

Einführung in die TEI

Text Encoding Initiative

Christiane Fritze



Leopoldina
Nationale Akademie
der Wissenschaften



berlin-brandenburgische
AKADEMIE DER WISSENSCHAFTEN



Wiederholung: warum Texte kodieren?

- um maschinenlesbar (explizit) zu machen, was vom Leser implizit verstanden wird
- um Texte mit Informationen anzureichern
- um Texte nachzunutzen
- in unterschiedlichen Formaten
- in unterschiedlichen Kontexten
- von unterschiedlichen Nutzern

Übersicht

- Was ist die TEI?
 - Ein Konsortium.
 - Ein Kodierungsstandard.
- Was bietet die TEI?
 - Guidelines.
 - Werkzeuge.
 - Und Mehr.
- Wie gehe ich mit der TEI um?
 - Grundaufbau des TEI Datenmodells.
 - Guidelines benutzen.



<http://tei-c.org>

Die Gründung der Text Encoding Initiative

- Frühjahr 1987: European workshop on standardisation of historical data (J.P. Genet, M. Thaller)
- Herbst 1987: NEH funds an exploratory international workshop on the feasibility of defining „text encoding guidelines“
- Juni 1990: Release of the first draft (known as „P1“) of the Guidelines

<http://www.tei-c.org>



Vassar College, Poughkeepsie, Herbst 1987



< Text Encoding Initiative >

[Home](#) [Guidelines](#) [Activities](#) [Tools](#) [Membership](#) [Support](#) [About](#) [News](#)

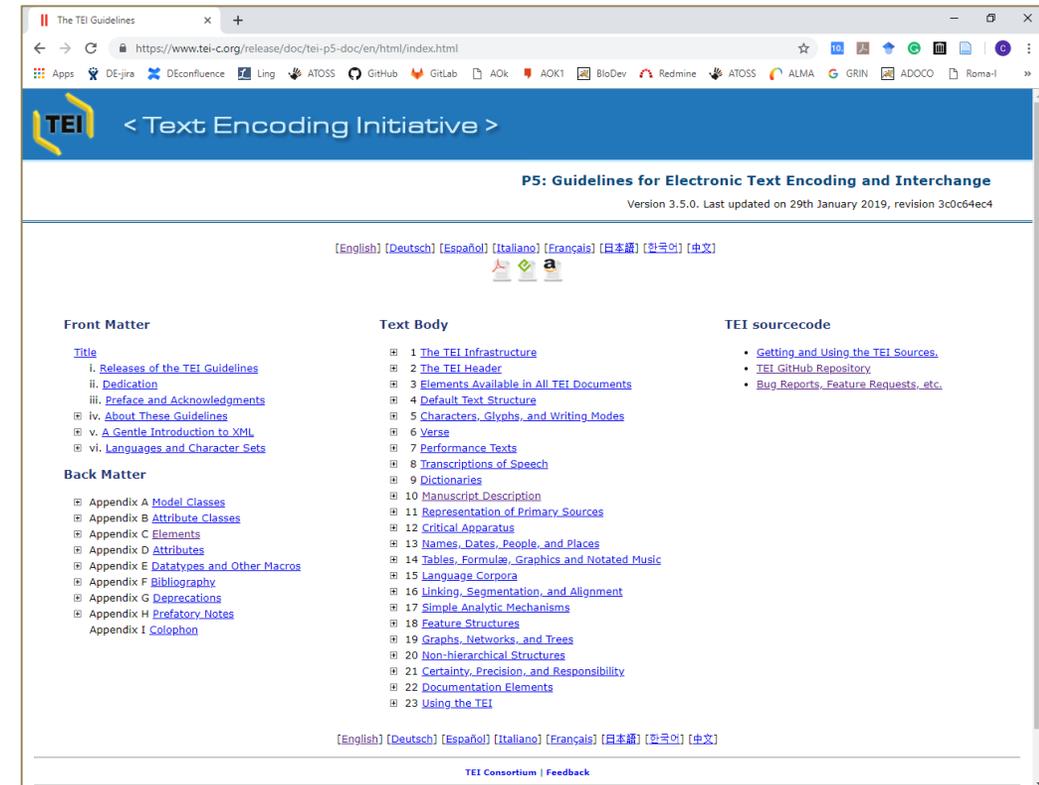
- “The TEI was established in 1987 to develop, maintain, and promulgate hardware- and software-independent methods for encoding humanities data in electronic form.”
- “Over nearly three decades the TEI has been extraordinarily successful at achieving its objective and it is now widely used by scholarly projects and libraries around the world.”
- “TEI is the de facto standard for text encoding.”

