

Historisch

Kulturwissenschaftliche

Informationsverarbeitung

Digitales Archiv NRW

Manfred Thaller
Universität zu Köln

Hamburg, DINI: Elektronische Langzeitarchivierung in Hochschulen,
29. Februar 2012

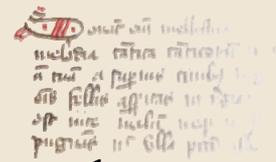
*Ad omne an melior
uolens tanta mētorū
ā nūc a pūpūc nūcū
sū felle affūcū nūcū
est nūc mēcū nūcū
pūcūc nūcū pūcūc*

Historisch

Kulturwissenschaftliche

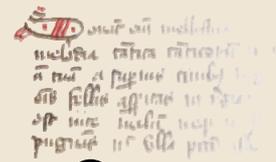
Informationsverarbeitung

I. Vorgaben



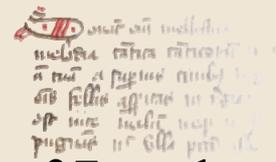
Langfristiges Ziel / Inhalt 1

- (1) Jede Kulturerbeeinrichtung in NRW soll die Möglichkeit haben beliebigen digitalen Inhalt an ein DANRW digital (über das Netz) *abzuliefern*.
- (2) Dies führt dazu, dass dieser Inhalt in einem OAIS kompatiblen landesweiten Langzeitarchiv abgelegt wird.
- (3) Dies schließt eine Technology Watch und Migrationen bei Bedarf ein.



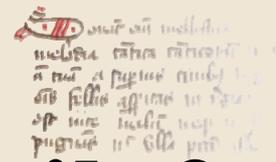
Langfristiges Ziel / Inhalt 2

- (4) Jede Kulturerbeeinrichtung in NRW kann bestimmen, in welchem Umfang der archivierte Inhalt an Portale weitergegeben werden darf.
- (5) Nach Maßgabe dieser Regelungen werden aus den abgelieferten Daten und Metadaten geeignete Darstellungen für DDB und Europeana abgeleitet, die via OAI PMH und anderer Protokolle auch allgemein bereitstehen.



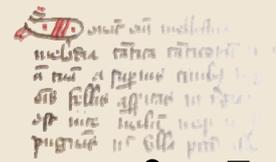
Langfristiges Ziel / Technik 1

- (1) *Existierende* IT Infrastruktureinrichtungen im Lande NRW stellen drei oder mehr „Knoten“ aus Rechner und Speicherkapazität bereit.
- (2) Diese erscheinen den Nutzern als ein einheitliches Langzeitarchiv für das Land.
- (3) Die drei+ Knoten synchronisieren sich selbständig und gleichen die Daten regelmässig gegeneinander ab.



Langfristiges Ziel / Technik 2

(4) „Eifelvulkanprinzip“: Wird nach der Eruption der Eifelvulkane ein Datenträger gefunden, enthält er vollständige, verarbeitbare digitale Objekte.

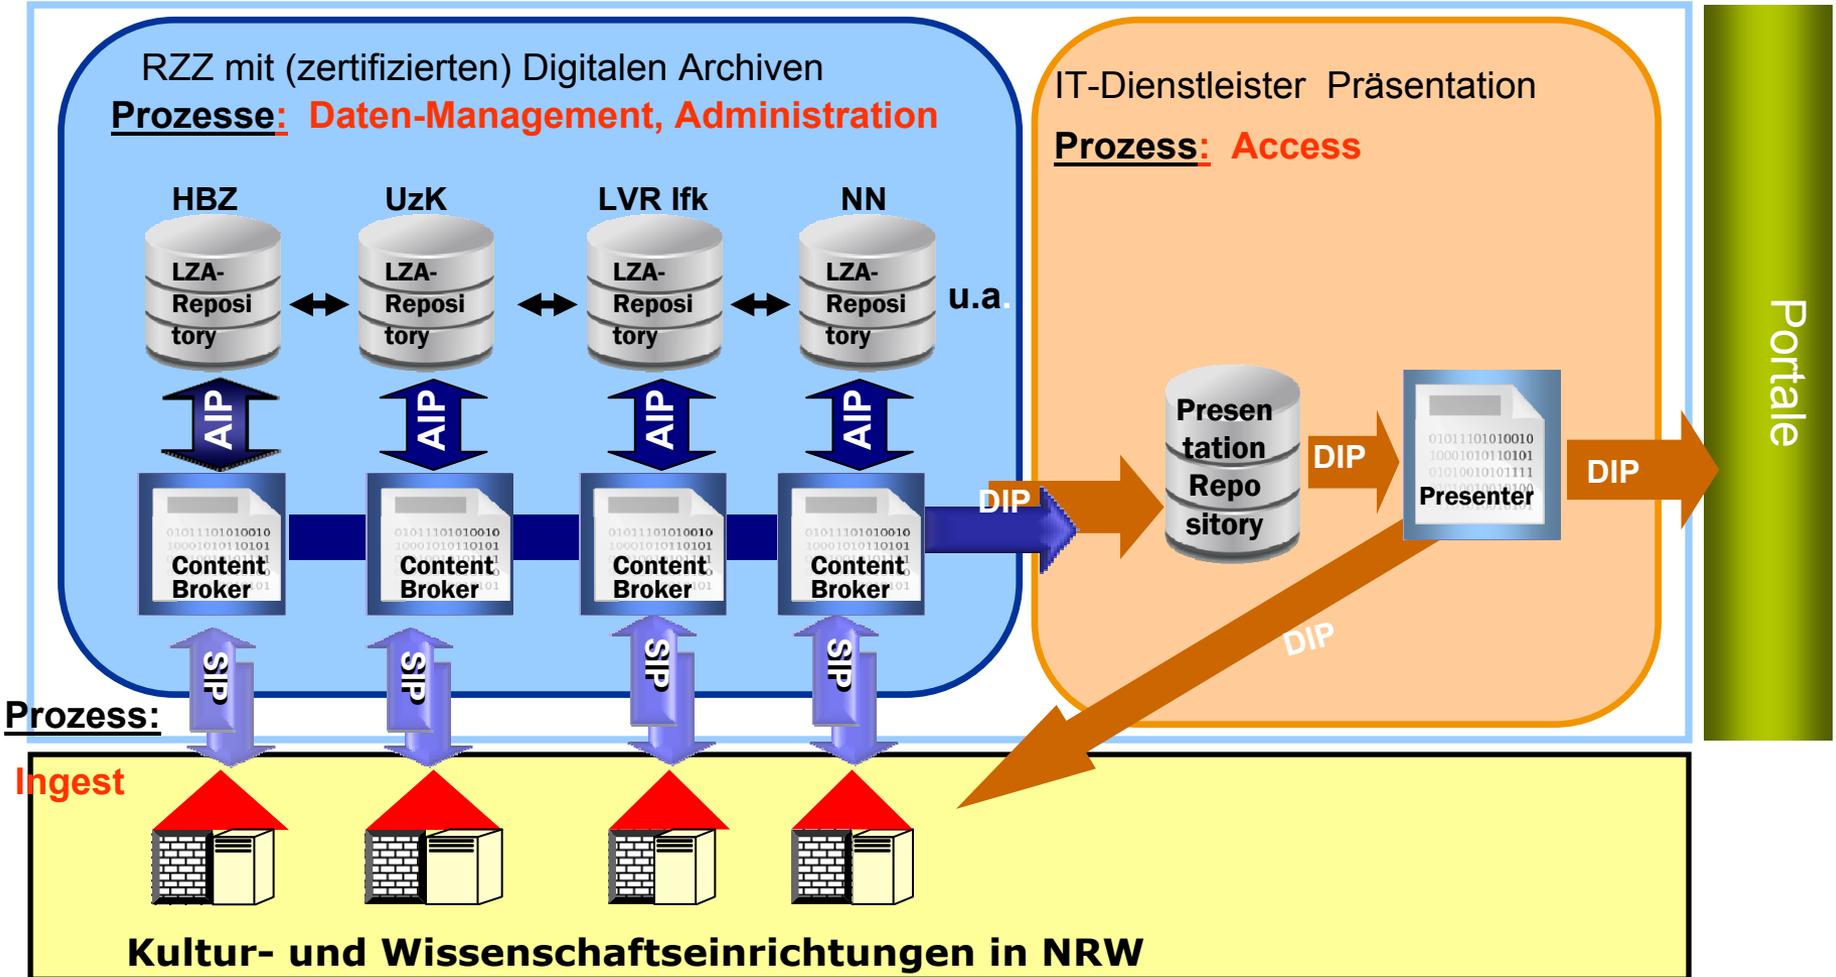


Kurzfristiges Ziel = Vorprojekt

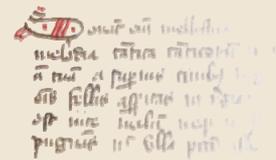
- (1) Nachweis der technischen Möglichkeit.
- (2) Exakte Kostenschätzung für den Dauerbetrieb.
- (3) Für eine beschränkte Zahl von Datenformaten und Metadatenstandards.
- (4) Bei einer Kapazität von etwa 200 TB.
- (5) Bei Formaten und Metadatenstandards unbeschränkt skalierbar.
- (6) Kapazität skalierbar um mindestens eine Größenordnung.



