



# Summer School “Digitale Edition”

Erschließung geisteswissenschaftlicher Quellen  
mit digitalen Methoden

5.-9. September 2016

Zentrum für Informationsmodellierung  
Austrian Centre for Digital Humanities  
Elisabethstraße 59/III, SR 81.31



# **TEI-Customization**

*Stefan Dumont*

*Unter Verwendung von Folien  
von Susanne Haaf, IDE-School 2012, Chemnitz*

# Was ist ein Schema?

- Inventar von Elementen
- Verhältnis der Elemente zueinander
- Regeln, in welchen Kontexten welche Auszeichnungen (d.h. Elemente und Attribute) möglich sind
  
- Umsetzung: DTD, XSD, RNG

Beispiele:

- TEI-Schema: tei\_all
- [http://www.tei-c.org/release/xml/tei/custom/schema/relaxng/tei\\_all.rng](http://www.tei-c.org/release/xml/tei/custom/schema/relaxng/tei_all.rng)
- TEI-Element: <correspDesc>
- <http://www.tei-c.org/release/doc/tei-p5-doc/en/html/ref-correspDesc.html>

# Schema-Spezifikation für TEI/P5

- Problem: Das tei\_all-Schema ist (intentional) sehr flexibel. Dadurch sind oft für ein Textphänomen mehrere Auszeichnungen möglich.
- Beispiel: Eigennamentagging
- → verschiedene Möglichkeiten, in TEI Personennamen auszuzeichnen
  - Element: <rs> (referencing string)  
→ <rs type="propNounPersName">
  - Element: <name> (name, proper noun)  
→ <name type="person">
  - Element: <persName> (personal name)

# Schema-Spezifikation für TEI/P5

- “[...] it is almost impossible to use the TEI scheme without customizing or personalizing it in some way.” (cf. P5 Guidelines of the TEI, ch. 23.2)
  - “Customization is a central aspect of TEI usage and the Guidelines are designed with customization in mind.”
  - (<http://www.tei-c.org/Guidelines/Customization/>)
  - “From the start, the TEI was intended to be used as a set of building blocks for creating a schema suitable for a particular project. This is in keeping with the TEI philosophy of providing a vocabulary for describing texts, not dictating precisely what those texts must contain or might have contained.”
  - (<http://www.tei-c.org/Guidelines/Customization/odds.xml>)
- Die TEI Guidelines unterstützen die Anpassung des Schemas.

# TEI-Empfehlungen für Spezifikationen

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

## Customizations provided by the TEI Consortium

<a href="#">Lite</a>	TEI Lite, the most widely used TEI customization; includes basic elements for simple documents	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a> <a href="#">HTML</a> <a href="#">PDF</a>
<a href="#">TEI Lite</a>	A constrained customization designed for use by keyboarding vendors.	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a> <a href="#">HTML</a> <a href="#">PDF</a>
<a href="#">Bare</a>	TEI Absolutely Bare, a very barebones schema with the absolute minimum of elements	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>
<a href="#">All</a>	TEI with all modules included	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>
<a href="#">Corpus</a>	TEI for Linguistic Corpora, includes the modules for encoding linguistic corpora	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>
<a href="#">MS</a>	TEI for Manuscript Description, includes the elements for describing manuscripts and complex physical aspects of documents	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>
<a href="#">Drama</a>	TEI with Drama, includes the TEI drama module	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>
<a href="#">Speech</a>	TEI for Speech Representation, includes the TEI module for spoken language	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>
Dictionaries	TEI for Dictionaries	<a href="#">ODD</a> <a href="#">DTD</a> <a href="#">RNG</a> <a href="#">XSD</a>

- Beispiel einer externen Customization:  
Basisformat des Deutschen Textarchivs  
<http://deutschestextarchiv.de/doku/basisformat>

# TEI: Customization

- ODD: „One document does it all“
- Grundlage für die TEI Guidelines, bestehend aus Dokumentation, Beispielen und den formalen Deklarationen (für Elemente, Attribute, Module, ...)
- ODD nutzt das **tagdocs**-Modul → Inventar zur Anpassung der TEI Guidelines an die eigenen Bedürfnisse
- kein direkter Eingriff in das Schema der TEI, sondern übergeordnete Anpassungsregeln

# TEI: Customization

## Einblick TEI Infrastruktur:

- **Modules:** Elemente und Attribute werden in der TEI nach ihrem Zweck gruppiert → Beispiel [persName](#): Modul "namesdates"
- **Model Classes:** Weitere Gruppierung von Elementen, um sie leichter als Kindelemente einbinden zu können  
→ Beispiel [correspDesc](#): Mitglied von [model.profileDescPart](#)
- **Attribute Classes:** Attribute sind häufig ebenfalls in Klassen definiert, um sie leichter in vielen verschiedenen Elementen einbinden zu können  
→ Beispiel: [att.canonical](#)
- **Macros:** Gruppiert Model Classes und ggf. Elemente, um sie leicht als bestimmte Inhaltsgruppen einbinden zu können  
→ Beispiel: [macro paraContent](#)