TEI Angebote - Community

- Special Interest Groups
- Annual members' meetings
 - September 2019 in Graz (Österreich)
- TEI-L Mailingliste
 - tei-l@listserv.brown.edu
 - Fragen von allen für alle auf allen Niveaus
 - Mail-Archiv:
 - <http://listserv.brown.edu/archives/cgi-bin/wa?A0=TEI-L>
 - <http://markmail.org/list/edu.brown.listserv.tei-l>
- Zeitschrift: jTEI
 - <http://journal.tei-c.org/journal/index>

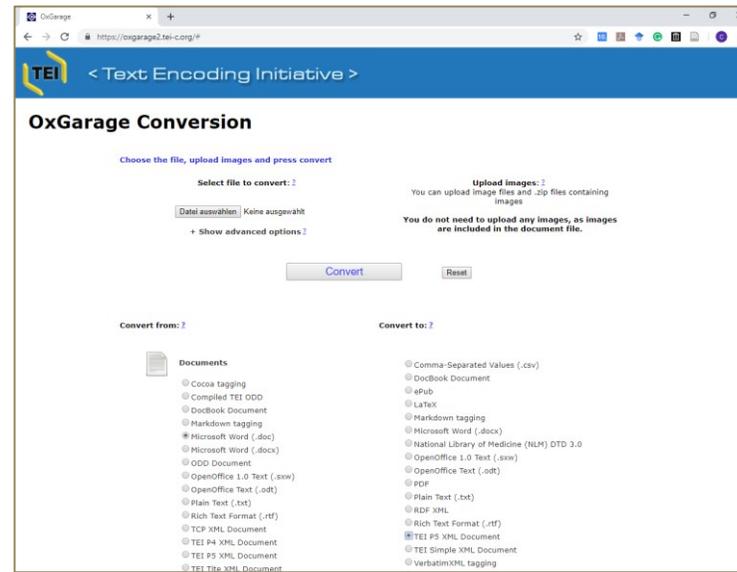
TEI Angebote - Guidelines

- **TEI P5 Guidelines for Electronic Text Encoding and Interchange**
 - Version 3.5.0.
 - Last updated on 29th January 2019, revision 3c0c64ec4
 - derzeit 1926 Seiten
- Online <https://www.tei-c.org/release/doc/tei-p5-doc/en/html/index.html>
- EPUB und MOBI Format
- PDP-Format
- Build-In im oXygen Editor

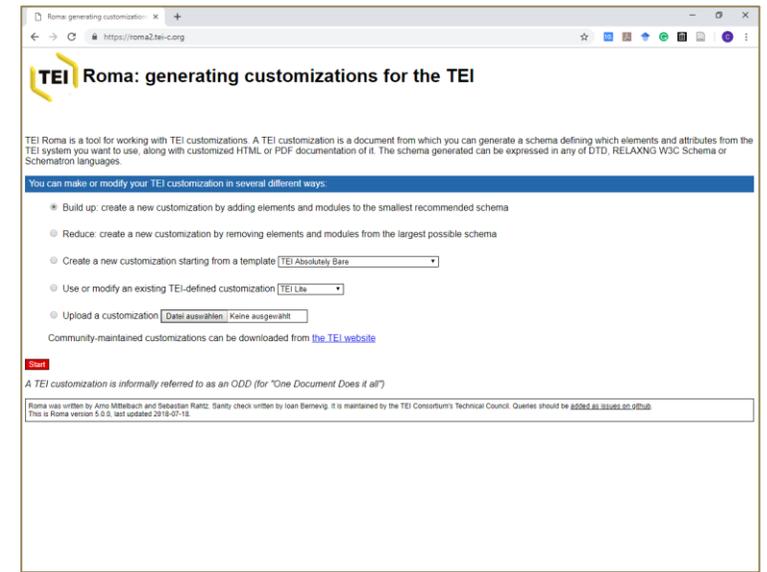


TEI Angebote – Tools

- **OxGarage:** Konversion von und nach TEI
- **ROMA:** Erstellen von Schemata und Dokumentationen
- **Stylesheets:** Konversion von TEI-Dokumenten in diverse Formatvorlagen



