Überblick:
Arbeitspaket und Architektur

Begutachtung des WissGrid AP 3

28. Januar 2010, AIP Potsdam

Jens Ludwig

SUB Göttingen

Bundesministerium
für Bildung
und Forschung

Aufbau

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

Auftrag des Arbeitspakets

- formales Ziel laut Antrag:
  - Generische LZA-Architektur für Forschungsdaten in D-Grid
  - Umsetzung der Architektur
    - Modulare LZA-Dienste
    - Grid-Forschungsdatenarchiv
  - LZA-Leitfäden/-Blaupausen
- inhaltliches Ziel:
  - Grid-Communities starke und attraktive Instrumente für ein langfristiges und nachhaltiges Datenmanagement anbieten!
  - Dadurch ein weiteres Argument für D-Grid schaffen...

Stand im AP-Projektplan

M06: Konzept für eine generische Grid-LZA Architektur

M08: 1. Iteration Spezifikation: LZA-Dienste und Repository

M09: Begutachtung Architekturkonzept

(Deliverables zu M06 und M08 Teil der Begutachtung)

M12: 2. Iteration Spezifikation: LZA-Dienste und Repository

M24: 1. Iteration Umsetzung LZA-Dienste und Repository

...

M26: Workshop zu LZA-Leitfäden

M36: 2. Iteration Umsetzung LZA-Dienste und Repository

...

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

Wichtige Erfolgsfaktoren

- Akzeptanz und Integration durch die Grid-Communities
  - Ihre Anforderungen verstehen und aufnehmen, unser bestehendes Wissen weitergeben
  - Generische Entwicklungen, die an Community-spezifische Anforderungen anpassbar sind
  - Wenn möglich Anpassung und Integration begleiten und unterstützen

- Stand der Technik aufnehmen und fortschreiben
  - Viele internationale Vorarbeiten existieren, keine völligen Neuentwicklungen, sondern Grid-Anpassungen
  - Grid mit LZA und LZA mit Grid ist ein z.T. neues Thema

Was wir bisher geleistet haben

- Akzeptanz und Integration durch die Grid-Communities
  - Begleitende AG mit Vertretern der Fachdisziplinen gegründet und erstes Treffen durchgeführt
  - Zwei weitere, nicht im Antrag genannte, aber interessierte Disziplinen: Sozialwissenschaften und Altertumswissenschaften
  - Treffen mit Photonenphysik und Sozialwissenschaften, weitere Anfang Februar
  - Fallstudien im Architekturdokument (werden fortgeschrieben)
  - (Gespräche mit SUN als interessierten kommerziellem Partner)

Was wir bisher geleistet haben

- Stand der Technik aufnehmen und fortschreiben
  - intern: gemeinsames Verständnis und Terminologie
  - 3 Deliverables, die den Stand der Technik analysieren und aufnehmen
    - Konzept für eine generische Grid-LZA Architektur
    - 1. Iteration Spezifikation: LZA-Dienste
    - 1. Iteration Spezifikation: Repository
  - Koorganisation der OGF Digital Repositories Research Group (letzte Workshop im Dezember in London, nächste bei der OGF 28 in München)
  - Paper beim International Symposium on Grid Computing im März 2010, Taiwan
  - Präsentation beim DGI-Metadaten-Workshop

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

Begriff und Aktualität

- Bisher keine klare deutsche Terminologie
- „Langzeitarchivierung“ als Überbegriff für
  - das Sicherstellen der Nachnutzbarkeit
  - in einem anderen technischen, zeitlichen, fachlichen, organisatorischen oder sonstigen Kontext
- Dadurch große Schnittmenge mit aktuellen Begriffen wie Data Driven Science, Data Sharing, etc.
- „Research cannot flourish if data are not preserved and made accessible. All concerned must act accordingly.“

