

Automatische Metadatenanalyse im beweissicheren elektronischen Laborbuch

5. BeLab-Workshop 2011

Steinbuch Centre for Computing (SCC)



Agenda

- Klassifikation in BeLab
- Übersicht über implementierte Module
- Framework und Ergebnisspeicherung
- Umsetzung
- Fazit

Klassifikation in BeLab

■ Signatur

- B1 - keine
- B2 - fortgeschritten
- B3- qualifiziert
- B4 - qualifiziert+ (signierter Zeitstempel)
- B5 - akkreditiert (Signatur eines Zertifikatanbieters)
- B6 - akkreditiert+

■ Dateiintegrität

- S1 - ungesicherte Datenerzeugung
- S2 - gesicherte Datenerzeugung

■ Datenformat

- L1 - ungeeignet
- L2 - geeignet (PDF, TIFF, DOC, DOCX, XLS, XLSX, ZIP)
- L3 - empfohlen (ASCII, XML, PDF/A, PDF/E, PDF/UA, PDF/X, TIFF, SVG, ODF, TAR)

Modulübersicht

- Dateiformat
 - → Modul zur Analyse des Dateityps
- Signatur
 - → Module zur Verifikation unterschiedlicher Signaturen
- Dateiintegrität
 - bereits bestehendes Modul zur Verifikation von Kappa-Dateien
 - → Modul zur Dateifolgenanalyse

