

Die Gestorbenen (in der Wohnbev.) nach Todesursachen und Alter

Tab. 42

# “Tables are tricky”

Testing Text Encoding Initiative (TEI) Guidelines  
for FAIR upcycling of digitised historical statistics

Digital History Conference 2024

Gabi Wüthrich

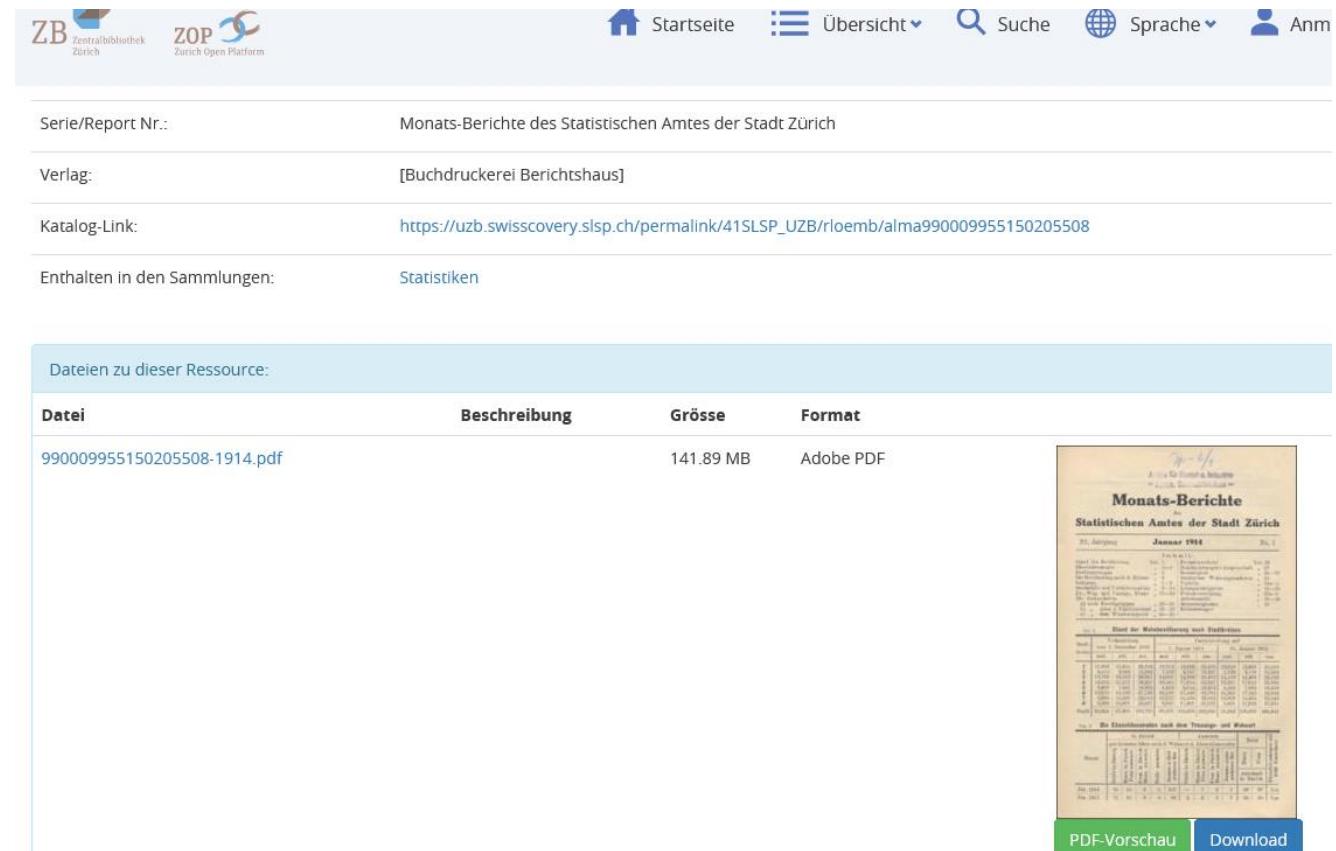
Universitätsbibliothek Zürich

## Overview

- Project(s) background and inspiration
- TEI in a nutshell
- Original Table and (code) structure of TEI table
- Challenges and conclusion