DA NRW: Systemarchitektur IT Verbund



SIP = Submission Information Packages
 AIP = Archival Information Packages
 DIP = Dissemination Information Packages



“Konsortium” 1 / 2

Kulturinstitutionen:

Theater der Klänge

Kunst- und Museumsbibliothek Köln

Landesarchiv NRW

LVR Archivberatungs- und Fortbildungszentrum

LVR Industriemuseum Oberhausen

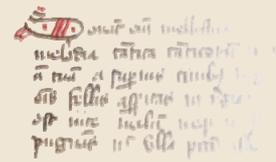
LVR Zentrum für Medien und Bildung

LWL Medienzentrum

Universitäts- und Landesbibliothek Bonn,

Universitäts- und Landesbibliothek Düsseldorf

Universitäts- und Landesbibliothek Münster



“Konsortium” 2 / 2

Koordination:

**Ministerium für Familie, Kinder, Jugend, Kultur, Sport des
Landes Nordrhein-Westfalen**

Technik:

**Universität Köln, Hist.-kulturwissenschaftliche
Informationsverarbeitung (HKI)**

Universität Köln, Regionales Rechenzentrum (RRZK)

Hochschulbibliothekszentrum NRW (hbz)

Landschaftsverband Rheinland, LVR-Infokom



HKI

„Fachinformatik der Geisteswissenschaften“

Beschäftigung mit Langzeitarchivierung:

- ❖ EU Projekte, u.a. Delos (<http://www.delos.info/>) und Planets (<http://www.planets-project.eu/>; dazu auch http://planetarium.hki.uni-koeln.de/planets_cms/index.php).
- ❖ Lehre auf ca. 12 LZA Summerschools seit 2004.
- ❖ Kooperation mit <http://www.openplanetsfoundation.org/>

Zum DANRW:

M.Thaller et al: „DA-NRW: a distributed architecture for long-term preservation“, in: L. Predoiu et al (Hg.): *Semantic Digital Archives*, Berlin, 2011, (<http://ceur-ws.org/Vol-801/paper13.pdf>)

*Ad omne an melior
uolens tanta mactat
a nat a pupis quib
sib filio affinis in d
est nix huius uop
pugna ut illi pnt*