<https://oxgarage.tei-c.org/>

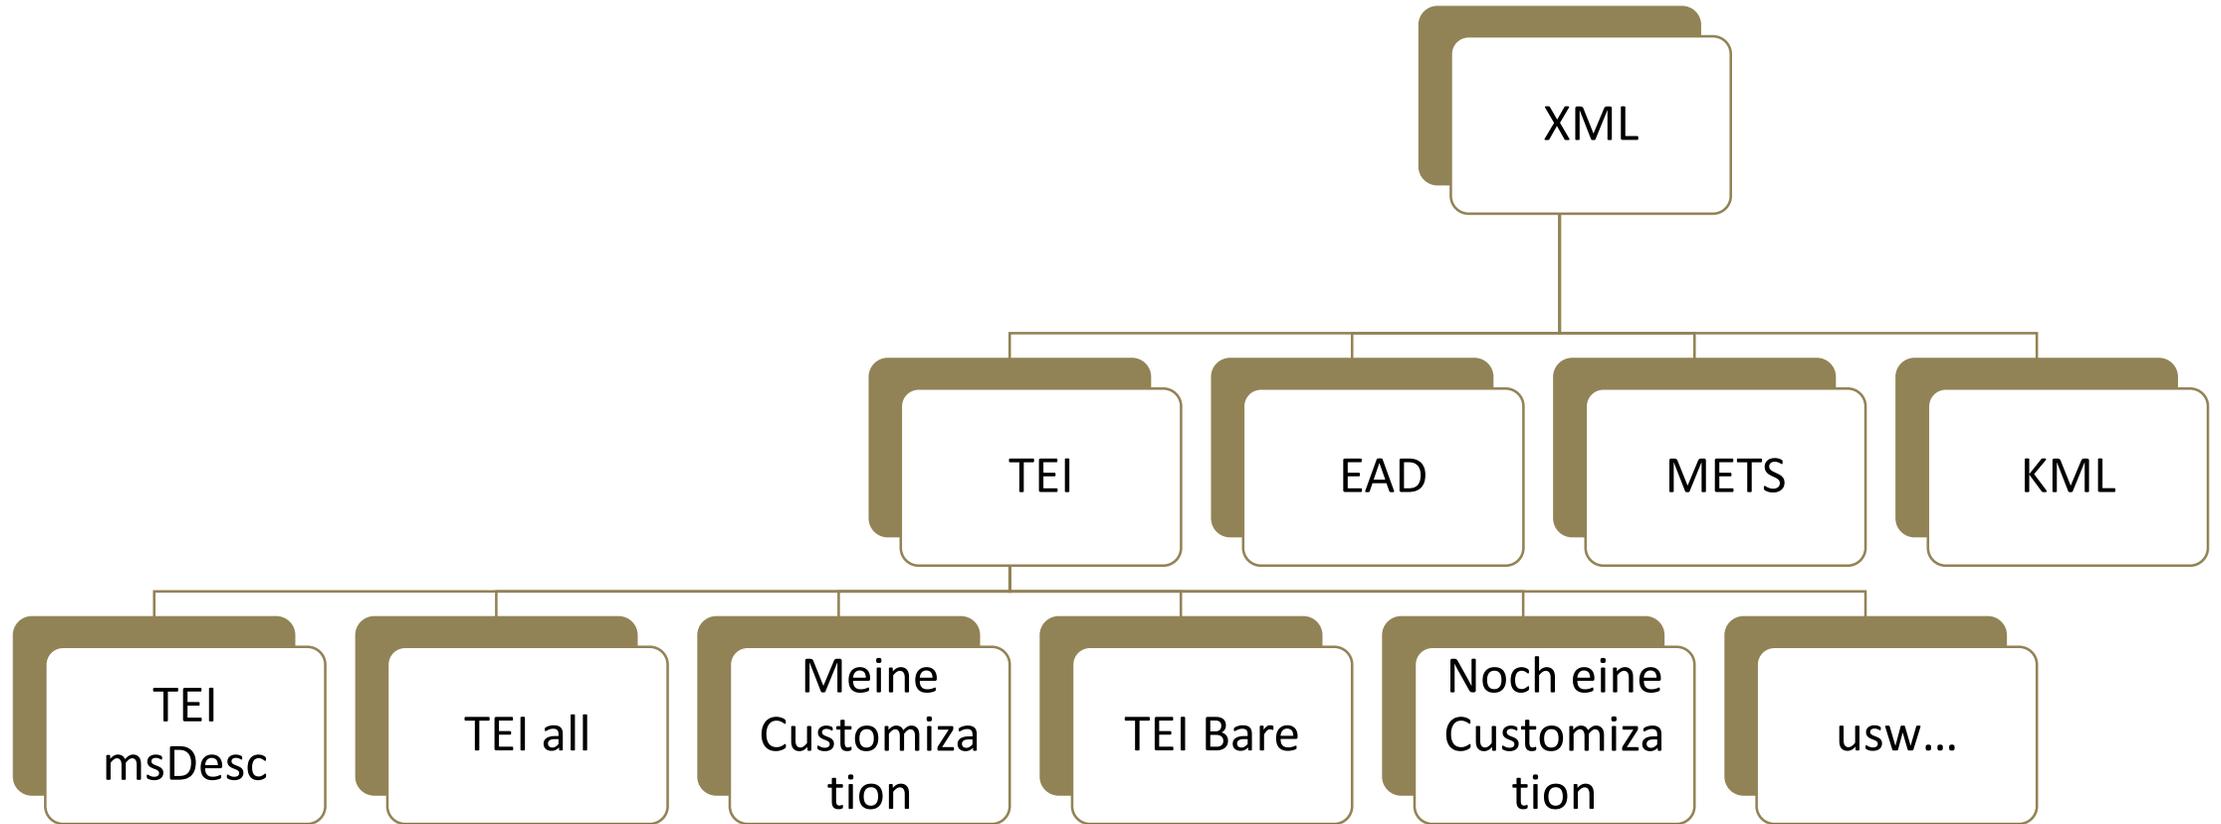


<https://roma.tei-c.org/>

XML ↔ TEI?