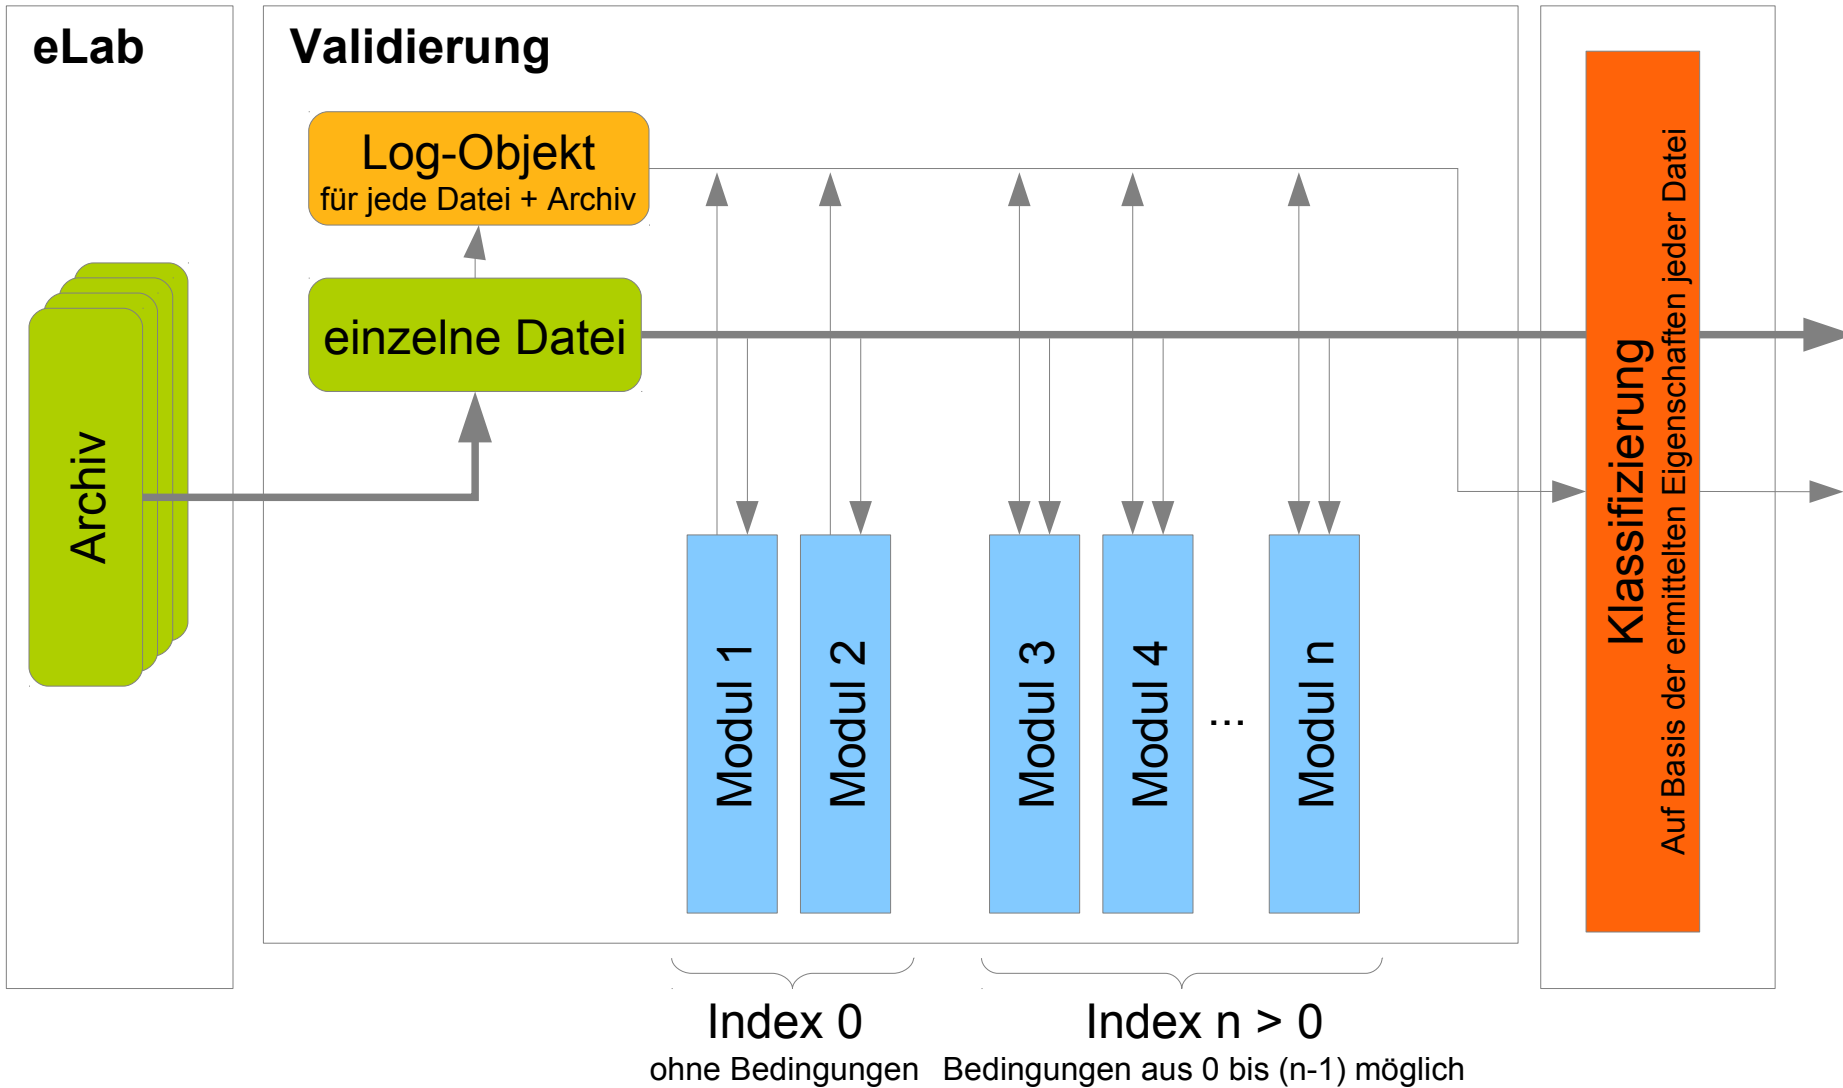
Framework

- Anforderungen:
 - Analyse auf Dateiebene
 - geeignete Auswahl entsprechender Module je Datei
 - Prüfungen bauen auf Ergebnissen anderer Prüfungen auf
 - Lese- und Schreibzugriff auf den Ergebnisspeicher
 - geeignete Reihenfolge der Prüfung notwendig

