

Coding the Sources

Digitales Edieren in den Geisteswissenschaften

Online Summerschool und Workshop

Lübeck/Online, 17.08. – 27.08.2020



Forschungsstelle
für die Geschichte
der Hanse und des Ostseeraums



Metadaten in TEI

<teiHeader>

Torsten Roeder
torsten.roeder@leopoldina.org
Lübeck/Online, 21.08.2020



Forschungsstelle
für die Geschichte
der Hanse und des Ostseeraums



Christian-Albrechts-Universität zu Kiel

Historisches Seminar

The image features a vibrant, abstract geometric design. It is composed of several overlapping triangles in various colors: a large red triangle in the top-left, an orange triangle in the top-right, a yellow triangle on the right side, a teal triangle in the bottom-right, a dark blue triangle in the bottom-left, and a purple triangle on the left side. These triangles are separated by thin white lines. In the center, a white, irregularly shaped area contains the text "teiHeader" in a simple, grey, sans-serif font.

teiHeader

Inhalte

- Was sind Metadaten?
- Wie ist der `teiHeader` aufgebaut?
- Welche Elemente umfasst der `teiHeader`?

Voraussetzungen

- Was ist XML?
- Was ist TEI?

Metadaten?

- strukturierte Daten
- enthalten Informationen zu Merkmalen anderer Daten
- können aus den Daten direkt hervorgehen
- oder auf anderen Wegen ermittelt werden

Metadaten!

- gut miteinander vergleichbar
- fast immer standardisiert
- meistens gut maschinenlesbar
- geeignet für Weiterverarbeitung
- erzeugen viel Geld und/oder Macht
 - nur nicht in der Wissenschaft, aber:
 - sie sind Teil der Dokumentation
 - gehören zur guten wissenschaftlichen Praxis
 - tragen zum Erkenntnisprozess bei

Forschungsdaten?!

- Daten, die im Zusammenhang mit wissenschaftlichem Erkenntnisgewinn entstehen
- Forschungsdaten-Management (FDM): gute Forschungsdaten brauchen gute Metadaten!

Brainstorming

- was könnten Metadaten einer TEI-Datei sein?
- welche Sorten von Metadaten ließen sich voneinander abgrenzen?
(nutzen Sie den Chat)

Der TEI-Header

- `<teiHeader>` ist obligatorisch
- ist immer das erste Kind von `<TEI>`
- ist immer das erste Kind von `<teiCorpus>`

Vergleich des `<teiHeader>`s mit anderen Strukturelementen

- `<group>` mit mehreren `<text>`en:
 - keine Metadaten zu den einzelnen Texten
- `<front>` und/oder `<back>`:
 - diese gehörten zur Quelle
 - `<front>` oder `<back>` sagen:
"der Text auf dem Buchumschlag lautet ..."
 - der `<teiHeader>` hingegen sagt:
"der Titel lautet ..."

Aufbau des <teiHeader>s

- **<fileDesc>** [obligatorisch]
- <encodingDesc>
- <profileDesc>
- <xenoData>
- <revisionDesc>

1. <fileDesc>

- **<titleStmt>** [*]
- <editionStmt>
- <extent>
- **<publicationStmt>** [*]
- <seriesDesc>
- <notesStmt>
- **<sourceDesc>** [*]

1.1 <titleStmt>

- identifiziert das Dokument und daran Beteiligte
 - <title>, <author>, <editor> ...
 - spezifisch: <principal>, <funder>, <sponsor>

1.2 <editionStmt>

- beschreibt die vorliegende Ausgabe des Textes
- ergänzend zu <titleStmt>
- optional, wird aber empfohlen

1.3 <extent>

- beschreibt den Umfang des Textes
- Maßeinheit ist frei wählbar
- sinnvoll zum Dateivergleich

1.4 <publicationStmt>

- Informationen zum Veröffentlichungsstatus und den Beteiligten
- kann und sollte auch Informationen zur Lizenz enthalten

1.5 <seriesDesc>

- beschreibt eine Reihe, zu welcher der vorliegende Text gehört
- ergänzend zu <titleStmnt>

1.6 <notesStmt>

- Anmerkungen
- alles was wichtig ist, aber woanders keinen Platz gefunden hat

1.7 <sourceDesc>

- Quellenbeschreibung
 - <bibl>
gedruckte Quellen
 - <msDesc>
handschriftliche Quellen
 - u.v.a.
(Details später)

2. <encodingDesc>

- beschreibt editorische Methoden und Richtlinien
- dokumentiert die eigene Systematik
- als internes Referenzsystem nutzbar
- hilfreich für Nachnutzung sowie für automatische Verarbeitung

2.1 <editorialDecl>

- <correction> Eingriffe am Text
- <normalization> Schreibweisen
- <punctuation> Satzzeichen
- <quotation> Anführungszeichen
- <hyphenation> Worttrennung
- <segmentation> Textuntergliederung
- <stdVals> Standardeinheiten
- <interpretation> Analyseschema