- XML: stellt nur die grundlegenden Regeln bereit:
 - Baumstruktur (ein Wurzelement, korrekte Schachtelung)
 - Konventionen für die Kodierung von
 - Elementen `<element/>`
 - Attributen `<element attribut="wert"/>`
 - Entity-Referenzen `&entity;` z.B. `<`
 - Kommentaren `<!-- ... -->` usw.
 - Benennungsregeln für Elemente und Attribute

TEI ist XML



TEI Guidelines

- ... sind eine Einschränkung der im Prinzip unendlichen Möglichkeiten von XML.
- ... bieten formalisierte Schemata zur Validierung von XML-Dateien.
- Fragen, die geklärt werden müssen:
 - Welche Tags für Elemente und Attribute werden bereitgestellt?
 - Wie dürfen die Tags verschachtelt werden?
 - Wie kann ich die gegebenen Möglichkeiten um eigene Regeln erweitern?

TEI Customizations

- TEI-Standard stellt mehrere hundert Elemente und Attribute bereit
- In den seltensten Fällen werden alle benötigt
- Modularer Aufbau der TEI erlaubt Definition von Untermengen des TEI-Tagsets/ Teilgruppen von TEI-Elementen zu definieren bzw. auszuwählen

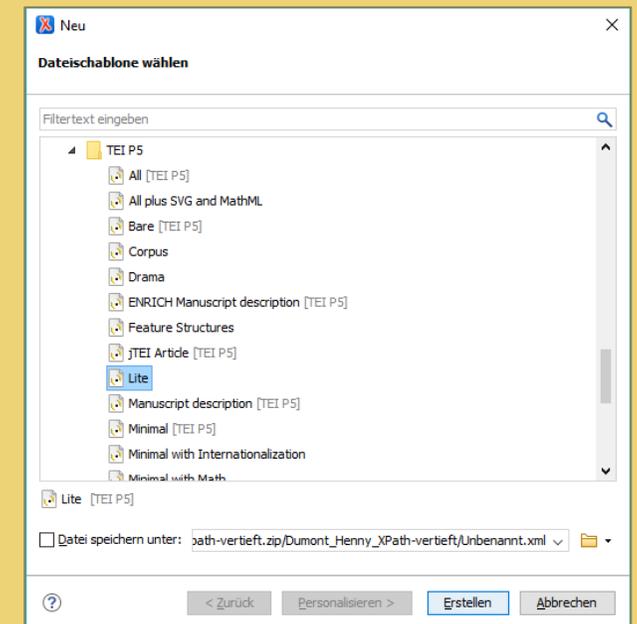


TEI Customizations

- Diese Schemata können mit Hilfe des ROMA-Tools erstellt und modifiziert werden: <http://www.tei-c.org/Roma/>
- oXygen XML editor kann Dokumente mit vordefinierten Schemata verbinden, z.B.:
 - TEI All (umfasst alle Elements, maximales Schema)
 - TEI Bare (umfasst nur absolut notwendige Elemente)
 - TEI Lite (umfasst alle wichtigen und am häufigsten gebrauchten Elemente)
 - TEI Minimal (noch weniger Elemente?)

Übung

- Öffnen Sie im Oxygen-XML-Editor ein neues XML-TEI P5-Dokument (TEI Minimal):
 - [STRG + N] → Framework-Vorlagen → TEI P5 → Minimal
- Ersetzen Sie die Platzhalter (Title, Publication information, Information about the source, Some text here) mit passenden Inhalten.



TEI ist XML

```
1 <?xml version="1.0" encoding="UTF-8"?>
2 <?xml-model href="http://www.tei-c.org/release/xml/tei/custom/schema/relaxng/tei_minimal.
3 <?xml-model href="http://www.tei-c.org/release/xml/tei/custom/schema/relaxng/tei_minimal.
4   schematypens="http://purl.oclc.org/dsdl/schematron"?>
5 <TEI xmlns="http://www.tei-c.org/ns/1.0">
6   <teiHeader>
7     <fileDesc>
8       <titleStmt>
9         <title>Title</title>
10      </titleStmt>
11     <publicationStmt>
12       <p>Information about publication or distribution</p>
13     </publicationStmt>
14     <sourceDesc>
15       <p>Information about the source</p>
16     </sourceDesc>
17   </fileDesc>
18 </teiHeader>
19 <text>
20   <body>
21     <p>Some text here.</p>
22   </body>
23 </text>
24 </TEI>
```