Nature 461, 145 (10 September 2009), doi: 10.1038/461145a

Ausgangsmodell

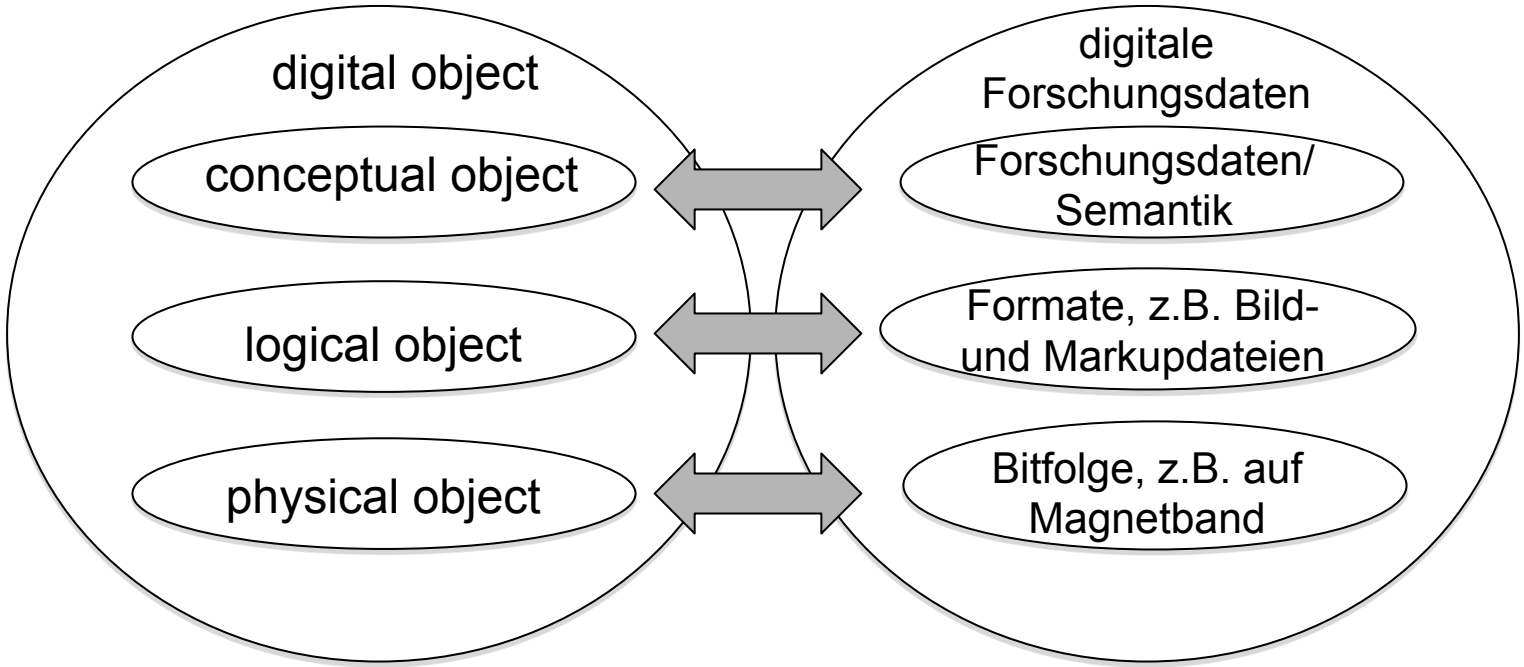

Angelehnt an Thibodeau: Overview of Technological Approaches to Digital Preservation and Challenges in Coming Years, 2002. http://www.clir.org/pubs/reports/pub107/thibodeau.html