## Project Background: Digitising Demographic Statistics of Zurich

- Historical Statistics of Switzerland Online ([HSSO](#))
- Willi Bretscher Fellowship Project by Dr. Joël Floris: Digitizing demographic data from Zurich, 1910-1925, to quantify and contextualize the «[Spanish flu](#)»
- Facsimile incl. OCR published on [Zurich Open Platform \(ZOP\)](#) by Central Library (ZB)
- “Pilot” project paper “From book to machine. XML as a platform-independent, machine-readable table format” as part of CAS UZH in Data Management and Information Technologies



The screenshot shows the ZOP interface with the following details:

- Top Bar:** ZB Zentralbibliothek Zürich, ZOP Zurich Open Platform, Startseite, Übersicht, Suche, Sprache, Anm.
- Resource Details:**
  - Serie/Report Nr.: Monats-Berichte des Statistischen Amtes der Stadt Zürich
  - Verlag: [Buchdruckerei Berichtshaus]
  - Katalog-Link: [https://uzb.swisscovery.slsp.ch/permalink/41SLSP\\_UZB/rlomb/alma990009955150205508](https://uzb.swisscovery.slsp.ch/permalink/41SLSP_UZB/rlomb/alma990009955150205508)
  - Enthalten in den Sammlungen: Statistiken
- File Details:**

Datei	Beschreibung	Grösse	Format
990009955150205508-1914.pdf		141.89 MB	Adobe PDF
- Facsimile Preview:** A thumbnail image of the historical document titled "Monats-Berichte des Statistischen Amtes der Stadt Zürich" for January 1914, showing tables of demographic data.
- Buttons:** PDF-Vorschau, Download

# Inspiration: Annual Fiscal Accounts of Basle

- Digital edition of the [Basel annual accounts 1535-1611](#)
- HTML, facsimile, and table view parallelly available
- Based on XML processing in accordance with TEI and RDF (Resource Description Framework) standard
- Early example for FAIR data edition

Jahrrechnungen der Stadt Basel 1535 bis 1610 – digital  
*Beta-Version*

HOME    Jahrrechnungen    Projekt    Erweiterte Suche    Suche    Suche

Einnahmen  
Einnahmen Stadt  
Weinungeld  
Mehlungeld  
Stadtviehzoll  
Bischofviehzoll  
Pferdzoll  
Torzölle  
Wegzoll Neuer Weg  
Wiesenbrückenzoll  
Gipszoll  
Weinsticherbüchse  
Wirtshausweinungeld  
Kaufhauszoll  
Pfundzoll  
Hausgeld  
Schultheissenstock Grossbasel  
Lade  
Gewinn Salzhandel  
Schultheissenstock Kleinbasel  
Brotkarren  
Kornauffuhrzoll

Alles in den Datenkorb übernehmen  
fol. 1r [^] »

Jarrechnung a festo  
Johannis Baptistae  
anno xv<sup>c</sup> xxxx<sup>o</sup> usque  
ad festum Johannis  
Baptistae anno xv<sup>c</sup>  
xxxii<sup>o</sup>

— »

Fussnotenapparat

Jahrrechnung Stadt Basel  
1540/1541 □  
StABS Finanz H 97.1 , fol. 1r  
Rechnungslegungszeitraum:  
26.6.1540 bis 25.6.1541  
  
Transkription von:  
Sonia Calvi  
Jonas Sagelsdorff  
Zitievorschlag: Jahrrechnung Stadt Basel  
1540/1541, bearb. v. Sonia Calvi und Jonas  
Sagelsdorff, in: Die Jahrrechnungen der  
Stadt Basel 1535-1610 – digitale Edition,  
hg. v. Susanna Burghartz, Basel/Graz 2015  
(zuletzt verändert am 5.7.2021), permalink  
über DOI/handle: 11471/1010.1.1540, fol.  
1r

Datenkorb    Leeren

## FAIR Principles

- **F**indable: Persistent Identifier and rich metadata
- **A**ccessible: (Meta)data retrievable (openly) online
- **I**nteroperable: Platform-/OS independent
- **R**eusable: Well-documented (meta)data with clear data usage license