Historisch

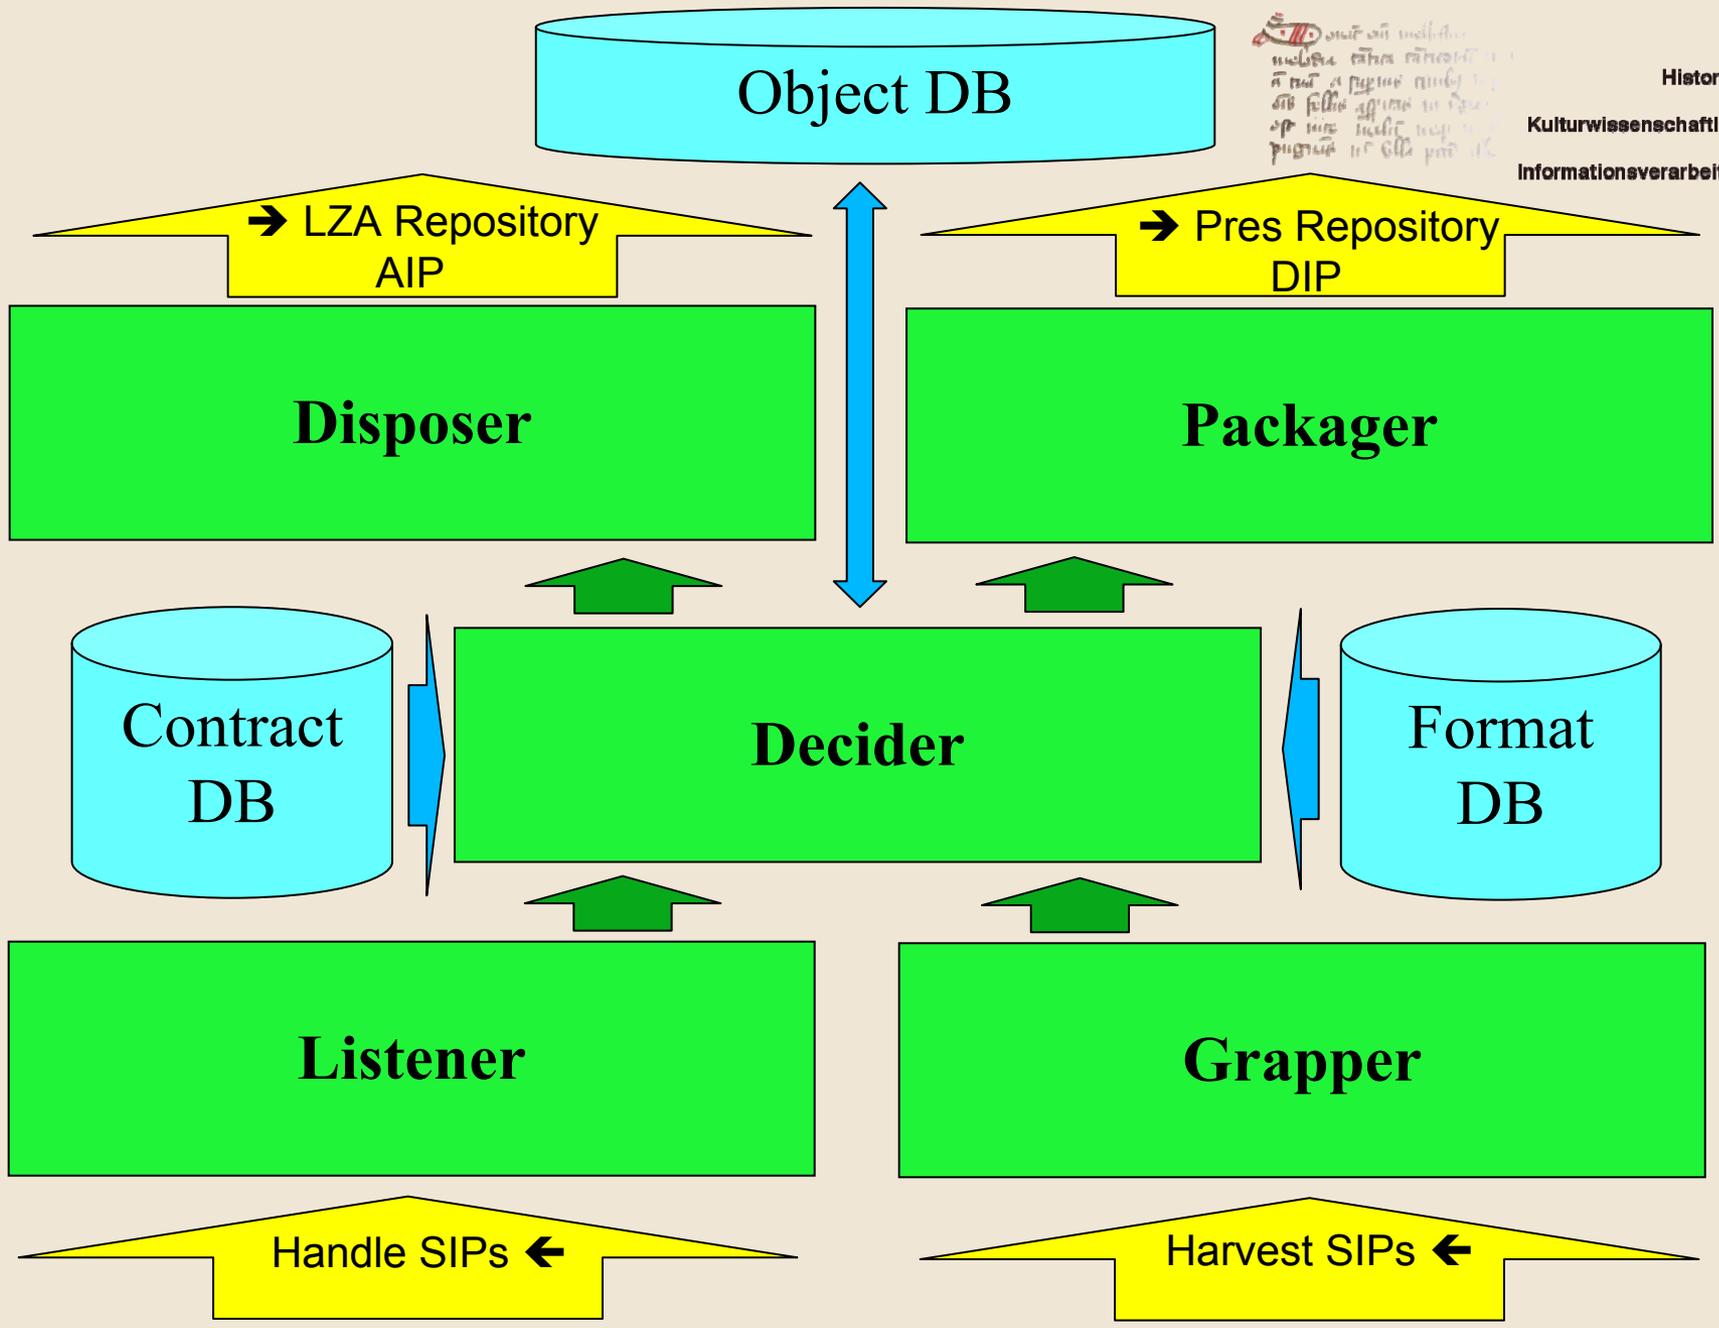
Kulturwissenschaftliche

Informationsverarbeitung

II. Basisarchitektur

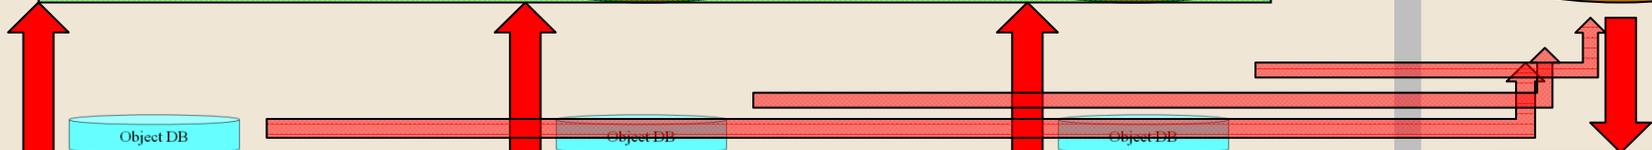
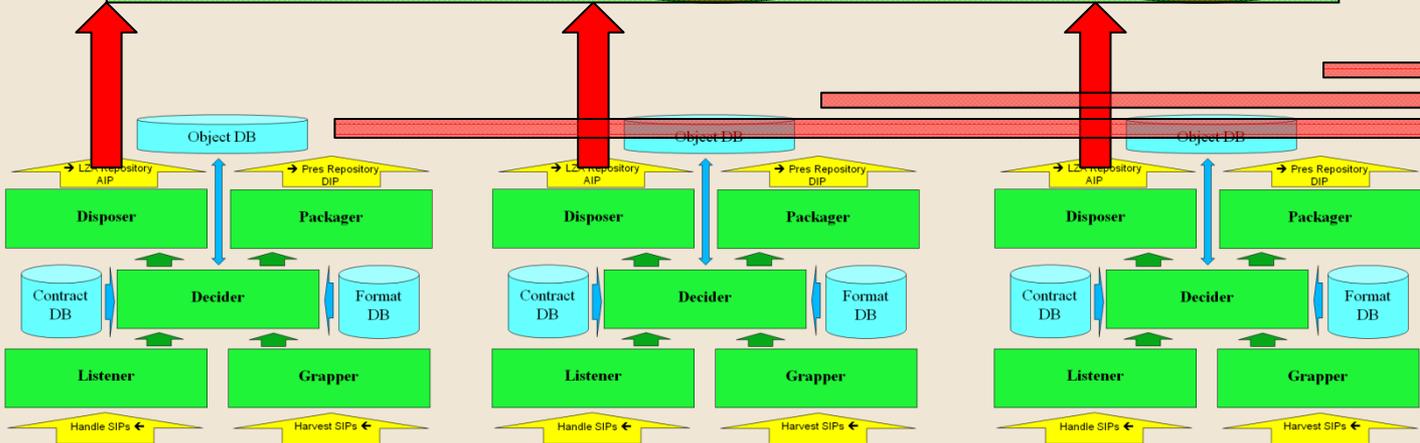
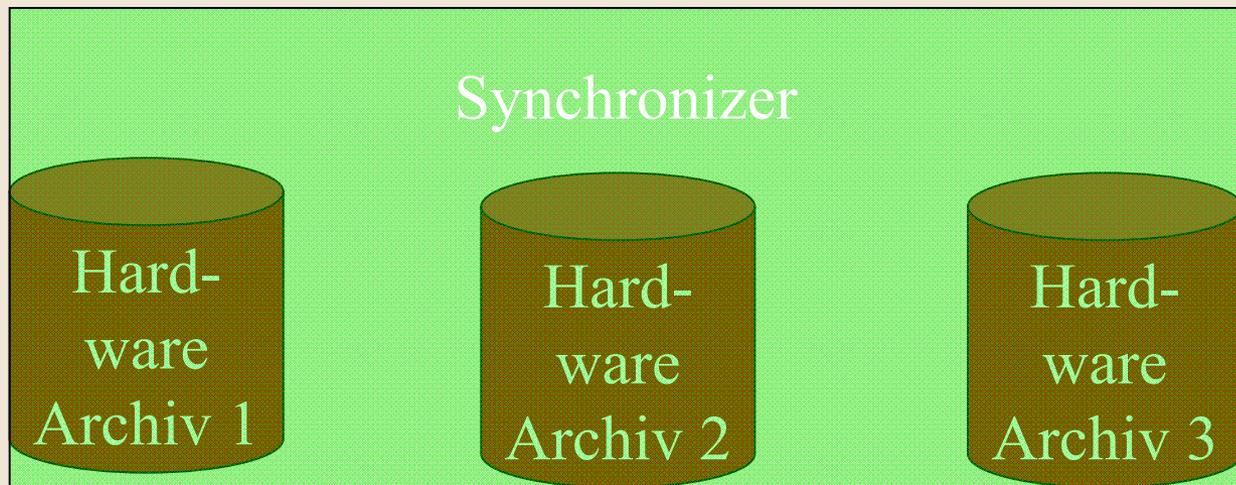
AD mit an melitu
nobra cana mncodit
a nat a pupus andi
as filio affine in dno
op nra hndit wop
pugna in illa pnt al