Drei Aspekte der Langzeitarchivierung

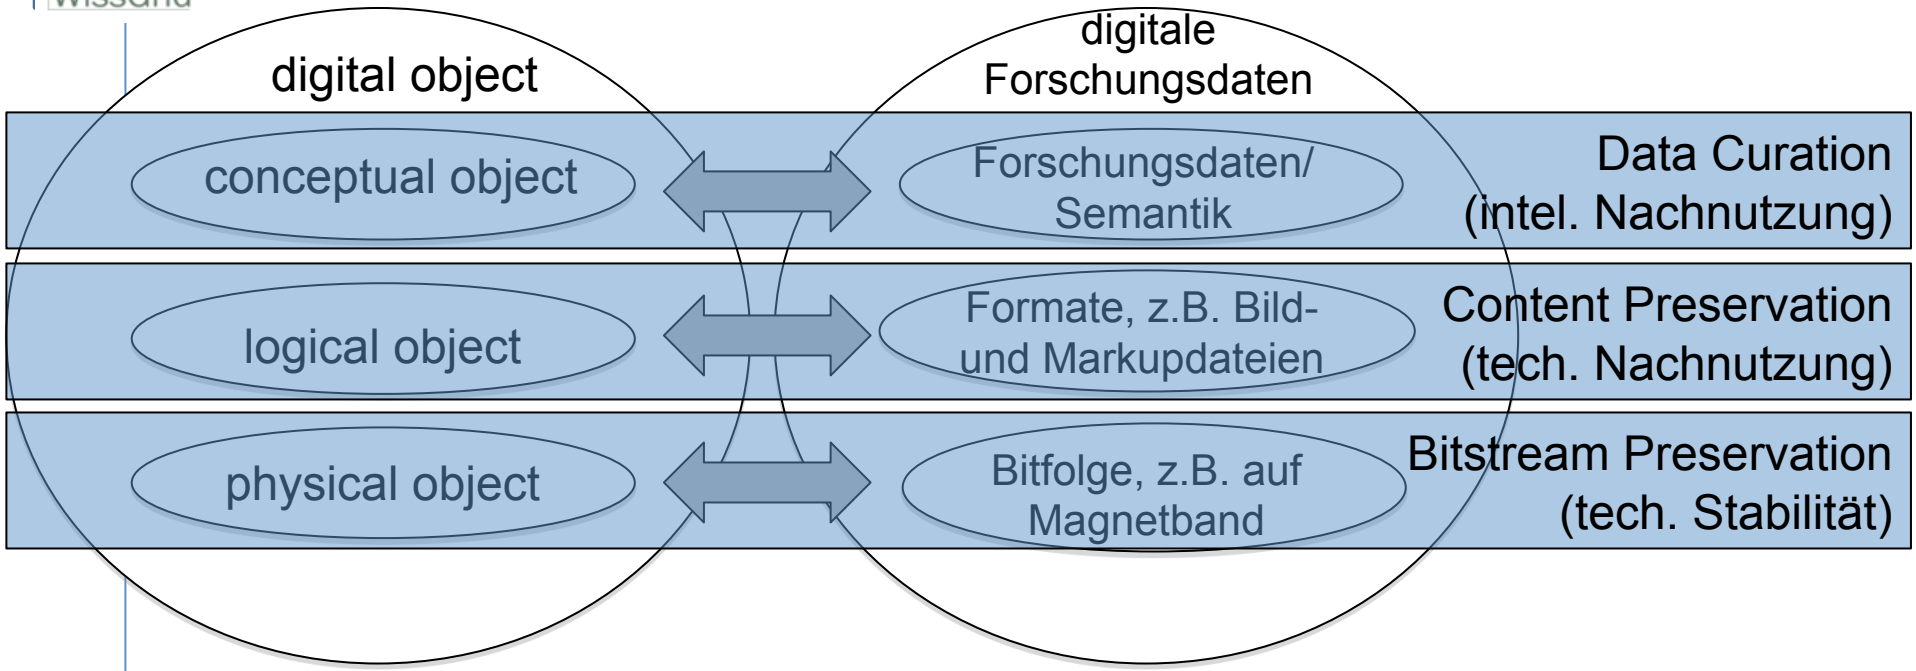

- Data Curation: intellektuelle Nachnutzbarkeit
  - Kontextinformationen, Objektmodelle, Versionierungen, ...
- Content Preservation: technische Nachnutzbarkeit
  - technische Qualitätskontrollen, Konvertierungen, ...
- Bitstream Preservation: technische Stabilität
  - genug unabhängige Kopien, Integritätsprüfung, ...

Kompetenzen für Langzeitarchivierung

- Für die Entwicklung von Infrastruktur und Werkzeugen zur LZA haben unterschiedliche Akteure die größte Kompetenz:

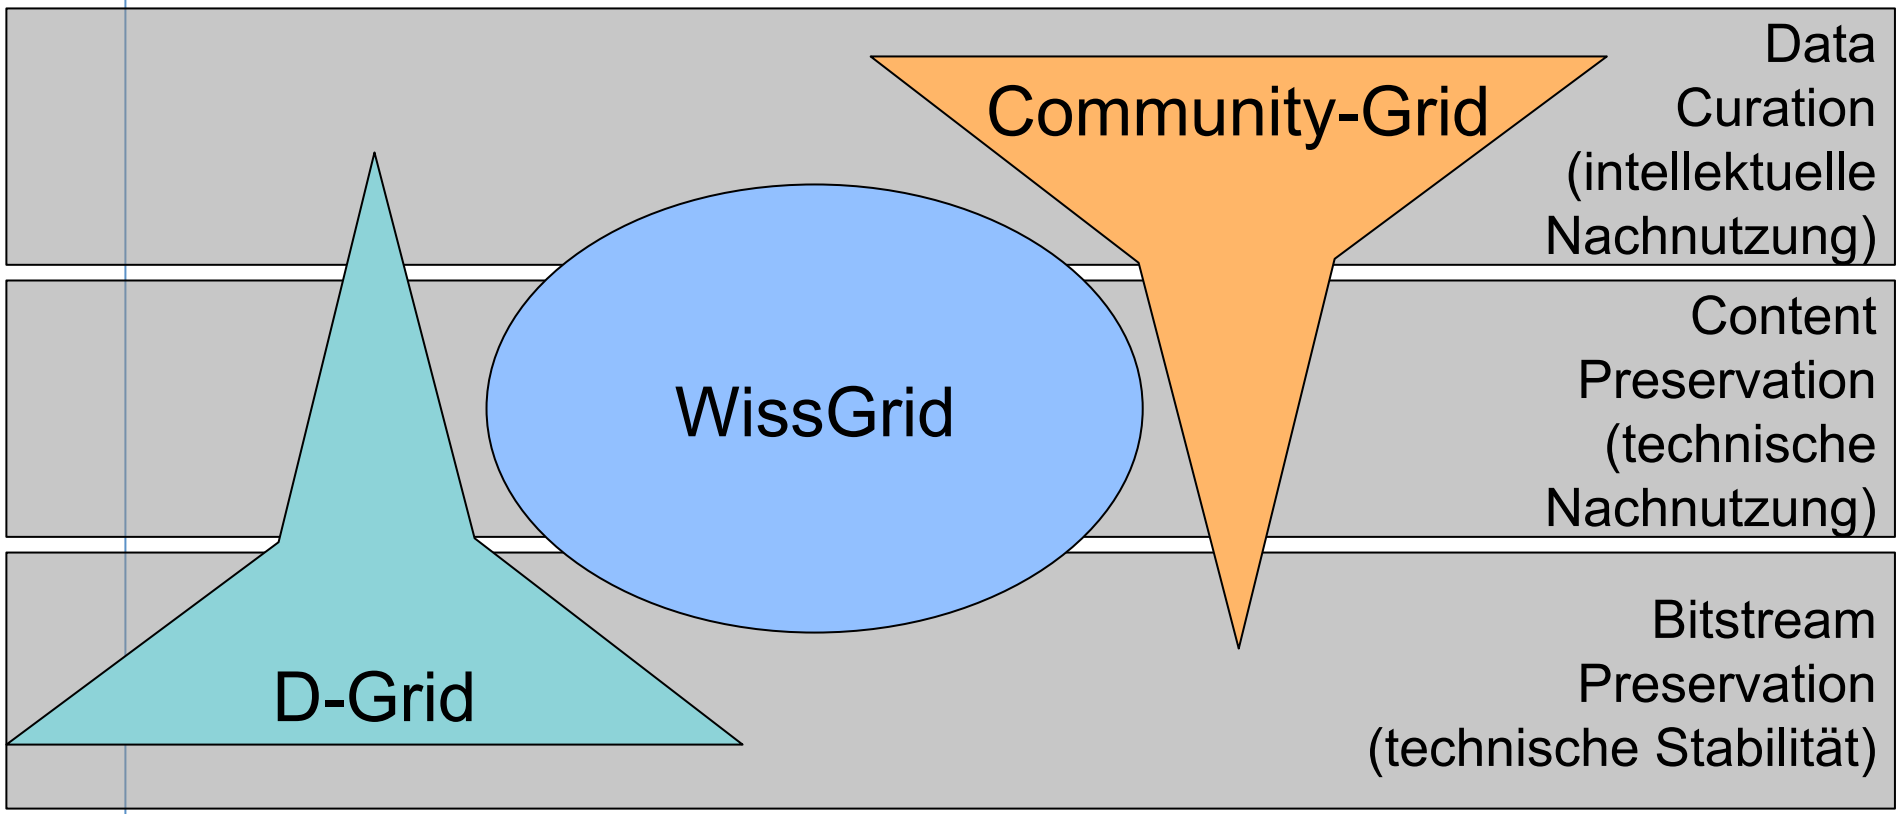

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

Architektur

- Rahmenbedingungen:
  - Kein einzelnes, technisches System
  - Keine/Kaum einheitliche, homogene Infrastruktur
  - technischer Wandel
  - große Community-Unterschiede und viele Spezifika
- Architektur ist
  - keine technische Detailarchitektur
  - sondern identifiziert wesentliche Funktionalitäten und Integrationsfaktoren
  - generisch, offen für neue Dienste, modular
  - wird ergänzt durch die Spezifikationen
- Organisatorische Faktoren werden in den LZA-Blaupausen behandelt werden

Analyse bisheriger LZA-Architekturen

- Analyse von internationalen Architekturen für LZA und Forschungsdaten
- Welche Funktionalität kann sinnvoll von wem entwickelt oder angeboten werden?
- Im Überblick...