# TEI: Customization

1. Elemente entfernen
  2. Elemente umbenennen
  3. "Content models" von Elementen oder Klassen modifizieren
  4. Attribut- und Werteauswahl für Elemente und Klassen modifizieren
  5. Klassenzugehörigkeiten modifizieren
  6. neue Elemente (zu bestehenden Klassen) hinzufügen
- (Vgl. <http://www.tei-c.org/release/doc/tei-p5-doc/en/html/USE.html#MDMD>)

Mögliche Grundaktionen: add, delete, change, replace

*Achtung!* Spezifikation vs. Veränderung des TEI-Schemas: Für die Austauschbarkeit von TEI-Dokumenten ist es wünschenswert, dass TEI-Dokumente in Bezug auf tei\_all gültig sind.

# Roma

**Webtool beim Erstellen eines ODD-Dokuments:**  
**Roma <http://www.tei-c.org/Roma/>**

# Roma: Startpunkt auswählen

-  **Roma: generating customizations for the TEI**

These pages will help you design your own TEI customization, as a DTD, RELAX NG or W3C Schema.

## Create a new or upload existing customization

- Build up: create a new customisation by adding elements and modules to the smallest recommended schema
- Reduce: create a new customization by removing elements and modules from the largest possible schema

- Create customization from template

TEI Absolutely Bare

- TEI Absolutely Bare
- TEI Lite
- TEI Tit
- TEI for Linguistic Corpora
- TEI for Manuscript Description
- TEI with Drama
- TEI for Speech Representation
- TEI for authoring ODD
- TEI with SVG
- TEI with MathML
- TEI with XInclude (experimental)
- TEI with W3C ITS
- TEI for Dictionaries (experimental)

Start

Roma was written by Arno Mittelbach and is maintained by

Ivan Bernevig. Please direct queries to the [TEI @ Oxford project](#).

# Roma: Metadaten für das ODD spezifizieren

 Roma: generating validators for the TEI

Set your parameters

New Customize Language Modules Add Elements Change Classes Schema Documentation Save Customization Sanity Checker

Set your parameters

Title

Filename

Namespace for new elements

Prefix for TEI pattern names in schema

Language  English,  Deutsch,  Italiano,  Español,  Français,  Portugues,  Russian,  Svenska,  日本語,  中文

Author name

Description

Save

# Module und Elemente auswählen

- Roma:
  - Module: „Modules“ > „List of selected Modules“
  - Elemente: „List of elements in module:[Modulname]“
- ODD:
  - Module: <moduleRef> (module reference) mit @key
  - Elemente: @except oder @include in <moduleRef>
- Beispiel:

```
<moduleRef key="textstructure" except="div1 div2 div3 div4 div5 div6  
div7 group"/>  
<moduleRef key="drama" except="camera caption epilogue move  
performance prologue set sound spGrp tech view"/>
```
- *Achtung!* Module ohne <moduleRef> im ODD werden nicht eingebunden in das Schema.

# Roma: Module auswählen

## Modules

New Customize Language **Modules** Add Elements Change Classes Schema Documentation Save Customization Sanity Checker

List of TEI Modules			
	Module name	A short description	Changes
<u>add</u>	<a href="#">analysis</a>	Simple analytic mechanisms	
<u>add</u>	<a href="#">certainty</a>	Certainty and uncertainty	
<u>add</u>	<a href="#">core</a>	Elements common to all TEI documents	
<u>add</u>	<a href="#">corpus</a>	Corpus texts	
<u>add</u>	<a href="#">dictionaries</a>	Dictionaries	
<u>add</u>	<a href="#">drama</a>	Performance texts	
<u>add</u>	<a href="#">figures</a>	Tables, formulæ, notated music, and figures	
<u>add</u>	<a href="#">gaiji</a>	Character and glyph documentation	
<u>add</u>	<a href="#">header</a>	The TEI Header	
<u>add</u>	<a href="#">iso-fs</a>	Feature structures	
<u>add</u>	<a href="#">linking</a>	Linking, segmentation and alignment	
<u>add</u>	<a href="#">msdescription</a>	Manuscript Description	
<u>add</u>	<a href="#">namesdates</a>	Names and dates	
<u>add</u>	<a href="#">nets</a>	Graphs, networks, and trees	
<u>add</u>	<a href="#">spoken</a>	Transcribed Speech	
<u>add</u>	<a href="#">tagdocs</a>	Documentation of TEI modules	
<u>add</u>	<a href="#">textcrit</a>	Critical Apparatus	
<u>add</u>	<a href="#">textstructure</a>	Default text structure	
<u>add</u>	<a href="#">transcr</a>	Transcription of primary sources	
<u>add</u>	<a href="#">verse</a>	Verse structures	