Historisch
Kulturwissenschaftliche
Informationsverarbeitung



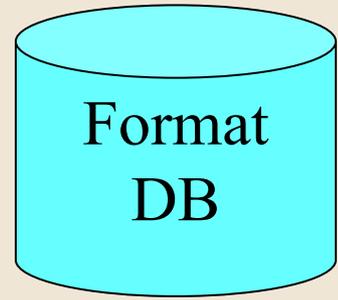
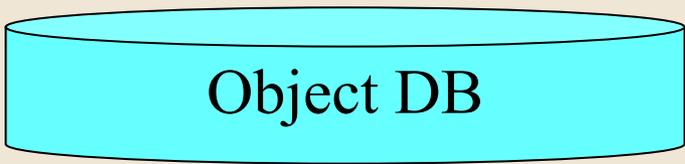
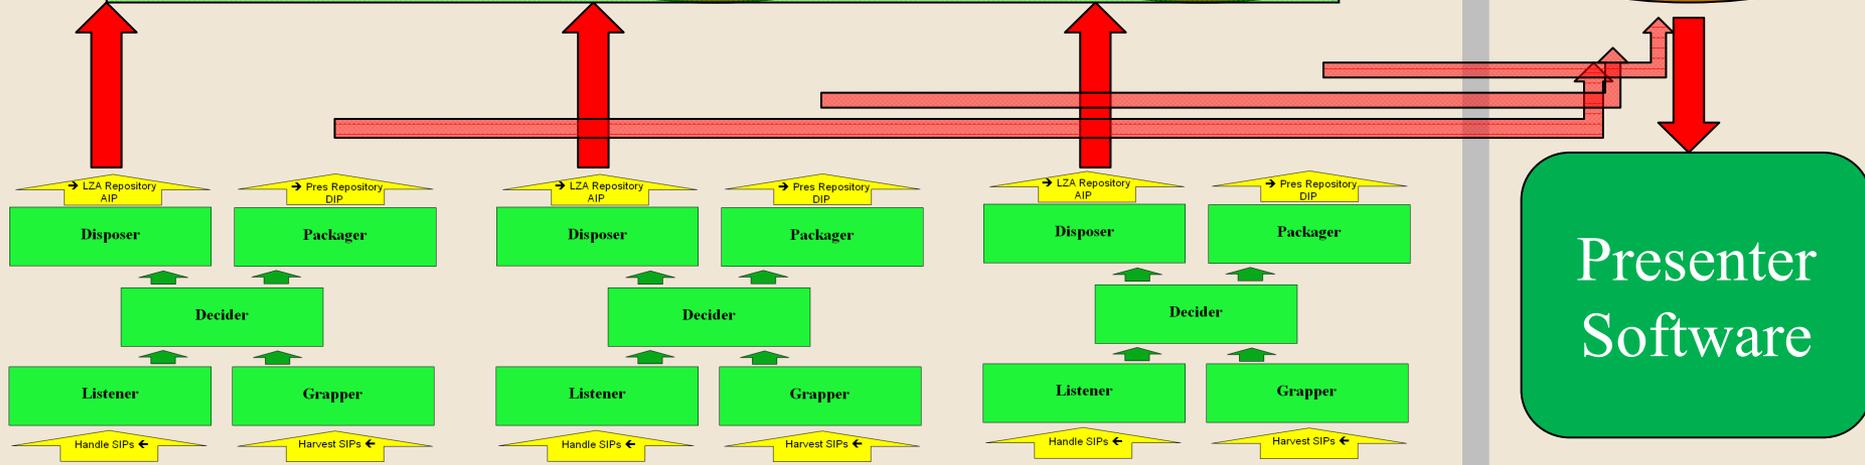
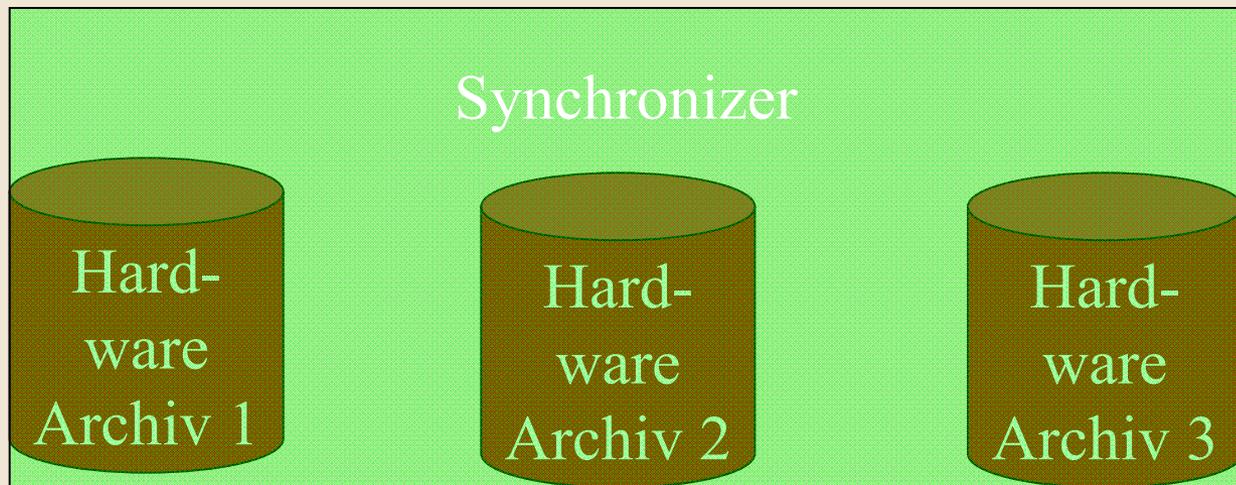
*D*omit an melioribus
natura cetera mioribus
a nat a pugnus amby
as filio affinis in digne
opt nix hucit uap nix
pugnus ut esse pnt ut

Historisch
Kulturwissenschaftliche
Informationsverarbeitung



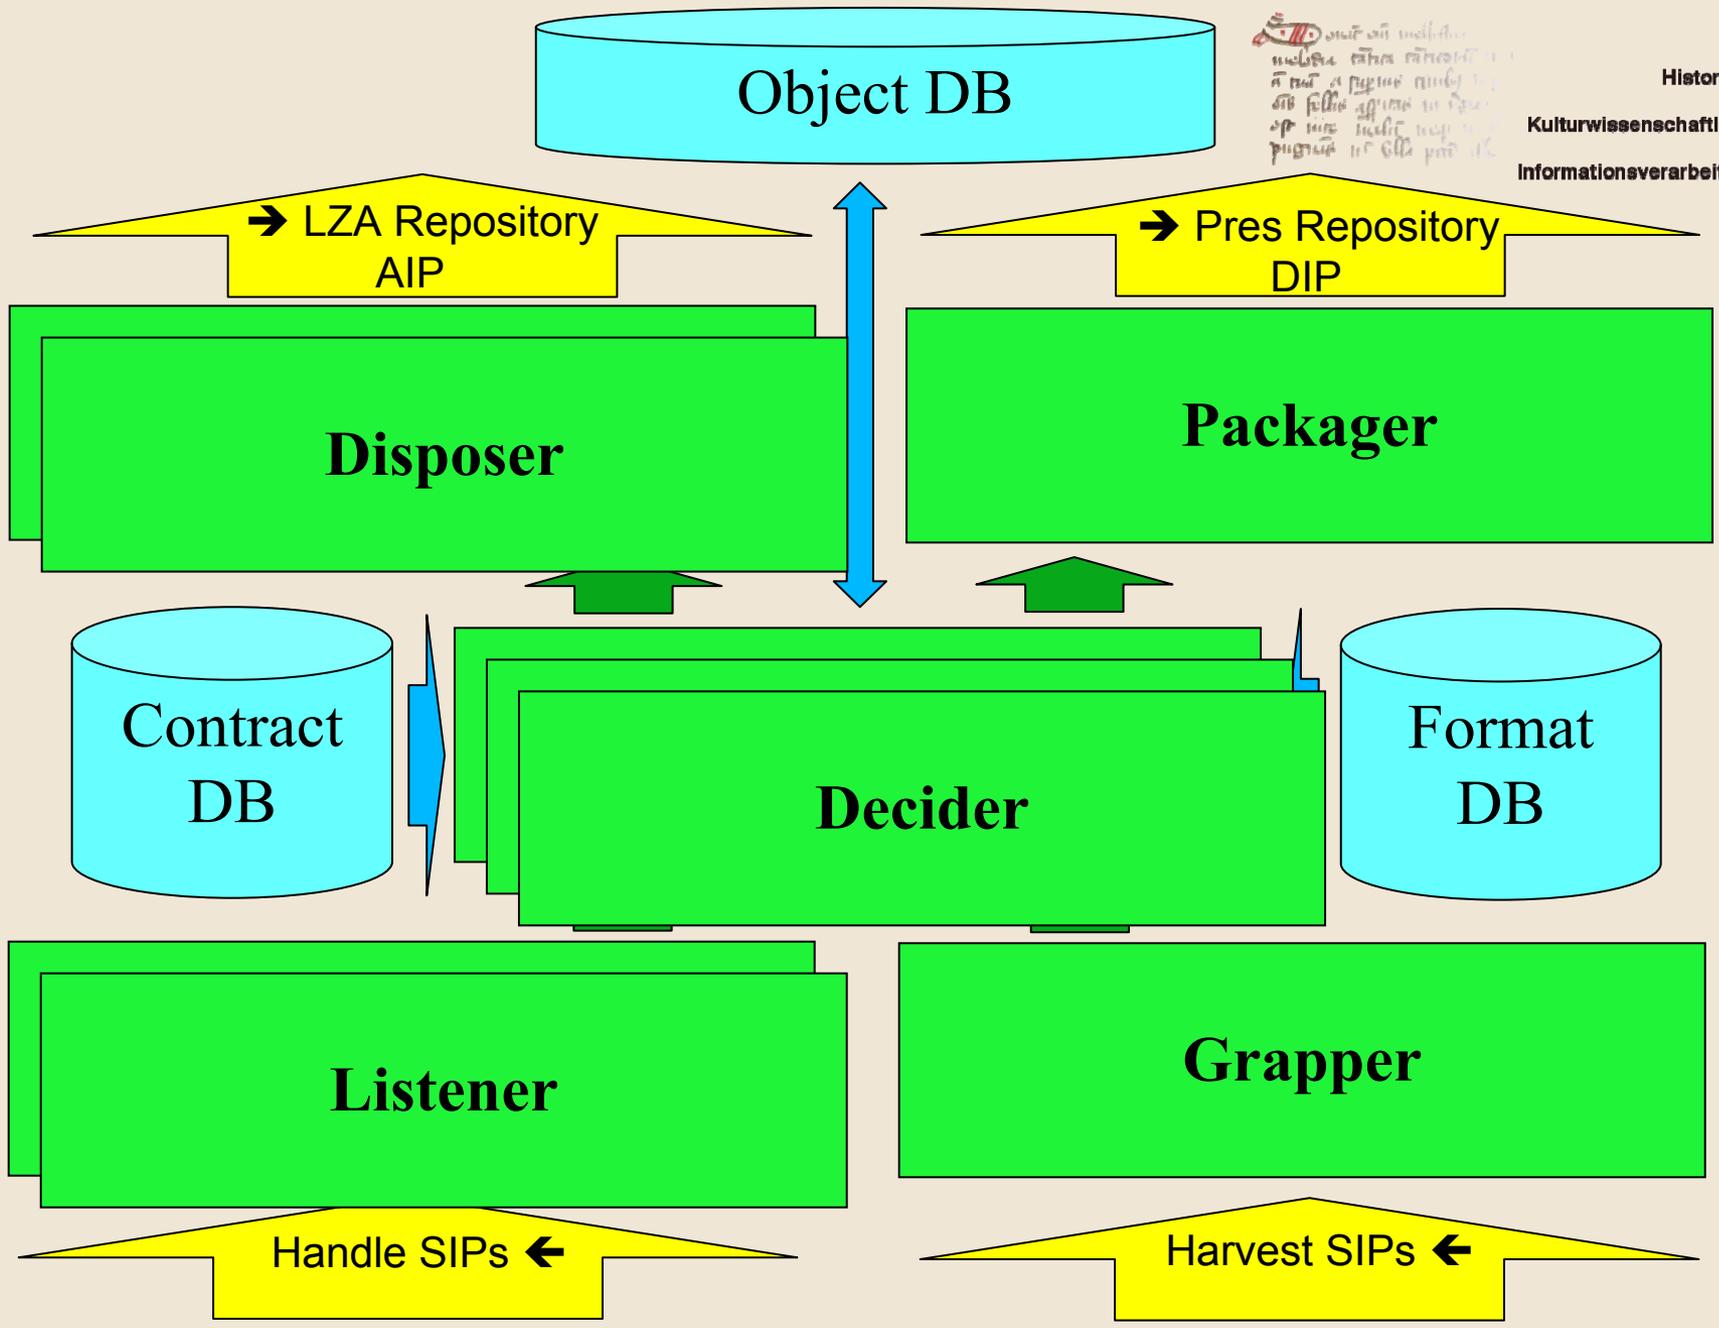
Handwritten text in a Gothic script, likely a historical document or manuscript snippet.