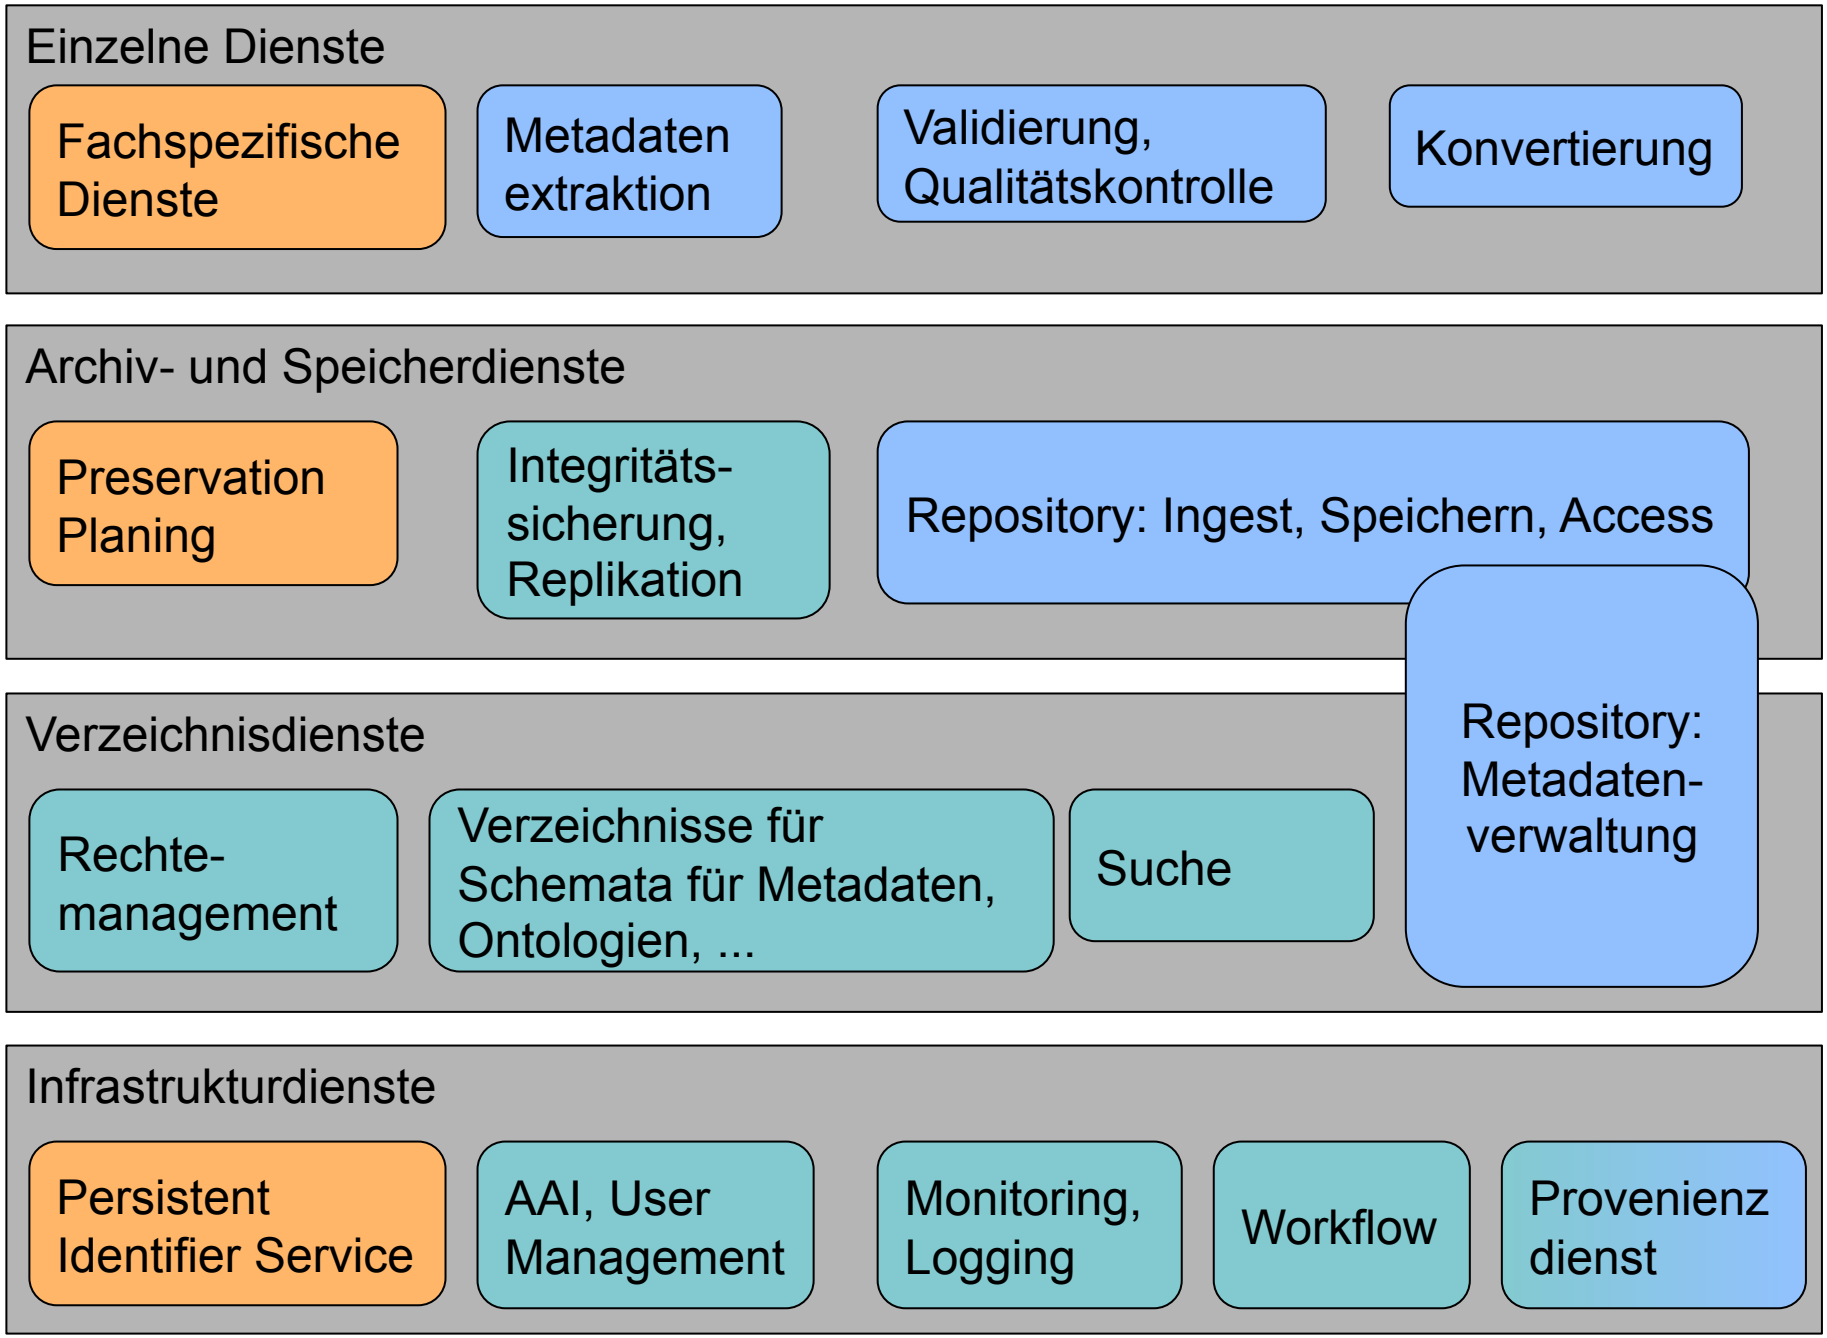
Einzelne Dienste
Fachspezifische Dienste
Metadaten extraktion
Validierung, Qualitätskontrolle
Konvertierung
Archiv- und Speicherdienste
Preservation Planing
Integritäts-sicherung, Replikation
Repository: Ingest, Speichern, Access
Repository: Metadaten-verwaltung
Verzeichnisdienste
Rechte-management
Verzeichnisse für Schemata für Metadaten, Ontologien, ...
Suche
Infrastrukturdienste
Persistent Identifier Service
AAI, User Management
Monitoring, Logging
Workflow
Provenienz dienst
WissGrid
Community
D-Grid (DGI, Projekte, ...)