## Text Encoding Initiative (TEI)

- Consortium developing and maintaining standards for the digital representation of texts since 1994
- Version 4.8.0. of the guidelines published Sept 2<sup>nd</sup>
- 24 chapters that explain TEI and define text elements (XML-based), including tables in chapter 15
- Structural elements: TEI root, TEI header, text body
- Advantages
  - Focus on the meaning of words and texts, not on layout
  - Software-independent
  - Supported by an open scientific community
- Disadvantages of tables
  - Layout and presentation are more important than in continuous text
  - Table processing in XML notations other than TEI



# Metadata of Original Table in TEI-XML

## TEI Header Elements

- Title
- Edition Statement
- Publication Statement
- Bibliographic Information on original source

```
<?xml version="1.0" encoding="UTF-8"?>
<TEI xsi:schemaLocation="http://www.tei-c.org/ns/1.0 AdjSchema.xsd" xmlns="http://www.tei-c.org/ns/1.0"
      xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance">
  <teiHeader>
    <fileDesc>
      <titleStmt> <!-- Titel dieser XML-Datei CHECK -->
        <title>Todesursachen nach Alter im Januar 1914, Tabelle 12</title>
      </titleStmt>
      <editionStmt> <!-- Die dieser XML-Datei zugrundeliegende Edition -->
        <edition>Digitalisierte pdf-edition der historischen Statistiken</edition>
        <respStmt>
          <resp>Digitalisiert durch</resp>
          <orgName>Zurich Open Platform Zentralbibliothek Zürich</orgName>
        </respStmt>
      </editionStmt>
      <publicationStmt> <!-- Art dieser digitalen "Edition" -->
        <p>Tabelle als XML in TEI für Projektarbeit</p>
      </publicationStmt>
      <sourceDesc>
        <biblFull> <!-- Bibliografische Erfassung -->
          <titleStmt>
            <title>Monats-Berichte des Statistischen Amtes der Stadt Zürich 1914</title>
            <author>Statistisches Amt der Stadt Zürich</author>
          </titleStmt>
          <extent>S.7-8</extent>
          <publicationStmt>
            <publisher>Buchdruckerei Berichtshaus</publisher>
            <date>1915</date>
          </publicationStmt>
          <notesStmt>
            <relatedItem>
              <ref>
                <idno type="DOI">https://doi.org/10.20384/zop-869</idno>
              </ref>
            </relatedItem>
          </notesStmt>
        </biblFull>
      </sourceDesc>
      </fileDesc>
      <!-- Hier eventuell xenodata ergänzen -->
    </teiHeader>
    <!-- Ende TEI Header und Start Textbody, d.h. Start der in den Tabellen erhaltenen Informationen-->
```