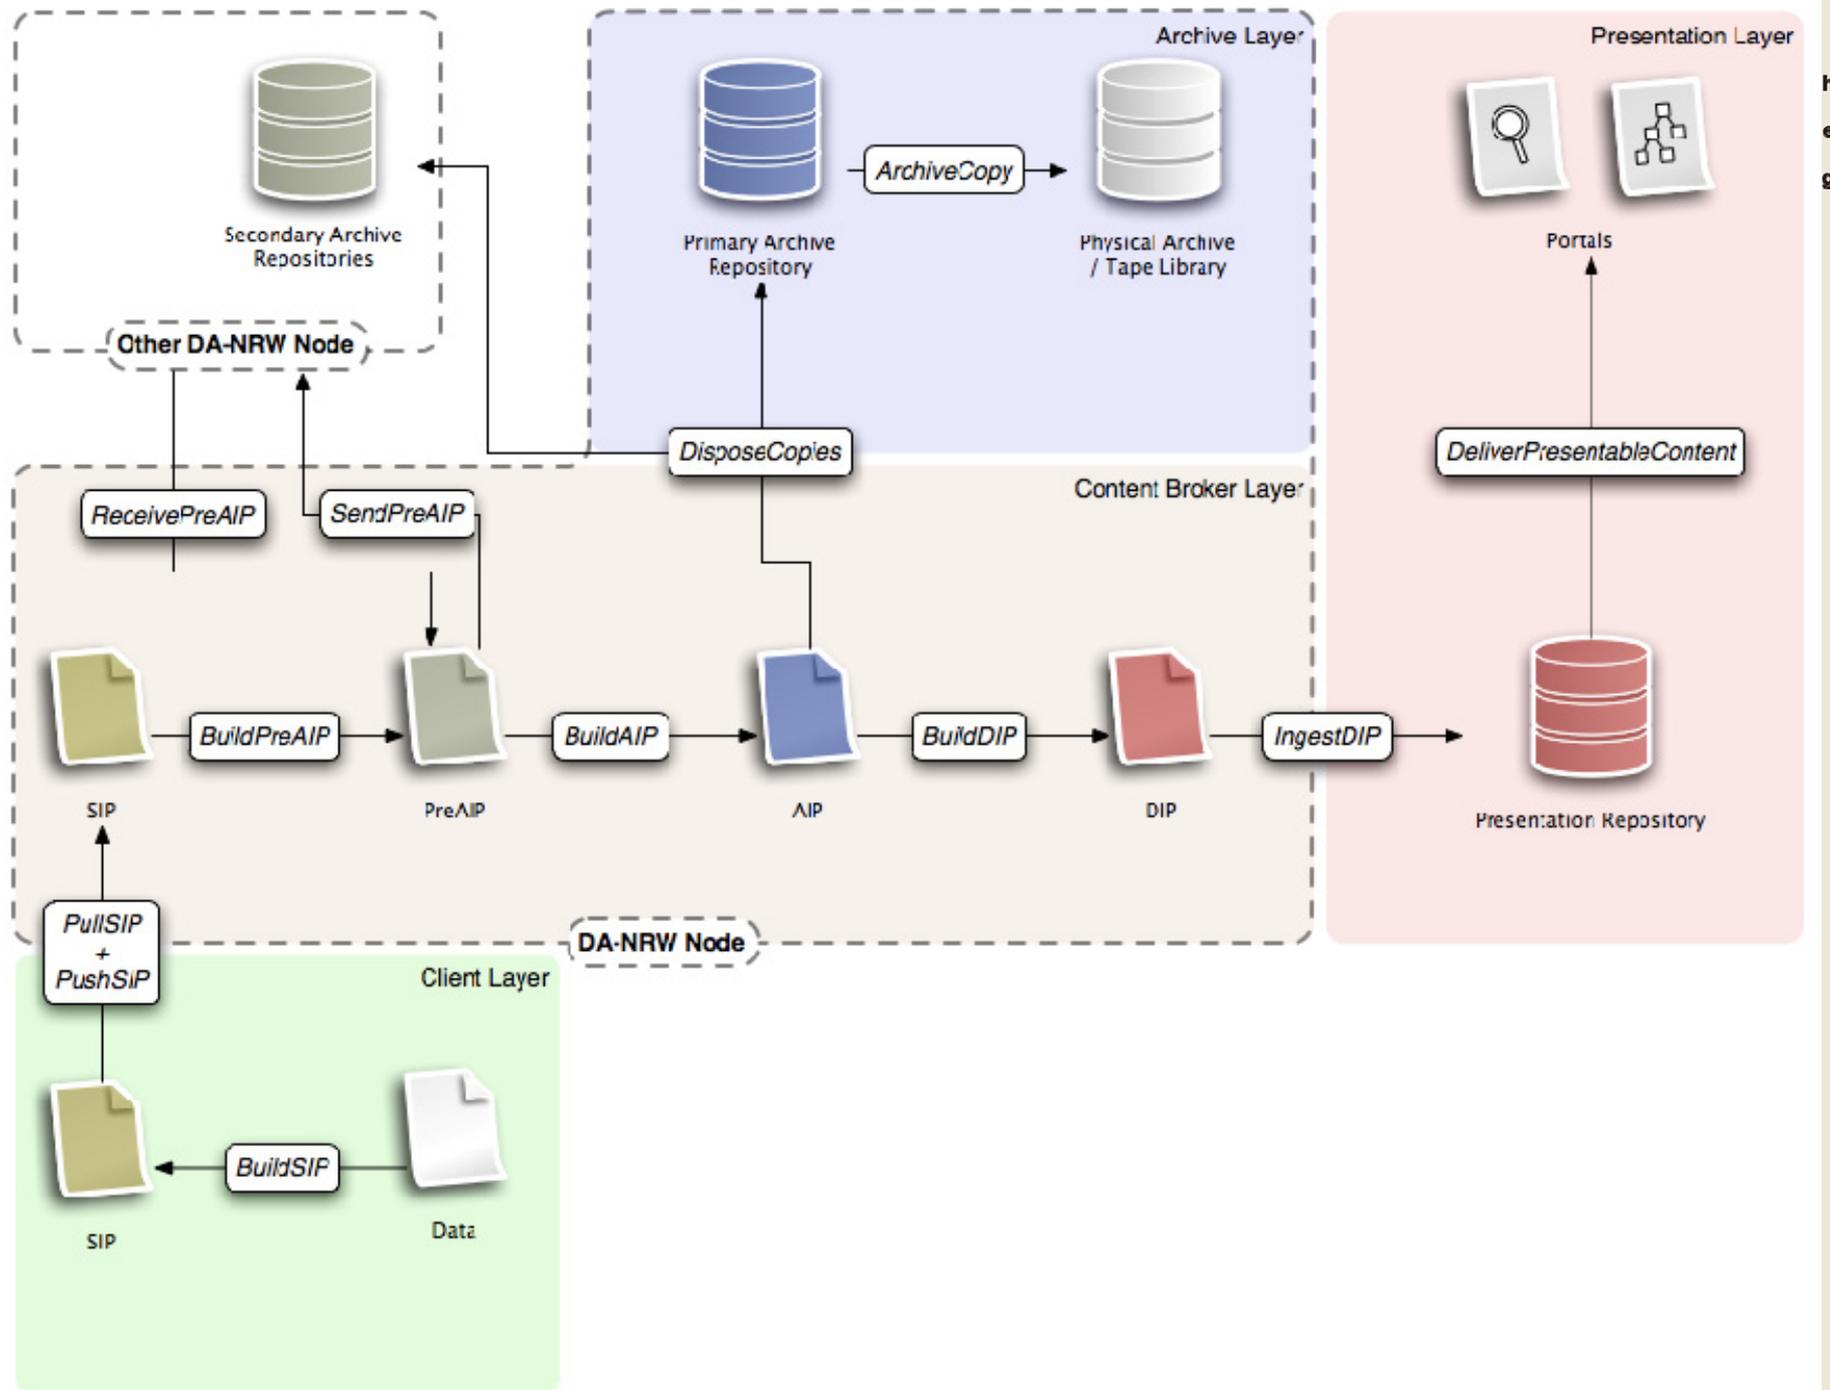
Historisch
Kulturwissenschaftliche
Informationsverarbeitung