Übersicht der Entwicklungen

WissGrid =
Community =
D-Grid/Infrastrukturanbieter =

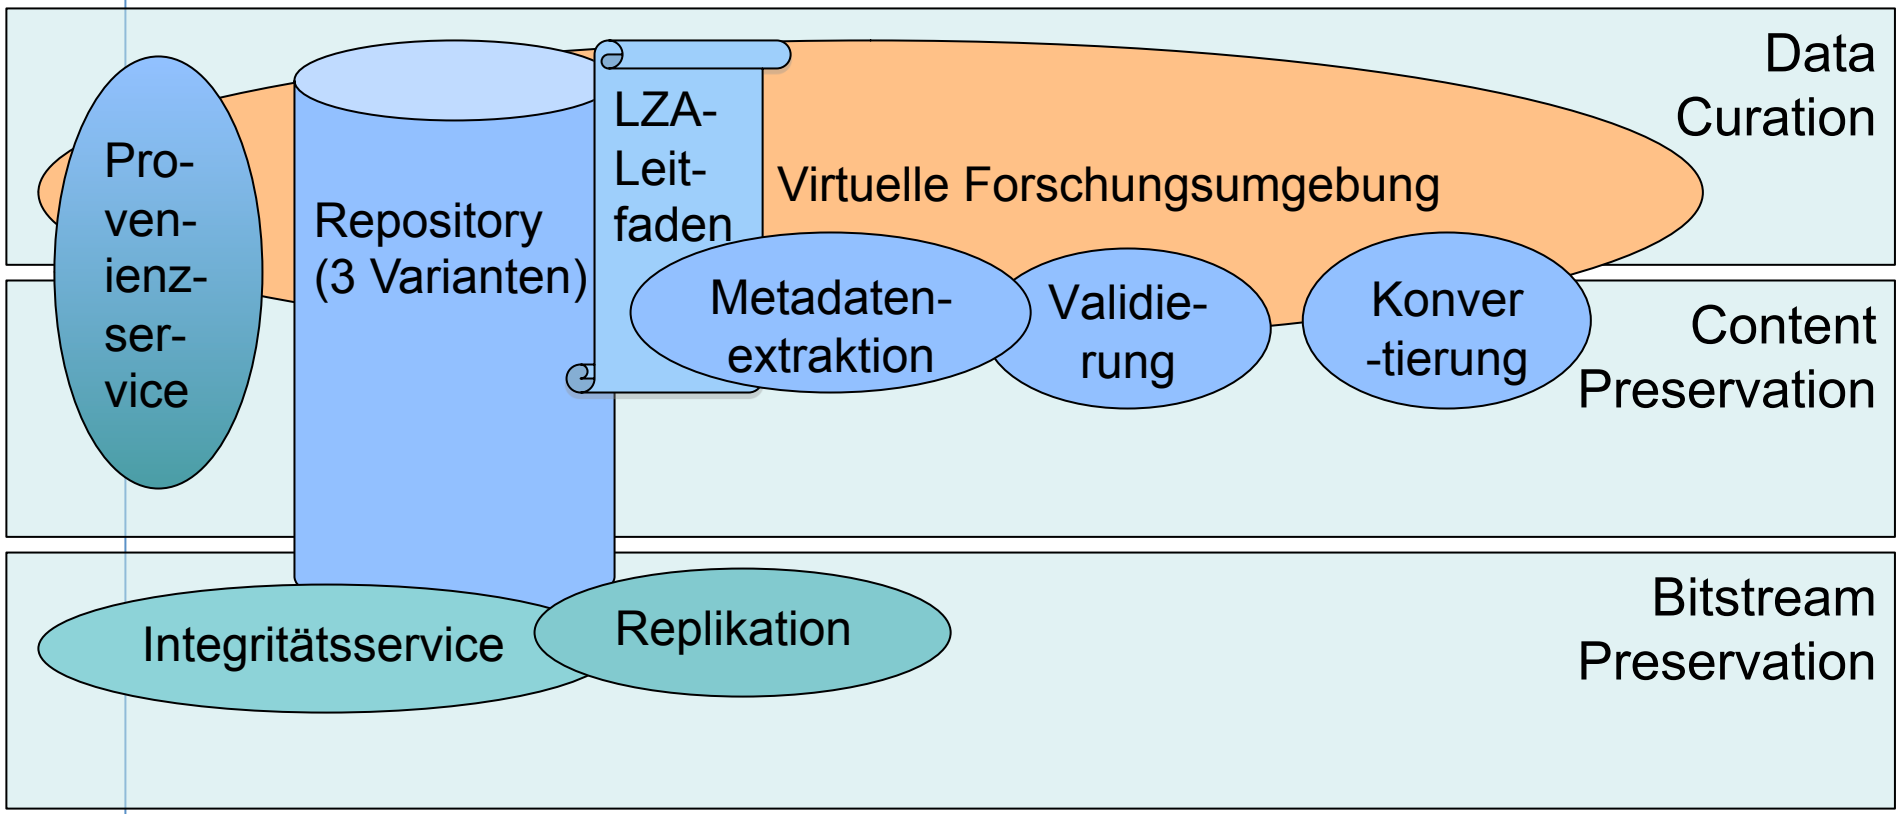

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

Communities und Kooperationen

- Wie dargestellt eine Reihe von Aktivitäten um bedarfsgerecht zu entwickeln:
  - Begleitende AG mit Vertretern der Fachdisziplinen und SUN
  - Besuche bei Fachdisziplinen
  - Fallstudien im Architekturdokument, die fortgeschrieben werden
- Drei Community-Vertreter präsentieren später ihren Stand
- Die Rückmeldungen der Communities in einer Überblickstabelle:

	Bit Preservation (Verant–wortung D-Grid)	Content Preservation						
		Metadaten-Extraktion	Validierung	Konver–tierung	Provenance (Verant–wortung D-Grid)	Repository		
						A	B	C
Astro	✗	○	○	○	○	✗	○	✗/○
C3	✗	○	✗ / ○	○	✗ / ○	✗	✗	✗
HEP	✗	–	–	–	–	✗	–	–
Medizin	✗	✗	○	○	○	○	–	–
Text	✗	✗ / ○	○	○	–	–	○	○
RadioAstro/ LOFAR	○	○	–	–	–	–	–	–
Klimafolgen	✗	○	○	○	○	✗	✗	✗
Photonen	○	○	○	○	○	○	○	○
Biostatistik	○	○	○	–	○	○	○	○
germ. Sprachwiss.	○	○/✗	○/✗	○/✗	○	–	○	–
Sowi (vorläufig)	○	○	○	○	○	–	○	○

Legende: ○ ... gewünscht

✗ ... vorhanden, Synergien möglich

Repository, Profil A: Grid-Workflowumgebung