Liste der verfügbaren TEI-Module

## List of selected Modules

tei  
remove core  
remove analysis  
remove certainty  
remove corpus  
remove dictionaries  
remove drama  
remove figures  
remove gaiji  
remove header  
remove iso-fs  
remove linking  
remove msdescription  
remove namesdates  
remove nets  
remove spoken  
remove textcrit  
remove textstructure  
remove transl  
remove verse  
remove tagdocs

Liste der für die eigene Spezifikation ausgewählten TEI-Module

# Roma: Elemente auswählen

## Change module

New Customize Language **Modules** Add Elements Change Classes Schema Documentation Save Customization Sanity Checker

[back](#)

### List of elements in module:namesdates

	Include	Exclude	Name	Description	Attributes
<a href="#">addName</a>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="text" value="addName"/>	(additional name) contains an additional name component, such as a nickname, epithet, or alias, or any other descriptive phrase used within a personal name.	<a href="#">Change attributes</a>
<a href="#">affiliation</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="affiliation"/>	(affiliation) contains an informal description of a person's present or past affiliation with some organization, for example an employer or sponsor.	<a href="#">Change attributes</a>
<a href="#">age</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="age"/>	(age) specifies the age of a person.	<a href="#">Change attributes</a>
<a href="#">birth</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="birth"/>	(birth) contains information about a person's birth, such as its date and place.	<a href="#">Change attributes</a>
<a href="#">bloc</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="bloc"/>	(bloc) contains the name of a geo-political unit consisting of two or more nation states or countries.	<a href="#">Change attributes</a>
<a href="#">climate</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="climate"/>	(climate) contains information about the physical climate of a place.	<a href="#">Change attributes</a>
<a href="#">country</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="country"/>	(country) contains the name of a geo-political unit, such as a nation, country, colony, or commonwealth, larger than or administratively superior to a region and smaller than a bloc.	<a href="#">Change attributes</a>
<a href="#">death</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="death"/>	(death) contains information about a person's death, such as its date and place.	<a href="#">Change attributes</a>
<a href="#">district</a>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="text" value="district"/>	(district) contains the name of any kind of subdivision of a settlement, such as a parish, ward, or other administrative or geographic unit.	<a href="#">Change attributes</a>
<a href="#">education</a>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="text" value="education"/>	(education) contains a description of the educational experience of a	<a href="#">Change attributes</a>

Liste der  
Elemente  
eines  
gewählten  
Moduls

# Module und Elemente auswählen

- Nötiges Vorwissen:
  - In welchen Modulen sind Elemente enthalten, die ich benötige?
  - Welche Module kann ich hingegen ganz eliminieren?
  - In welchen der von mir ausgewählten Module sind die Elemente enthalten, die ich verändern möchte?
- Hilfreich dabei: TEI-Elemente gruppiert nach Modulen
- <http://www.tei-c.org/release/doc/tei-p5-doc/en/html/REF-ELEMENTS.html>
- → „Show by Module“

# Module und Elemente auswählen – Beispiel

*Beispiel:* Eigennamen (vgl. Folie 3)

- Modul „namesdates“ (und somit auch das in diesem Modul enthaltene Element <persName>) entfernen
  - Roma:** „Modules“ → in der „List of selected modules“: „remove namesdates“
  - ODD: auf eine <moduleRef key="namesdates"/> verzichten
- Element <rs> (aus dem Modul „core“) entfernen
  - Roma:** „Modules“ → in der „List of selected modules“ das Modul „core“ auswählen; die „List of elements in module:core“ erscheint; dort mittels „Exclude“ das Element <rs> aus dem Modul entfernen
  - ODD: <moduleRef key="core" except="rs"/>

# Module und Elemente auswählen – Beispiel

*Beispiel:* Eigennamen (vgl. Folie 3)

- Element <name> (aus dem Modul „core“) für die Auszeichnung von Eigennamen erhalten
  - **Roma:** „Modules“ → in der „List of selected modules“ das Modul „core“ auswählen; die „List of elements in module:core“ erscheint; dort mittels „Include“ das Element <name> in dem Modul erhalten
  - ODD:
    - <moduleRef key="core"/>: erlaubt sämtliche Elemente des Moduls „core“
    - <moduleRef key="core" insert="name p quote"/>: erlaubt nur die genannten Elemente des Moduls „core“ (also auch <name>)
    - <moduleRef key="core" except="rs q said"/>: erlaubt alle Elemente des Moduls „core“, außer den genannten (also auch <name>)