Repräsentation eines Dokuments

- Eine TEI-Datei repräsentiert ein „real world object“, durch
 - Metadaten ([<teiHeader>](#), u.a. [<msDesc>](#))
 - digitale Abbilder ([<facsimile>](#))
 - Transkription/„Edition“ ([<text>](#))

TEI Grundstruktur

- Wurzelement `<TEI>`
- Enthält mindestens zwei Unterelemente, nämlich
 - `<teiHeader>` für Metadaten und **muss** immer vorhanden sein und
 - `<text>` für Texte aller Art und/oder
 - `<sourceDoc>` für genetische Edition / topographische Transkriptionen und /oder
 - `<facsimile>` für Verknüpfungen und/oder
 - `<fsDecl>` v.a. für Textanalysen, linguistische Merkmale u.ä.

TEI Grundstruktur - Sonderfall `teiCorpus`

- Sonderfall `<teiCorpus>` besteht aus
 - `/teiCorpus/teiHeader`
 - `1..n /teiCorpus/TEI`
 - Vorteil: Trennung von Metadaten, die sich auf das Gesamtkorpus beziehen („Goethes Briefe“), und Metadaten, die sich auf die Teile beziehen („Brief an Eckermann v. 14.8.1830“)
 - Geeignet z.B. für:
 - sprachwissenschaftliche Korpora
 - Sammeleditionen aus mehreren Quellen
 - Briefeditionen
 - Nachlässe

```
5  ▾ <teiCorpus xmlns="http://www.tei-c.org/ns/1.0">
6  ▶   <teiHeader> [13 lines]
20 ▾   <TEI xml:id="MyTextNumber1">
21 ▶     <teiHeader> [13 lines]
35 ▶     <text> [6 lines]
42   </TEI>
43 ▾   <TEI xml:id="MyTextNumber2">
44 ▶     <teiHeader> [13 lines]
58 ▾     <text>
59 ▶         <body> [4 lines]
64     </text>
65   </TEI>
66
67 </teiCorpus>
```

<text> und Sonderfall <group>

- Das <text>-Element enthält den eigentlichen Text
 - Enthält i.d.R. ein <body>-Element
 - dazu fakultativ <front> und/oder <back>
 - oder <group>
- Sonderfall <group>: enthält 1..n <text>-Elemente
- Unterschied zw. <teiCorpus> und <group>: bei <teiCorpus> hat jeder Text einen eigenen Header, bei <group> nicht
- Die Entscheidung zw. <teiCorpus> und <group> hängt v. Editions Aufbau ab

TEI-Header – Mittwoch

- **<teiHeader>** kann aus vier Hauptteilen bestehen:
 - **<fileDesc>** (file description)
Bibliographische Beschreibung des TEIDokuments
 - **<encodingDesc>** (encoding description)
Beschreibung der editorischen Praxis
 - **<profileDesc>** (profile description)
Kodierung inhaltlicher Informationen über den Text, v.a. bei Sprachcorpora
 - **<revisionDesc>** (revision description)
Informationen über die Änderungsgeschichte des TEI-Dokuments
- **N.B.: Only <fileDesc> is mandatory.**

TEI Grundgerüst

```
<TEI>
  <teiHeader>
    <!--...-->
  </teiHeader>
  <facsimile>
    <!-- Reihe von <graphic> oder <surface> Elementen -->
  </facsimile>
  <text>
    <pb facs="page1.png" />
    <!-- text contained on page 1 is encoded here -->
    <pb facs="page2.png" />
    <!-- text contained on page 2 is encoded here -->
  </text>
</TEI>
```

<facsimile>

```
<facsimile>  
  <graphic url="page1.png"/>  
  <graphic url="page2.png"/>  
</facsimile>
```

Gruppierung ist möglich

```
<facsimile>  
  <graphic url="page1.png"/>  
  <surface>  
    <graphic url="page2-  
highRes.png"/>  
    <graphic url="page2-  
lowRes.png"/>  
  </surface>  
</facsimile>
```

Ausweis von Zonen auf der Seite ist möglich

```
<facsimile>  
  <surface  
    ulx="0"    uly="0"  
    lrx="200"  lry="300">  
    <graphic url="page1.png"/>  
    <zone  
      ulx="25" uly="25"  
      lrx="180" lry="60">  
      <desc>Titel</desc>  
    </zone>  
  </surface>  
</facsimile>
```

<text>

- Das **<text>** Element enthält den eigentlichen Text
- Struktur des Textes: Front Matter, Body, Back Matter

<text>

```
<pb facs="page1.png" />
```

```
<front> </front>
```

```
<body> </body>
```

```
<back> </back>
```