# Structure Original Table in TEI-XML

## TEI Text Body

- Title
  - Table no. as note
  - Date of table
  - Table organised row by row, cell after cell
  - Cell content can be text or numeric or empty
  - Lines and long dashes ignored
- Human and machine readable but error prone...

```

<text>
  <body>
    <div>
      <head>
        <title>Die Gestorbenen (in der Wohnbevölkerung) nach Todesursachen und Alter</title>
        <note n="Tabelle 12"></note>
        <date>"Januar 1914"</date>
      </head>
      <table>
        <row role="label">
          <cell role="label">Todesursachen</cell> <!-- entspricht Zelle in der Spalte A, markiert mit
          Attributrolle Label -->
          <cell>0 bis 1</cell> <!-- entspricht Zelle in der Spalte B -->
          <cell>1 bis 5</cell> <!-- entspricht Zelle in der Spalte C -->
          <cell>5 bis 15</cell> <!-- entspricht Zelle in der Spalte D -->
          <cell>15 bis 20</cell> <!-- entspricht Zelle in der Spalte E -->
          <cell>20 bis 30</cell> <!-- entspricht Zelle in der Spalte F -->
          <cell>30 bis 40</cell> <!-- entspricht Zelle in der Spalte G -->
          <cell>40 bis 50</cell> <!-- entspricht Zelle in der Spalte H -->
          <cell>50 bis 60</cell> <!-- entspricht Zelle in der Spalte I -->
          <cell>60 bis 70</cell> <!-- entspricht Zelle in der Spalte J -->
          <cell>70 bis 80</cell> <!-- entspricht Zelle in der Spalte K -->
          <cell>über 80 J.</cell> <!-- entspricht Zelle in der Spalte L -->
          <cell>unbekannt</cell> <!-- entspricht Zelle in der Spalte M -->
          <cell ana="#sum">Zusammen</cell> <!-- entspricht Zelle in der Spalte N, markiert mit
          Attributname #sum für Summenzelle der entsprechenden Zeile -->
          <cell>Davon sind m</cell> <!-- entspricht Zelle in der Spalte O -->
          <cell>Davon sind w</cell> <!-- entspricht Zelle in der Spalte P -->
        </row>
        <row role="data">
          <cell role="label">Masern</cell> <!-- A -->
          <cell></cell> <!-- B -->
          <cell></cell> <!-- C -->
          <cell>1</cell> <!-- D -->
          <cell></cell> <!-- E -->
          <cell></cell> <!-- F -->
          <cell></cell> <!-- G -->
          <cell></cell> <!-- H -->
          <cell></cell> <!-- I -->
          <cell></cell> <!-- J -->
          <cell></cell> <!-- K -->
          <cell></cell> <!-- L -->
          <cell></cell> <!-- M -->
          <cell ana="#sum">1</cell> <!-- N -->
          <cell></cell> <!-- O -->
          <cell>1</cell> <!-- P -->
        </row>
      </table>
    </div>
  </body>
</text>
```

## Challenges

- Comprehensive TEI text elements require training time for practical implementation in XML
- Manual transfer of table content is prone to errors
- TEI's XML generates long code file for only one table
- tbc...

# Challenge: Original OCR Output

Todesursachen	0 bis 1 bis 10 bis 15	1 bis 5 bis 20	15 bis 30	20 bis 40	30 bis 50	40 bis 60	50 bis 80	60 bis 70	70 bis über 80	Unbekannt	Zusammen	Davon sind
	1	5	15	20	30	40	50	60	70	80	J.	m. w.
Masern			1							2	2	
Scharlach												
Diphtherie und Croup					1							
Keuchhusten	1		1								2	2
Rotlauf												
Unterleibstypus												
Kindbettfieber						2	1	1			4	4
Influenza												
Croupöse Lungenentzündg.						1	1	1	3	1	12	4
Tuberkulose der Lungen						4	4	1			11	7
Hirnhaut and. Organe						1	1	1	2		2	2
Andere übertragbare Krankheiten			1								3	3
Krankh. d. Verdauungsorg. darunter Brechdurchfall	2			1	1		2	5	1	1	14	8
Krankh. der Atmungsorgane	1				1	1	3	1	2		1	1
Krankh. d. Kreislauforgane						3	10	14	15	4	37	27
Hirnschlag						5	6	4	4	2	21	11
Krebs											10	10
Fruhgeburt und Lebenschwäche	10					5	6	4	4	2	7	3
Altersschwäche											5	5
Unfall	1			1	1	1	1				3	2
Selbstmord						2	1				3	2
Fremde strafbare Handig.												
Andere Todesursachen	3	1	1	1	1	5	8	4	8	3	35	21
Zusammen	19	1	4	3	9	19	27	28	39	83	11	5
Januar 1917	16	10	6	3	13	10	26	30	40	30	15	—
											199	112
											86	87

OCR text copied from pdf in table format

Tab.

Er u wu.