Profil B: interaktive Umgebung

Profil C: Repositorien-Föderation

[Kooperation mit SUN]

- Sun, Forschung und Lehre
- Mitglied in der Community-AG
- Erste Gespräche haben gemeinsame Interessen gezeigt:
  - Bitstream Preservation: Anforderungen von WissGrid und Sun als Anbieter von Hardware und Mangement Software für heterogenen Storage
  - Data Curation: WissGrid liefert generische, zu integrierende Dienste und SUN ist Anbieter von Community-spezifischen Anpassungen
  - Technik: iRODS and Fedora spielen eine wichtige Rolle für WissGrid, Sun arbeitet an Forschungsumgebungen mit Fedora.

- Auftrag
- Vorgehen
- LZA-Verständnis
- Architektur
- Grid-Community-Unterstützung
- Weiterer Ablauf

Weiterer Ablauf

10:30 – 11:15 **Spezifikation und Schnittstellen**

- **Forschungsdatenarchiv**
  Andreas Aschenbrenner, SUB
- **LZA-Dienste**
  Michael Lautenschlager, DKRZ

11:15 – 11:30 Pause

11:30 – 12:30 **Anwendungsfälle und Communities**

- **Photonenphysik**
  Frank Schluenzen, DESY
- **germanistische Sprachwissenschaft**
  Andreas Witt, IDS
- **Sozialwissenschaft**
  Peter Bartelheimer, SOFI

12:30 – 13:00 **Diskussion**