</text>

<text> Front matter

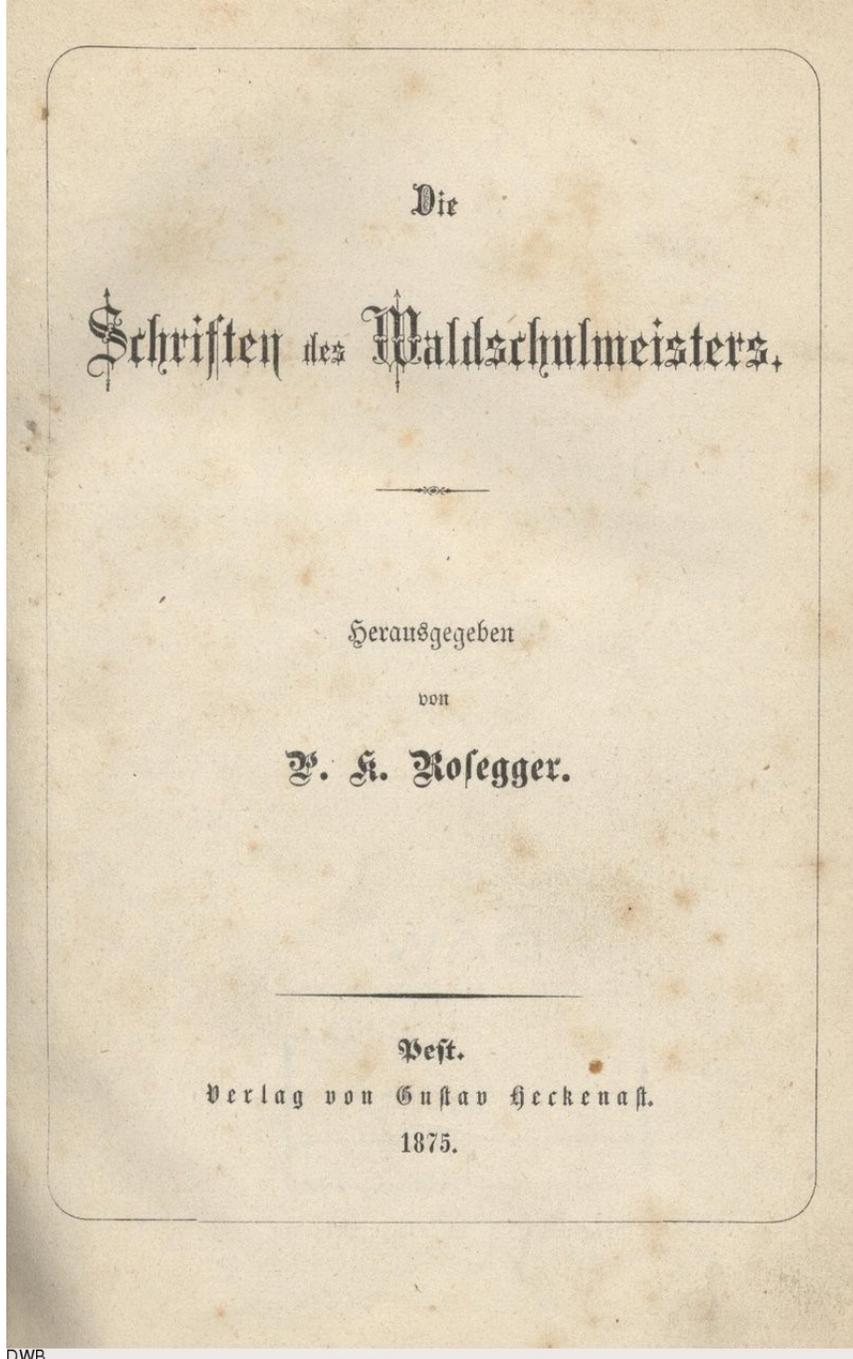
- Front Matter
 - Titelseite, Vorwort/Prolog, Widmung, ...
 - Funktionen: Identifikation, Einleitung, Aufforderung, Dank ...
 - NICHT der TEI-Header!
 - Hier wird das vorliegende Dokument transkribiert
 - Im Header dagegen werden (zusätzliche) Metadaten zur TEI-Datei notiert

- Elemente:

<titlePage>

```
<div type="preface | ack | dedication | abstract  
| contents | frontispiece | incipit | prayer"/>
```

<docTitle> <titlePart>



```
<TEI>
  <text>
    <front>
      <pb facs="#f0007"/>
      <titlePage type="main">
        <docTitle>
          <titlePart type="main"> <hi
rendition="#b">Die<lb/>
Schriften des Waldschulmeisters.</hi>
</titlePart>
          </docTitle><lb/>
          <milestone rendition="#hr"
unit="section"/>
          <byline>Herausgegeben<lb/>
von<lb/><docAuthor><hi rendition="#b">P. K.
Ro&#x017F;egger.</hi></docAuthor></byline><lb/>
          <milestone rendition="#hr"
unit="section"/>
          <docImprint>
            <pubPlace> <hi
rendition="#b">Pe&#x017F;t.</hi> </pubPlace><lb/>
            <publisher> <hi rendition="#g">Verlag
von Gu&#x017F;tav Heckena&#x017F;t.</hi>
</publisher><lb/>
            <docDate>1875.</docDate>
          </docImprint>
        </titlePage><lb/>
      </front>
    </text>
  </TEI>
```