- Ergebnisspeicherung (Log-Objekt)
 - auf Dateiebene
 - enthält mehrere Einträge:
 - (**Class** type, **String** key, **Object** content)
 - Lese- und Schreibzugriff über Identifikation `key` möglich

- Modulverwaltung über XML-Datei
 - Beinhaltet jeweils Name der Klasse und Aufrufbedingungen

Framework



Implementierung der Formatanalyse

- Benchmark verschiedener Frameworks
 - jMimeMagic, MimeUtil, MimetypeFileTypeMap
 - Erkennungsraten zwischen 10% und 56.6%
 - Fehlerraten zwischen 3.3% und 33.3%

- → Kombination zweier Bibliotheken
 - 1. Prüfung durch Bibliothek mit der geringsten Fehlerrate
 - 2. bei Standardrückgabewert Prüfung durch eine weitere Bibliothek
 - → Steigerung der Erkennungsrate auf 73,3% bei 3,3% Fehlerrate

- Problem: Erkennung von ODT und DOCX als ZIP, PKCS#7 als Text
 - → Einführung einer Ersetzungstabelle auf Basis der Dateiendung
 - z.B. erkanntes Format „text/plain“ und Endung „.sha1“
 - neues Format „application/pkcs7-mime“

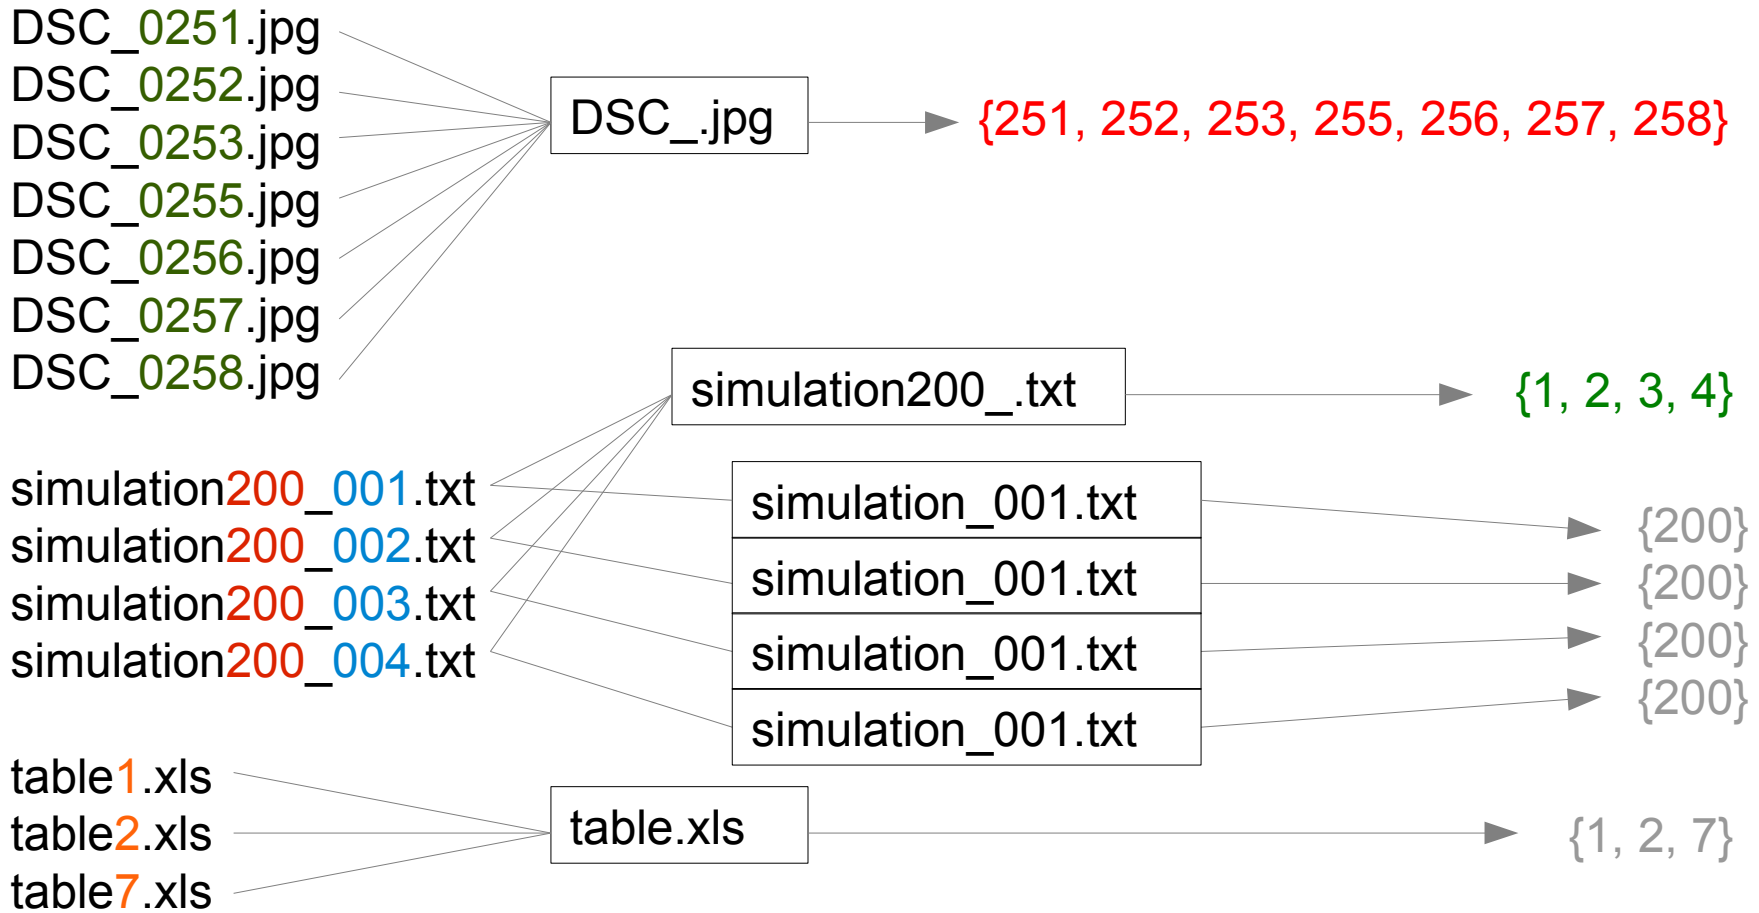
Implementierung der Signaturanalyse

- Problem: verschiedene Arten der Signatur möglich
 - XMLDSig in OpenDocument und Office Open XML
 - PKCS#7 in PDF
 - externe Signaturen auf PKCS#7-Basis

- BeLab-eigenes Werkzeug zur Verifikation von XMLDSig-Signaturen
 - Problem: Entpacken des ZIP-Archives in ein temporärer Verzeichnis nötig
 - Auswertung von Signaturen in Office Open XML nicht möglich
 - Änderung der Spezifikation zur Kanonialisierung durch Microsoft

- BouncyCastle Crypto API zur Verifikation von PDF-internen und externen Signaturen

Implementierung der Folgenerkennung



Fazit

- Aussage in den Klassifikations-Bereichen „Signatur“ und „Dateiformat“ möglich
 - Bis auf Office Open XML zuverlässige Erkennung
- Robuste Möglichkeit zur Bestimmung fehlender Dateifolgegliedern
 - Damit Erweiterung des Bereichs „Dateiintegrität“
- Leicht zu erweiterndes Framework, dadurch einfache Implementation weiterer Analysemodule möglich

Fragen?