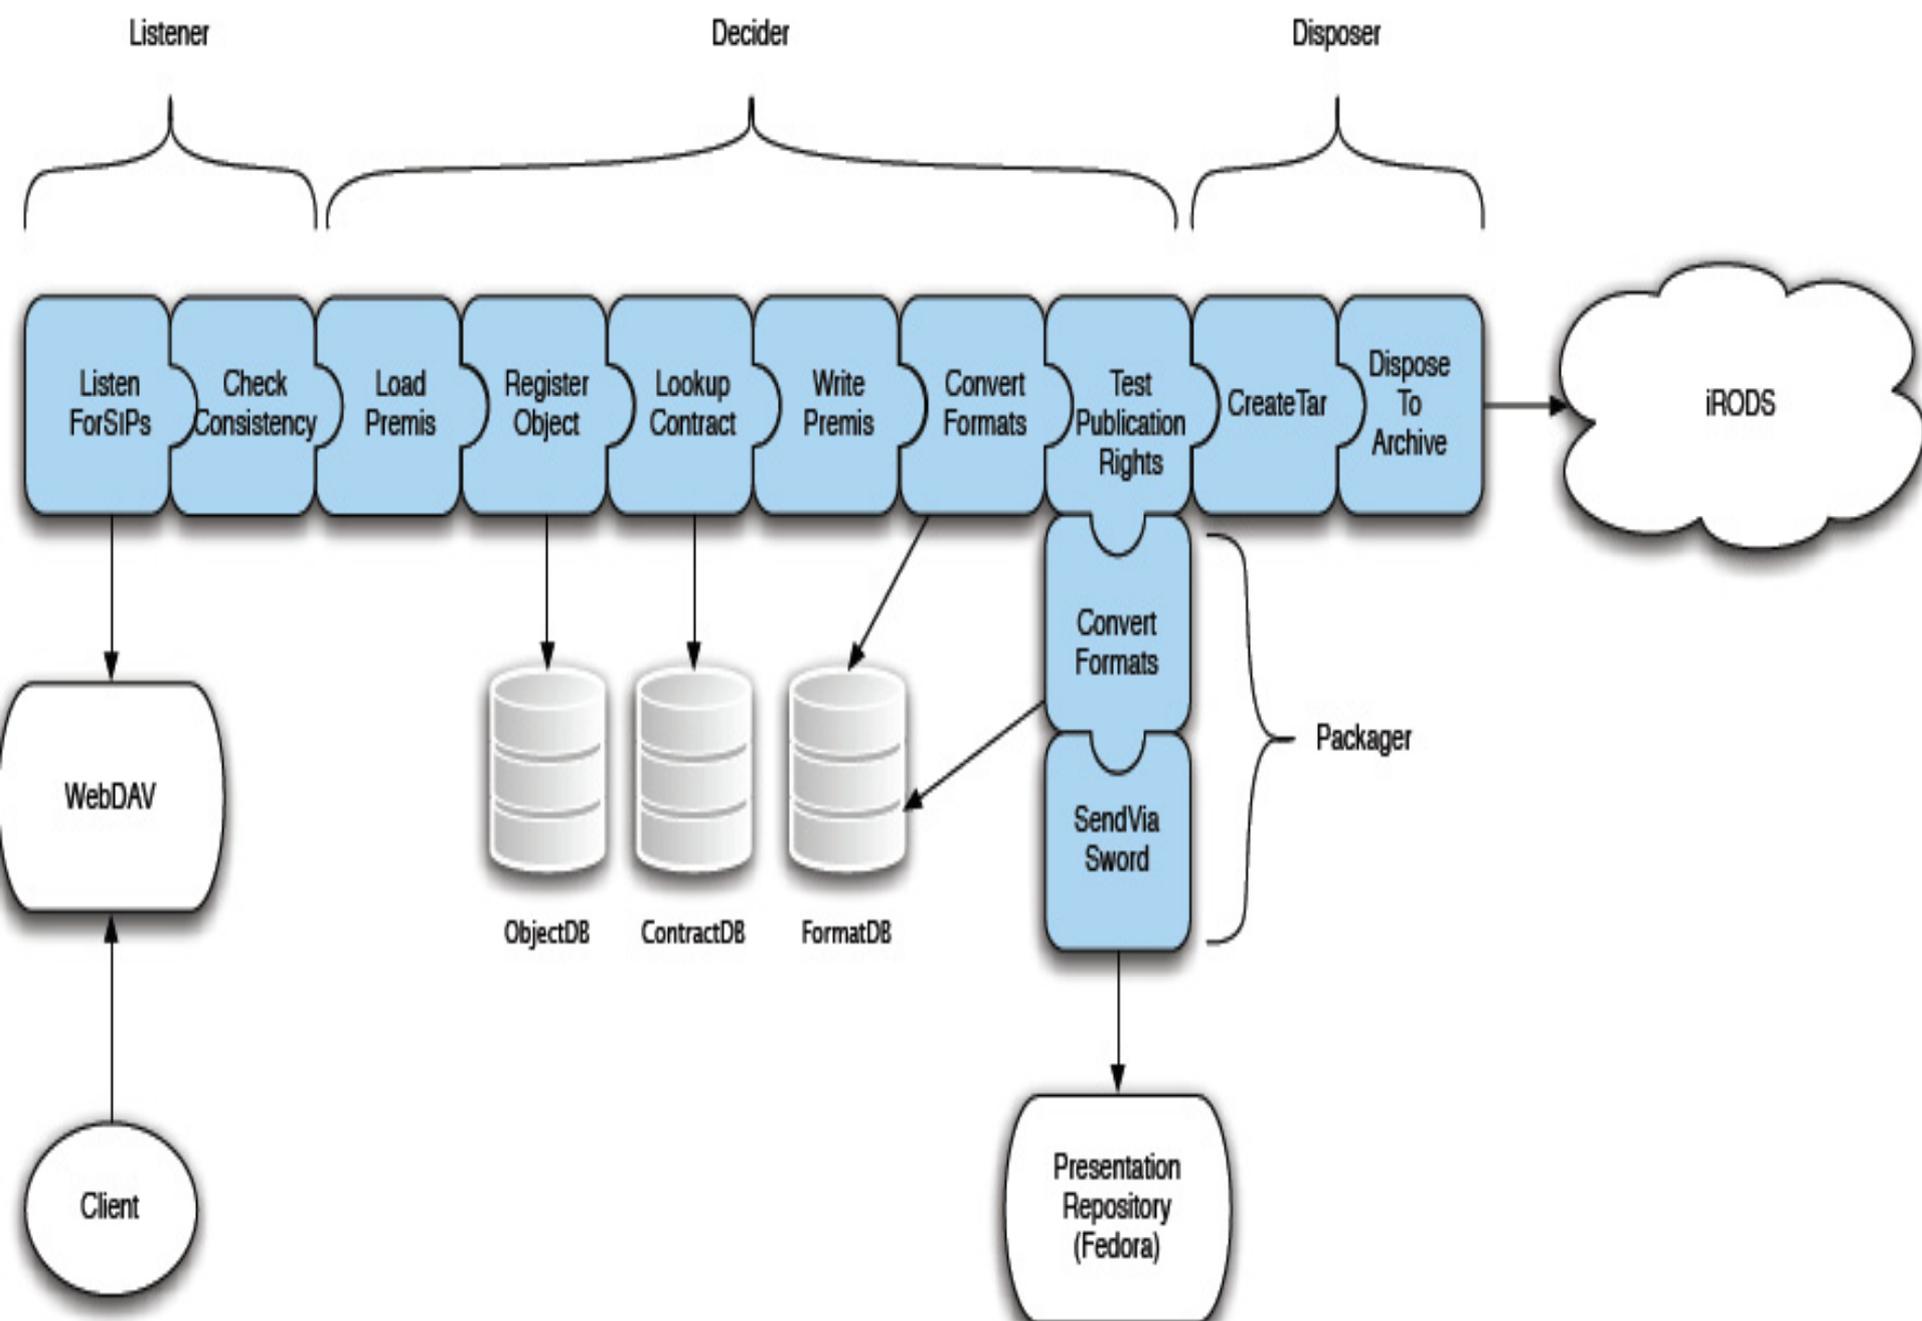


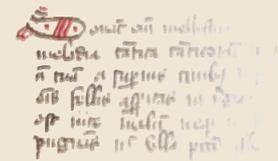
AD omni an melior
natura cetera mioribus
a nat a pupus ambo
as felle affinis in dno
op nra hndit uop
pugna ut illi pnt ut

Historisch
Kulturwissenschaftliche
Informationsverarbeitung



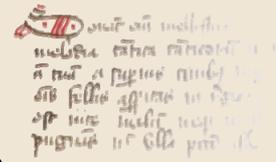






III. Umsetzung eines inhaltlichen Konzepts in einen Use Case

Beispiel: *Contracts*

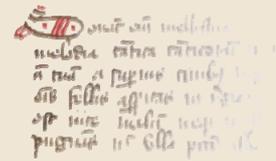


Konzept des “Contracts”

Eine Beschreibung der Bedingungen, unter denen eine Einrichtung dem DA NRW digitale Inhalte zur LZA übergibt.

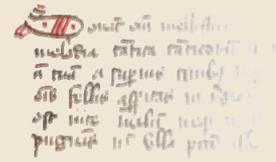
(1) Gespeichert als XML Dokument.

(2) Verfügbar als gedrucktes und ggf. gezeichnetes Dokument.



“Bedingungen”

- (1) Das Land NRW stellt eine Infrastruktur bereit, die sicherstellt, dass das digitale Kulturerbe des Landes auf Dauer sicher ist.
- (2) Das Land NRW stellt eine Infrastruktur bereit, die sicherstellt, dass das digitale Kulturerbe des Landes international die größtmögliche Sichtbarkeit hat.
- (3) Ausnahmen sind möglich.

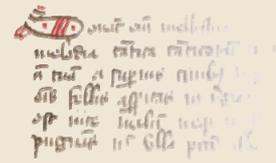


Inhalt des “Contracts”

Einschränkungen bei der Benutzung von Ressourcen innerhalb des DA NRW.

Einschränkungen der an den Presenter weiterreichbaren Metadaten.

Maximale Qualität der an den Presenter weiterreichbaren Metadaten.



Ebenen des “Contracts”

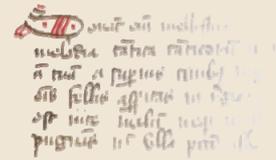
Ablieferungen einer Institution.

Ablieferungen eines Datentyps.

Ablieferungen einer Objektgruppe.

Ablieferung eines einzelnen Objekts.

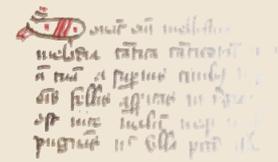
➔ Resultierender „Object contract“ wird Teil der LZA Metadaten.



IV. Umsetzung einer organisatorischen Annahme in konkrete Komponenten

Beispiel: *Pre-Ingest*

Beispiel Ingest: Prämissen 1 / 2



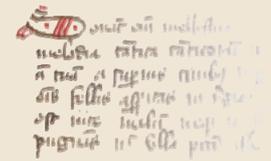
Grundsatz DA NRW: *Übernahme* von SIPs nach DIN 31645

Beispiel: (Standardentwurf 5.2.4 – “Zeitliche Abnahme der Validierungsprozesse”)

In einer ersten Phase werden Kriterien abgefragt, die vollständig erfüllt sein müssen:

- a. Enthält die Lieferung alle vereinbarten digitalen Objekte?
- b. Sind die digitalen Objekte integer?

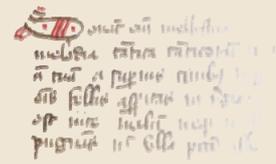
Beispiel Ingest: Prämissen 2 / 2



Grundsatz DA NRW: *Übernahme* von SIPs nach DIN 31645

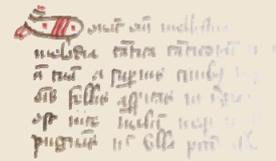
Beispiel: Vorgesehene Umsetzung DA-NRW seitig

- a. Sind alle in den SIP Metadaten erwähnten physikalischen Dateneinheiten vorhanden?
- b. Werden alle vorhandenen Dateneinheiten in den Metadaten erwähnt?
- c. Sind die Checksummen aller Dateneinheiten verifizierbar?
- d. Sind alle *supported* und *understood* formats „validierbar“?




Beispiel Ingest: Konsequenz

- (1) Es wird erwartet, dass die abliefernden Einrichtungen in der Lage sind, korrekte SIPs abzuliefern.
- (2) Deshalb wurde eine Vereinbarung mit einem Service Provider getroffen, wonach dessen Ablieferungsformat akzeptiert wird.
- (3) Es wird aber auch ein *SIP Builder* angeboten, der Daten und Metadaten zusammenfasst, mit Checksummen versieht und für den Transfer vorbereitet.



V. Technologieentscheidungen / gewählte Standards

Technologieentscheidungen



(1) Orchestrierung durch eigene Module oder als Teil ...

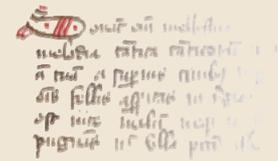
(2) hardwarenaher Komponenten auf der Basis von iRods. (iRods /
University of North Carolina at Chapel Hill: Basis für NARA
Transcontinental Persistent Archive Prototype.)

<https://www.irods.org>

(3) Presentation Repository auf der Basis von Fedora.

<http://fedora-commons.org>

Zentrale Standards



Historisch

Kulturwissenschaftliche

Informationsverarbeitung

- (1) OAIS konform ... als Kern
- (2) LZA Objekte: BagIT <http://tools.ietf.org/html/draft-kunze-bagit-06>
- (2) Objektidentifikatoren: URN
- (3) Strukturdaten: METS / MODS, so anwendbar
- (4) [Formatidentifikatoren: PRONOM / UDFR version, RDF based]
- (5) PREMIS: PREMIS. Derzeit XML Bindung, kann noch durch RDF oder UML Bindung ersetzt werden

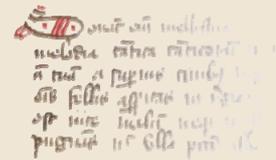
Domit an melitu
uelora cana mēcorū
ā nū a pupus nūbi
sū filio affinis in dū
est nū melit nūp
pugna nū illū pūc