<back>

- enthält Anhänge jeglicher Art, die auf den Hauptteil eines Textes folgen

```
<back>
  <div type="appendix">
    <head>Bibliography</head>
    <listBibl>
      <bibl>Bieler, Ludwig, The Works of St. Patrick,
        in Ancient Christian Writers (Westminster, Maryland/ London, 1953).</bibl>
      <bibl>Bieler, Ludwig, "Irish Manuscripts in Medieval Germania",
        Irish Ecclesiastical Record, 87, 5th ser. (1957), 161-169.</bibl>
      <bibl> ... </bibl>
    </listBibl>
  </div>
</back>
```

<body>

- enthält den gesamten, eigenständigen Text, außer Vorspann (front) und Nachspann (back)

```
<text>
```

```
  <body>
```

```
    <p>
```

```
      <!-- Text goes here -->
```

```
    </p>
```

```
  </body>
```

```
</text>
```

TEI-Guidelines: 4 Default Text Structure

- „division“
- Neutrales Element für Textabschnitte
- Kann beliebig tief geschachtelt
- Kann mit @type und @subty
- @n für Nummerierung
- @xml:id für Identifikation

```
<body>  
<div type="Kapitel" n="1">  
  <div type="Unterkapitel" n="1">  
    <!-- Hier kommt der Text des ersten Unterkapitels im ersten Kapitel -->  
  </div>  
  <div type="Unterkapitel" n="2">  
    <!-- Hier kommt der Text des zweiten Unterkapitels im ersten Kapitel -->  
  </div>  
</div>  
<div type="Kapitel" n="2">  
  <div n="1" type="Unterkapitel">  
    <!-- Hier kommt der Text des ersten Unterkapitels im zweiten Kapitel -->  
  </div>  
  <div n="2" type="Unterkapitel">  
    <!-- Hier kommt der Text des zweiten Unterkapitels im zweiten Kapitel -->  
  </div>  
</div>  
</body>
```

<p> <ab> <floatingText>

- **<head> ...</head>** Überschrift
- **<p>...</p>** (paragraph) Absatz
- **<ab>...</ab>** (anonymous block) irgendein Textblock
 - Textblock, ohne die Semantik von „Absatz“
- **<floatingText>...</floatingText>** schwebender Text
 - Ein bestimmter Text (jeglicher Sorte), der einen anderen Text unterbricht, der ihn umgibt
 - Kann selbst ein Einzeltext oder eine Gruppe von Texten sein
 - Kann überall vorkommen (auf allen Ebenen, beliebig tief)
 - In <floatingText> kann wieder eine komplexe Textstruktur codiert werden

Strukturelle Meilensteine

- **<pb/>** (page break) Seitenumbruch, Seitenumbruch, normalerweise der der Vorlage
- **<lb/>** (line break|beginning) Zeilenumbruch (z.B. wenn Zeilenumbrüche der Vorlage mit transkribiert werden)
 - Diskussion: vor oder nach der Zeile?
- **<cb/>** (column break) Spaltenumbruch
- **<anchor/>** Ankerpunkt (attaches an identifier to a point within a text, whether or not it corresponds with a textual element.)
- ... mit **@n**, **@type**, **@xml:id** spezifizierbar

Hervorhebung und wörtliche Rede

- **<hi>** (highlighted)
 - allgemeiner Tag für Hervorhebungen
 - z.B. für *kursiv*, **fett**, `g e s p e r r t` etc.
 - spezifizierbar durch **@rend**
- **<foreign>**, **<emph>**, **<distinct>**
 - verschiedene Hervorhebungsarten bzw. Markierung ‚ungewöhnlicher‘ Textteile (Fremdsprachiges, Betonung, Archaismen etc.)
- **<q>** (quoted)
 - für wörtliche Rede, Fachausdrücke, „sog.“ (anstelle von Anführungsstrichen)
- **<quote>** (quotation) und **<cit>** (citation) für Zitate

Mehr Elemente

- Strukturelle Texteinheiten
 - `<div>`, `<p>`, `<list>`, `<table><lg>`, `<line>`, `<index>`
- Semantische Texteinheiten
 - `<head>`, `<fw>`, `<note>`, `<quote>`, `<term>`
 - `<ref>`, `<bibl>`, `<rs>`
- Entitäten
 - `<persName>`, `<orgName>`, `<placeName>`, `<name>`
 - `<date>`, `<geo>`