# Attribute & Werte auswählen

- Die laut TEI erlaubten Attribute können eliminiert oder hinsichtlich ihrer Werte konkretisiert werden
- → Klassenweise (und somit Element-übergreifend)
  - **Roma:** „Change Classes“ → für jede Klasse unter „Change attributes“ mittels „Include“ Attribute einschließen oder sie mittels „Exclude“ entfernen; nähere Festlegungen zur Attributauswahl können von dort aus für jedes Attribut unter „Change attribute“ vorgenommen werden
  - ODD: <classSpec> (class specification)
  - Beispiel:
  - <classSpec ident="att.datcat" module="tei" type="atts" mode="delete"/>
  - <classSpec ident="att.typed" module="tei" type="atts" mode="change">  
    <attList><attDef ident="subtype" mode="delete"/></attList>  
</classSpec>

# Attribute & Werte auswählen

- Die laut TEI erlaubten Attribute können eliminiert oder hinsichtlich ihrer Werte konkretisiert werden
- → Elementweise
  - **Roma:** „Modules“ → ... „List of elements in module:[X]“ → „Change Attributes“
  - ODD: <elementSpec> (element specification) → <attDef> (attribute definition)
  - Beispiel:

```
<elementSpec ident="figure" module="figures" mode="change">
  <attList>
    <attDef ident="place" mode="delete"/>
    <attDef ident="type" mode="change" usage="opt">
      <valList type="closed" mode="replace">
        <valItem ident="notatedMusic"/>
      </valList>
    </attDef>
    <attDef ident="n" mode="delete"/>
  </attList>
</elementSpec>
```

# Attribute & Werte auswählen

- Hilfreich dabei: die Auflistung sämtlicher Elemente, die von einer bestimmten Attributklasse Gebrauch machen
  - z.B. <http://www.tei-c.org/release/doc/tei-p5-doc/en/html/ref-att.global.html>
- *Übrigens:* Übersicht über die Attributklassen in den TEI Guidelines: <http://www.tei-c.org/release/doc/tei-p5-doc/en/html/REF-CLASSES-ATTS.html>

# Schema erstellen mit Roma

- ODD auf Fehler überprüfen mit dem „Sanity Checker“  
→ derzeit nicht funktionsfähig
- ODD speichern unter „Save customization“
- Achtung! Das ODD sollte immer abgespeichert werden, damit die bestehende Spezifikation späteren möglichen Anpassungen zugrunde gelegt werden kann.
- Schema erstellen unter „Schema“  
→ Auswahl des bevorzugten Schema-Formats (RNG empfohlen)



# Arbeiten mit dem erstellten Schema

- Das Schema wird an zweiter Stelle (nach der XML-Deklaration) in die TEI-Datei eingebunden mit dem Ausdruck:
- <?xml-model href="[URL zum Schema]" schematypens="[Namensraum]"?>
- z.B. das RNG von tei.all:
- <?xml-model href="http://www.tei-c.org/release/xml/tei/custom/schema/relaxng/tei\_all.rng" schematypens="http://relaxng.org/ns/structure/1.0"?>
- Im **oXygen** kann das Schema auch durch Verwendung des Menüs „Dokument“ > „Schema“ > „Schema zuweisen“ eingebunden werden:
  - Pfad zum Schema angeben, Schematyp festlegen, OK
  - Resultat: Schema wird an der richtigen Stelle in der Datei eingebunden

# Literatur und Links

- TEI Guidelines zu ODD und Customization: Kapitel 22 und 23
- Einführung zu ODD: <http://www.tei-c.org/Guidelines/Customization/odds.xml>
- ODD-Wiki: <http://wiki.tei-c.org/index.php/ODD>
- Roma: <http://www.tei-c.org/Roma/>
  
- Zum DTA-Basisformat im Vergleich mit anderen TEI-Formaten:  
*Geyken/Haaf/Wiegand*, The DTA 'base format': A TEI-Subset for the Compilation of Interoperable Corpora (Proceedings der Konvens 2012,  
<http://www.oegai.at/konvens2012/proceedings.pdf#page=383>)
- Dokumentation des DTA-Basisformats inkl. ODD und RNG:
- [www.deutsches-textarchiv.de/doku/basisformat](http://www.deutsches-textarchiv.de/doku/basisformat)

Dieses Werk ist lizenziert unter einer [Creative Commons Namensnennung 4.0 International Lizenz.](#)



Alle darin verwendeten Werke anderer Urheber sind Zitate zu wissenschaftlichem Gebrauch.