Historisch

Kulturwissenschaftliche

Informationsverarbeitung

VI. Status



Projekt DANRW / Vorprojekt - Stand

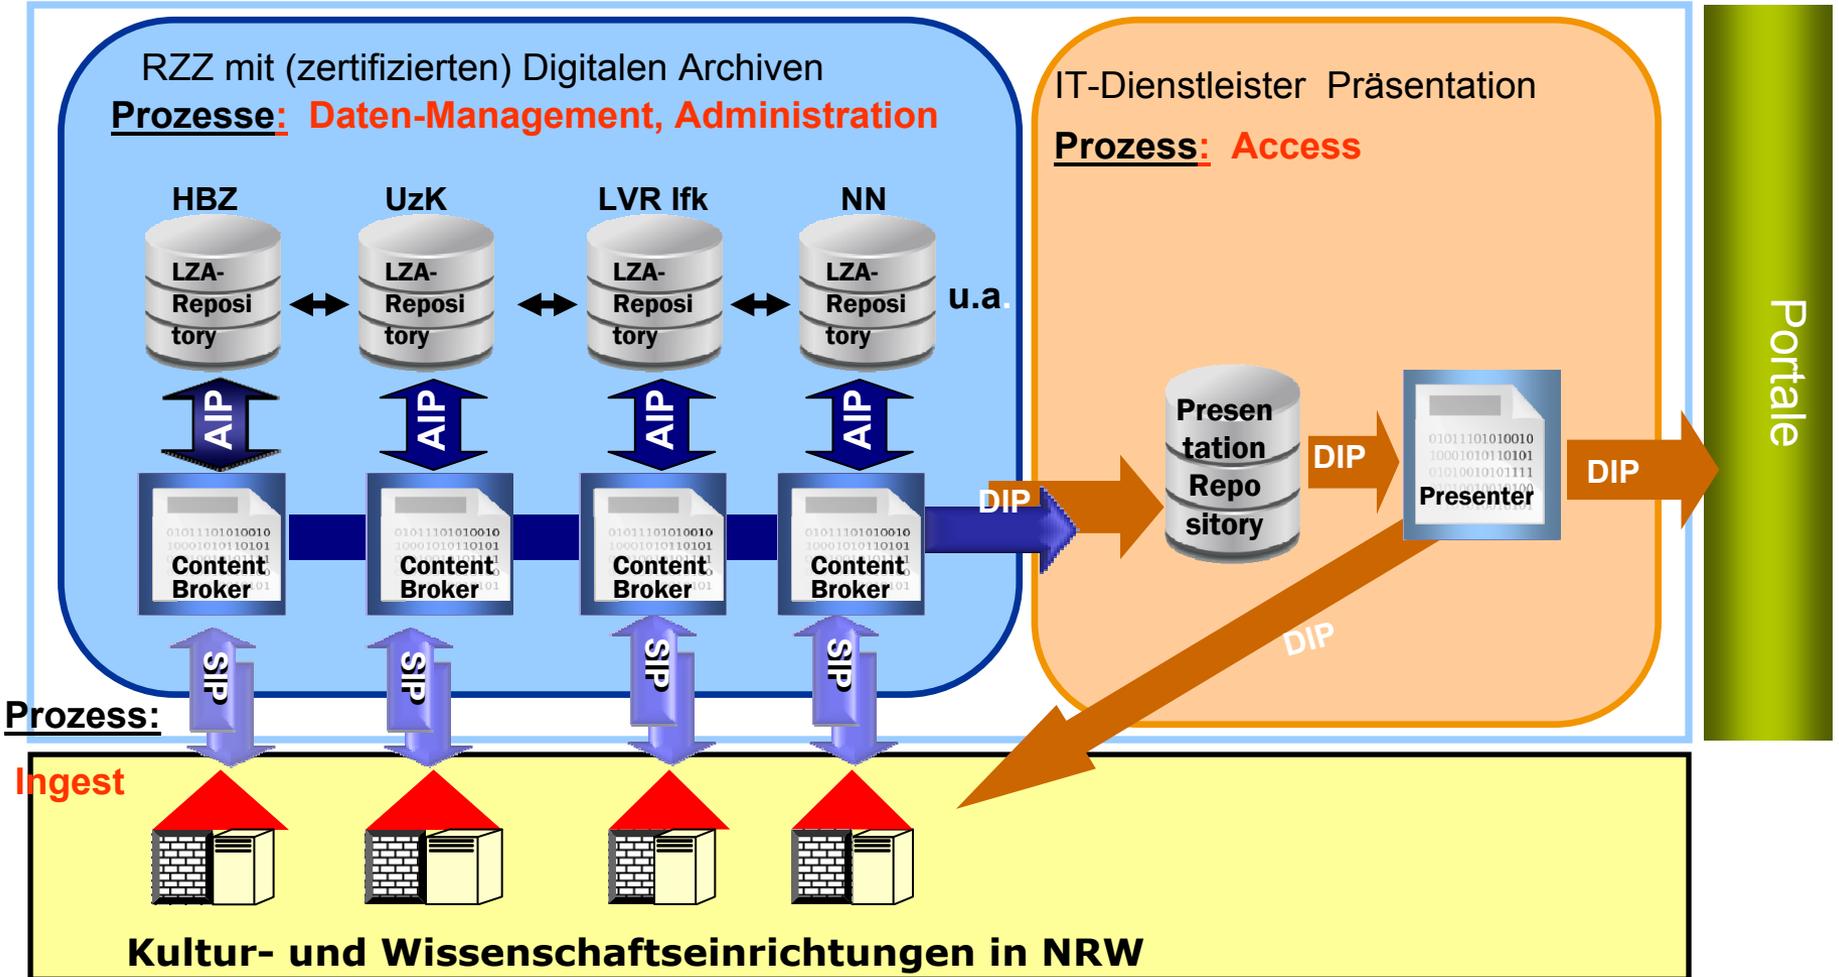
Ziel: „Erweiterte Machbarkeitstudie“

Zeitplan:

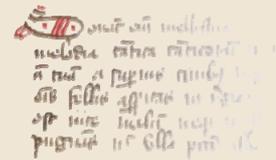
- (1) Organisatorische Vorbereitungen = Nov. / Dez. 2010
- (2) Vorphase: Design = Jan. / Feb. 2011
- (3) Iteration I: Pre-Prototyp = März / Juni 2011
- (4) Iteration II: Stabiler Prototyp = Juli / Dez. 2011
- (5) Iteration III: Skalierbares System = Jan. / April 2012
- (6) [Verstetigung = Mai / Dezember 2012]



DA NRW: Systemarchitektur IT Verbund



SIP = Submission Information Packages
AIP = Archival Information Packages
DIP = Dissemination Information Packages



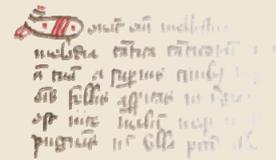
Projekt DANRW / Vorprojekt – Stand 1

Ziel: „Erweiterte Machbarkeitstudie“

Status 29. Februar 2012:

„Kontrollierter Produktionsbetrieb“ auf der Basis der
ULB Bestände

Tests auf Basis der Bestände anderer Partner



Projekt DANRW / Vorprojekt – Stand 2

Ziel: „Erweiterte Machbarkeitstudie“

Mutmaßlicher Status 30. April 2012:

LZA – „Beschränkter Produktionsbetrieb“ 30 – 40 TB

Portal – DDB ja; sonst: Wiedervorlage

- ❖ Technologywatch: Schnittstellen.
- ❖ „Eifelvulkanprinzip“ noch nicht umgesetzt.

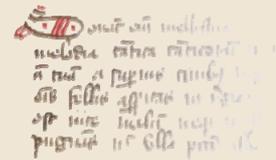
Domit an melito
uolera cana mēcorū
ā nū a pūpūo nūbū
sū fello affūo nū dūo
op nū mūhū nūp nū
pūgūo nū ellū pūo dū

Historisch

Kulturwissenschaftliche

Informationsverarbeitung

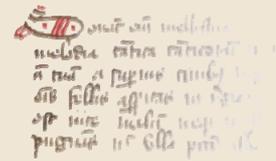
VII. Lehren



Meinungen & Erfahrungen

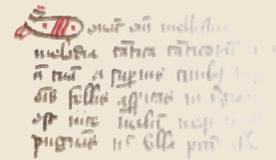
Claire Bretecher:

<http://www.clairebretecher.com/NET/classic/casanova.htm>



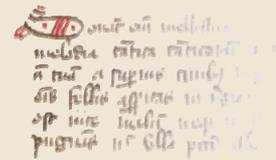
Meinungen & Erfahrungen

Langzeitarchivierung jetzt!



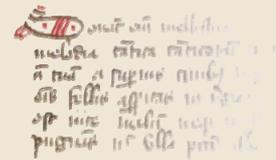
Meinungen & Erfahrungen

Bitstream preservation alleine reicht nicht;
ohne Bitstreams sind die Metadaten aber
nutzlos.



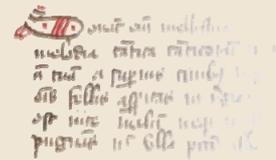
Meinungen & Erfahrungen

Ein Preservation Strategie sollte mit dem Allgemeinen beginnen, die Ausnahmefälle sollten DANACH diskutiert werden.



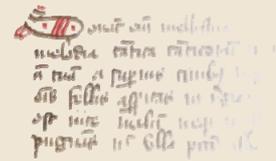
Meinungen & Erfahrungen

Agile Methodologies sind praktisch sehr relevant. Der "Wasserfall" entspricht NICHT mehr dem State of the Art.



Meinungen & Erfahrungen

Digitale LZA kann organisch in bestehende Infrastrukturen integriert werden und erfordert keine grundlegenden Neukonstruktionen. Nachdem sie ein erhebliches *operatives* Knowhow erfordert, hat dies auch generell positive Aspekte.



Historisch

Kulturwissenschaftliche

Informationsverarbeitung

Herzlichen Dank!

manfred.thaller@uni-koeln.de