[\[English\]](#) [\[Deutsch\]](#) [\[Español\]](#) [\[Italiano\]](#) [\[Français\]](#) [\[日本語\]](#) [\[한국어\]](#) [\[中文\]](#)



Front Matter

[Title](#)

- i. [Releases of the TEI Guidelines](#)
- ii. [Dedication](#)
- iii. [Preface and Acknowledgments](#)
- iv. [About These Guidelines](#)
- v. [A Gentle Introduction to XML](#)
- vi. [Languages and Character Sets](#)

Back Matter

- Appendix A [Model Classes](#)
- Appendix B [Attribute Classes](#)
- Appendix C [Elements](#)
- Appendix D [Attributes](#)
- Appendix E [Datatypes and Other Macros](#)
- Appendix F [Bibliography](#)
- Appendix G [Deprecations](#)
- Appendix H [Prefatory Notes](#)
- Appendix I [Colophon](#)

Text Body

- 1 [The TEI Infrastructure](#)
- 2 [The TEI Header](#)
- 3 [Elements Available in All TEI Documents](#)
- 4 [Default Text Structure](#)
- 5 [Characters, Glyphs, and Writing Modes](#)
- 6 [Verse](#)
- 7 [Performance Texts](#)
- 8 [Transcriptions of Speech](#)
- 9 [Dictionaries](#)
- 10 [Manuscript Description](#)
- 11 [Representation of Primary Sources](#)
- 12 [Critical Apparatus](#)
- 13 [Names, Dates, People, and Places](#)
- 14 [Tables, Formulae, Graphics and Notated Music](#)
- 15 [Language Corpora](#)
- 16 [Linking, Segmentation, and Alignment](#)
- 17 [Simple Analytic Mechanisms](#)
- 18 [Feature Structures](#)
- 19 [Graphs, Networks, and Trees](#)
- 20 [Non-hierarchical Structures](#)
- 21 [Certainty, Precision, and Responsibility](#)
- 22 [Documentation Elements](#)
- 23 [Using the TEI](#)

TEI sourcecode

- [Getting and Using the TEI Sources](#)
- [TEI GitHub Repository](#)
- [Bug Reports, Feature Requests, etc.](#)

[\[English\]](#) [\[Deutsch\]](#) [\[Español\]](#) [\[Italiano\]](#) [\[Français\]](#) [\[日本語\]](#) [\[한국어\]](#) [\[中文\]](#)

TEI Guidelines lesen

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

TEI Klassen und Datentypen

- Module → inhaltlich bzw. formal zusammengestellt
- Elemente → nach semantischen Modellen gruppiert
 - Modellklassen: `model.biblLike`, `model.choicePart`, `model.quoteLike`
- Attribute → nach Inhaltsmodell gruppiert
 - Attributklassen: `att.global`, `att.dataable.w3c`
 - Datentypen: z.B. `data.pointer`, `data.word`
- Module z.B.
 - [core](#) (Basiselemente)
 - [header](#) (Metadaten)
 - [textstructure](#) (grundlegende Textstrukturen)
 - [msdescription](#) (Handschriftenbeschreibungen)
 - [gaiji](#) (Sonderzeichen)

Globale Attribute

- **@xml:id** (eindeutiger Identifikator, muss dokumentenweit eindeutig sein, und mit einem Buchstaben beginnen, i.d.R. selbst vergeben oder automatisch erzeugt)
- **@xml:lang** (Sprache des Inhalts eines Elements)
- **@n** (Nummerierung, entweder aus Quelle übernommen oder selbst erstellt)
- **@rend** (Aussehen einer Textstelle in der Quelle!)

TEI Dokumentation lesen – Chapter „C Elemente“

- (kurze) Charakterisierung
- Welche Attribute sind im Element erlaubt?
- Innerhalb welcher Elemente darf das Element verwendet werden?
- Welche Kinderelemente darf das Element haben?
- Technische Beschreibung des Elements
- Klammerung
- Reihenfolgen → 'Komma', |
- Häufigkeiten → 'nichts', +, ?, *
- Beispiele
→ show all

TEI – Hilfe?!

- TEI P5 Guidelines:
<http://www.tei-c.org/release/doc/tei-p5-doc/en/html/index-toc.html>
- IDE: Folien, Mailinglist, Mitglieder
- TEI by Example (tutorial): <http://www.tbe.kantl.be>
- Andere TEI-Schools z.B. “TEI@Oxford”:
<http://tei.oucs.ox.ac.uk/Talks/> und
<http://tei.oucs.ox.ac.uk/Talks/2014-01-toronto/>
- TEI-L@listserv.brown.edu
- <http://listserv.brown.edu/archives/cgi-bin/wa?A0=TEI-L>
- <http://markmail.org/list/edu.brown.listserv.tei-l>

Alles wird gut

