExternalID + External Workflow gefragt.

Für den Workflow Fotothek entfällt dieser Schritt. Er wird implementierungstechnisch nicht extra behandelt werden.

Aufwand geschätzt: 1 PT Entwicklung, 1PT Test

Abfrage Archivematica, ob Erstingest

Dies könnte über eine Such-Abfrage erfolgen [\[amsearch\]](#).

Aufwand geschätzt, 1 PT Entwicklung, 1PT Test

Ingestierung in Archivematica

Es muss ein AM-spezifisches BagIt gebaut werden. Dieses Bag wird durch Aufruf Webservice Archivematica übermittelt. In der Submission Application müssen dazu neue EventCallbacks angelegt werden

Aufwand geschätzt, 5 PT Entwicklung, 8PT Test

MDUpdate

Siehe [\[slub1\]](#) und [\[ameventimport\]](#)

In der Submission Application müssen dazu neue EventCallbacks angelegt werden.

Zur Zeit keine Schätzung möglich.

AIP-Update

Es muss die Archivematica-ID des AIP ermittelt werden, dann wird ein neues Bag für Archivematica erzeugt und die notwendigen Ergänzungen in der *bag-info.txt* vorgenommen. Es müssen in der Submission Application neue EventCallbacks angelegt werden.

Aufwand geschätzt, 5 PT Entwicklung, 8PT Test

Access

Es muss die Archivematica-ID des AIP ermittelt werden, dann wird über WebAPI der Access in AM ausgelöst (siehe [\[amdownload\]](#)) und das DIP gebaut.

In der Submission Application müssen dazu neue EventCallbacks angelegt werden.

Aufwand geschätzt, 3 PT Entwicklung, 4PT Test

AIP-SIP-Transfer

Es muss das AIP vom Dateisystem von Rosetta geholt und als Bag für Archivematica gebaut werden (entspricht AIP-SIP-Transfer). Es muss die Migration als PREMIS-Event erzeugt werden. Danach wird es wie Erstingest behandelt. Im Erfolgsfall muss der Eintrag in DB gelöscht werden.

In der Submission Application müssen dazu neue EventCallbacks angelegt werden.

Aufwand geschätzt, 5 PT Entwicklung, 8PT Test

Steuerung AIP-SIP-Transfer

Folgende Komponenten können den AIP-SIP-Transfer triggern:

- Submission Application im Falle eines MDUpdate
- Submission Application im Falle eines AIPUpdate
- Dissemination Application im Falle einer DIP-Anfrage und nicht-Vorhandensein in Archivemata
- Transferscript für parallele, dauerhaft laufende Migration

Um die Steuerung zu vereinfachen, wird die Datenbank (aus Exitstrategie) mitgenutzt. Dazu erhält sie eine Tabelle migrateAIP mit der Zuordnung IEPID → TransferState. TransferState ist einer der folgenden Werte:

- requested → das AIP soll zeitnah transferiert werden
- prepared → das AIP wurde als SIP vorbereitet
- running → das AIP wird als SIP eingested

Wenn der Transfer erfolgreich war, wird das AIP komplett aus DB entfernt.

Aufwand geschätzt, 3 PT Entwicklung, 3PT Test

Offene Fragen

- ~~Gibt es in Archivemata eine Möglichkeit alle AIPs zu bestimmen, die in *bag-info.txt* die gleiche *externalID* benutzen und diese nach Datum zu sortieren?~~ Antwort: ja, über Anfrage Elasticsearch würde man für die Frage nach AIP den neuesten Eintrag verwenden (und auf den nicht referenziert wird)
- ~~Gibt es Möglichkeiten in Archivemata beim Ingest bestimmte PREMIS Events mitzugeben? Wenn ja, könnte man die Versionsinformationen zusätzlich über Events in das entstehende AIP eintragen.~~ Ja, siehe → Siehe [ameventimport]
- An welchen Stellen ist PT Schätzung unrealistisch?

Quellen

- [] Übertragbarkeit von Archivinformationspaketen zwischen Langzeitarchivsystemen als Teil der Exit-Strategie, Andreas Romeyke, 2016-10-17, http://andreas-romeyke.de/bkm/romeyke_masterarbeit2016.pdf, Definition 2.4.5, S.27
- [] SlubArchiv.digital: Exit-Strategie Rosetta. , Techn. Ber., Sächsische Landesbibliothek – Staats- und Universitätsbibliothek Dresden (SLUB), v1.3.4, 2017-10-18., url: <https://slubarchiv.slub->

dresden.de/fileadmin/groups/slubsite/slubarchiv/SLUBArchiv_Exit_Strategie_v1.3.4.pdf

- [] Ex Libris Documentation Department (Hrsg.): Rosetta AIP Data Model, Englisch, Version 5.0, DNX Model auf Seite 43ff., ExLibris Group, 16. März 2016, url: https://knowledge.exlibrisgroup.com/@api/deki/files/39700/Rosetta_AIP_Data_Model.pdf
- AIP re-ingest, Englisch, in: Artefactual Systems Inc. (Hrsg.), 28. Apr. 2016, url: https://wiki.archivematica.org/AIP_re-ingest, ArchivematicaWiki.
- Transfer, Englisch, Version 1.5, in: Artefactual Systems Inc. (Hrsg.) 2016, url:<https://www.archivematica.org/en/docs/archivematica-1.5/user-manual/transfer/transfer/>[], Archivematica Dokumentation.
- [] Kunze, J. u. a.: The BagIt File Packaging Format, Englisch, Techn. Ber., RFC 8493, Internet Engineering Task Force (IETF), 2020-01-21, url: <https://datatracker.ietf.org/doc/rfc8493/>
- [] Bestandsaufnahme existierender Suchfunktionen, Intranet der SLUB, 2021-06-14, <https://intranet.slub-dresden.de/pages/viewpage.action?spaceKey=LZA&title=Bestandsaufnahme+existierender+Suchfunktionen>
- [] AM Test - Reporting, Intranet der SLUB, 2021-06-14, <https://intranet.slub-dresden.de/display/LZA/AM+Test+-+Reporting>
- [] Importing event metadata with premis.xml, Artefactual Systems Inc. (Hrsg.), 2021-06-14, url: <https://www.archivematica.org/en/docs/archivematica-1.12/user-manual/transfer/import-metadata/#premis-xml>, ArchivematicaWiki.
- [] Download Package, , Artefactual Systems Inc. (Hrsg.), 2021-06-14, url: https://wiki.archivematica.org/Storage_Service_API#Download_package, ArchivematicaWiki.
- [] Ausschreibung „Softwareentwicklung für das Archivinformationssystem Artefactual Archivematica – Erweiterung der Funktionalität für Metadaten-Import, Metadaten-Aktualisierung und Metadatenuche“, SLUB intern, 2021-03-11