2.2 <refsDecl>

- beschreibt die verwendeten Referenzsysteme
- hilfreich, wenn mit Normdaten, IDs oder Registern gearbeitet wird
- Standort des Referenzsystems lässt sich schablonenartig beschreiben
- im Editionstext muss dann nicht mehr die vollständige URL genannt werden

2.3 encodingDesc/*

- <projectDesc> Projekt
- <samplingDesc> Textselektionsmethode
- <classDecl> Klassifikationssystem
- <geoDecl> geograph. Referenzsystem
- <unitDecl> z.B. historische Maße
- <fsdDecl> linguistische Features
- <metDecl> Versmetrik-Notation
- <variantEncoding> Varianz-Kodierung

u.v.a.

3. <profileDesc>

- Angaben über den Text
 - <abstract> zum Inhalt
 - <creation> zur Textentstehung
 - <langUsage> zum Sprachgebrauch
 - <textClass> zur Textgattung
 - <correspDesc> zu schematischen Beschreibung von Absender und Adressaten (Korrespondenzen, Briefe)
 - <calendarDesc> zum verwendeten Kalender
 - speziell zu Korpora:
 - <textDesc>, <particDesc> und <settingDesc>
 - speziell zu Handschriften:
 - <handNotes> zu unterschiedlichen Schreibern
 - <listTranspose> zu Verschiebungen im Text

4. <xenoData>

- Metadaten in anderen Formaten
- z.B. importierte Daten aus Katalogen
- auch geeignet für den späteren Export
- Data Loop:
 - Metadaten importieren
 - Metadaten verbessern
 - Metadaten zurückspielen

5. <revisionDesc>

- Beschreibung des Bearbeitungsverlaufs
- unterschiedliche Methoden möglich
- sehr empfohlen!

<bibl>

- Beschreibung gedruckter Quellen
- Varianten:
 - <bibl> = praktisch ein Freitextfeld, einzelne Elemente können bei Bedarf getaggt werden
 - <biblStruct> = stärker durchstrukturierte Variante, interessant für systematische Verarbeitung
 - <biblFull> = Variante analog zum `teiHeader` mit <fileDesc> etc. etc.

<msDesc>

- Beschreibung handschriftlicher Quellen
- Gliederung:
 - <msIdentifier> Standort, Signatur etc.
 - <msContents> inhaltliche Beschreibung
 - <physDesc> materielle Beschreibung
 - <history> genetische Beschreibung
 - <additional> sonstiges

Fazit

- der Header ist sehr umfangreich
- viele Elemente sind sehr speziell
 - vieles wird man vielleicht nie brauchen
- mehrere Beschreibungsmethoden werden unterstützt
 - prosaischer Ansatz
 - vollständig durchstrukturierter Ansatz
- nutzbar als eigenes Referenzsystem

Wann kümmern?

- vermutlich mindestens zweimal:
 - bei der Erstellung eines Dokuments
 - beim Abschluss eines Dokuments
 - ggf. auch während der Bearbeitung eines Dokuments
- Metadatenerfassung als Teil des Erschließungsprozesses

Übung

- Verwenden Sie eine Datei, die Sie bereits bearbeitet haben und gut kennen.
- Prüfen Sie die obligatorischen Informationen im Header. Ist alles zufriedenstellend beschrieben? Können Sie die vorhandenen Informationen noch tiefer strukturieren?
- Nehmen Sie sich nun ein Metadaten-Element vor, welches noch nicht vorhanden ist, beispielsweise `<encodingDesc>`.
- Beginnen Sie mit der Prosa-Methode: Nutzen Sie zum Ausfüllen zunächst nur `<p>` und schreiben Sie hinein, was der TEI-Dokumentation zufolge dort passen könnte.
- Fahren Sie fort, indem Sie die `<p>` auflösen und stattdessen die spezifischen Header-Elemente nutzen. Vertiefen Sie den Detailgrad mithilfe der TEI-Dokumentation weitestmöglich. An welchen Stellen treten Schwierigkeiten auf?
- Versuchen Sie für Ihr Vorhaben oder für Ihre Herangehensweise eine pragmatische Grenze zwischen prosaischen und strukturierten Metadaten-Angaben zu finden. An welchen Stellen hilft Ihnen die Strukturierung?
- Vergleichen und erläutern Sie untereinander Ihre Ansätze.

Weiterführende Literatur:

<https://www.tei-c.org/release/doc/tei-p5-doc/en/html/HD.html#HD11>

Fragen?

torsten.roeder@leopoldina.org



Forschungsstelle
für die Geschichte
der Hanse und des Ostseeraums



Christian-Albrechts-Universität zu Kiel

Historisches Seminar