0,15 115|20)30|40|50 60 |70 jüber, 5| 5 Davon

Todesursachen bis bis| bis bis bis bis| bis nn bis bis 80'& = sind

1 |5|15|20|30|40|50 | 5S|ilE ee

Masern . See u 1 — 1

Scharlach ; \_ — | 1-1 1-2 -|1212)2| —1—| —

Diphtherie und Croup . d: Hz \_ -|-1-1|-/-| — .2] 2 —

Keuchhusten T - -|-1-1-1- -)- — 23—| 2

Rotlauf \$ — \_ —|-1| — Ira 1— 2-2

Unterleibstypus ; \_ —|-11- eis wur. —| — 11 —

Kindbettfieber . | - -112=+/-|-|-| 11 — 1

Influenza : Seesen 1 1—| 21 —| 2

Croupöse Lungenentzündg. 1] 11773177 = 2 1| —'— 9 3) 6

Tuberkulose der Lungen .|— 1— 1| 8 3| 2| 2) 4/— | ut 21] 13) 8

5 wsBrnnaut Eee De 1 41.21 2

ee ieDel en sl 3 2

Andere übertragbare Krankheiten 3—[—| — 11— -| 1 |—| -|= 5 2 3

Krankh. d. Verdauungsorg. 3 — —| — 1 2/1— 3) 11 — — 1165

darunter Brechhäurehfal 83 — —| — || — - Ba een 8.267

Krankh.der Atmungsorgane 6| 2 — — 11-11 2|4 — — 1 611

Krankh. d. BIER 1=)—=| 17.177174 [1578 ef=ej7832[ 151717

'Hirnschlag . ö || — 1-11 1—12|.1.1) — — Al-- 2:52

Krebs . . | — 1—| 12) 1} 54! 6) 7) —| = 2724| ° ° 6) 18

Fruhgeburt ni Tebenschwäche 10 — || eek er 20I- 7,48

Altersschwäche 1-1 - —|— 1 a 71—| 22]. 8) 14

Unfall --/-/-=f4-|2|-/-| — 6| 2 4

Selbstmord . . —|1— 21—|.11— — 11 —|— .81- 211

Fremde strafbare Handig. er el est | ee en \_ —

Andere Todesursachen . DEab 1) 4! 4|2| 4| 4 1)—| 26| 12) 14

Zusammen 32 7| 2| 322 17 19 17.40 ai 10 — 210] 921118

Januar 1913 31) 7| 2| 5|14|18 29 |27|31 32) 9— 200110 9

# Challenge: Implementing Simple XML Table Structure in Excel

1918\_12\_Vorlage\_generalTable.xlsx - Excel

Gabriela Wüthrich

Developer ribbon tab open, showing ACROBAT, Properties, Source, and XML buttons.

Cell F3 is selected, containing the formula: `=In der Wohnbevölkerung Gestorbene Kreis 5`.

The XML Source pane shows the following structure:

```


    <!-- cellB -->
    <!-- cellC -->
    <!-- cellD -->
    <!-- cellE -->
    <!-- cellF --> (highlighted with a yellow circle)
    <!-- cellG -->
    <!-- cellH -->
    <!-- cellI -->
    <!-- cellJ -->
    <!-- cellK -->
    <!-- cellL -->
    <!-- cellM -->
    <!-- cellN -->
    <!-- cellO -->
    <!-- cellP -->
    <!-- cellQ -->
    <!-- cellR -->
    <!-- cellS -->

```

To map repeating elements, drag the elements from the tree onto the worksheet where you want the data headings to appear.

To import XML data, right click an XML mapped cell, point to XML, and then click Import.

Options XML Maps... Verify Map for Export...

Sheet tabs: 1918\_13\_simple\_format\_Orig, 1918\_13\_XML-Map (highlighted)

Ready

## Challenges

- Comprehensive TEI text elements require training time for practical implementation in XML
- Manual transfer of table content is prone to errors
- TEI's XML generates long code file for only one table
  
- OCR recognition in digital copies needs to be adjusted for tables – or image quality needs to be good enough
- TEI schema not suitable for direct table mapping in Excel yet
- OCR and TEI are flow text oriented → Table recognition and XML structure are correspondingly poor for structured text
- Chicken-and-egg problem: More (XML) table templates for better text recognition (esp. wrt LLMs)?

## Conclusion

- Upcycling tables according to TEI guidelines is generally possible
- TEI offers tools that can be used to capture complex structures of historical tables in XML format
- TEI can be used to track changes in table structures
- TEI enables platform- and software-independent processing of table data – so do .csv and .txt
- TEI generally suitable for structuring continuous text, less suitable for texts where structure determines meaning

## Potential Extensions

- Update to current TEI version
- Integration of additional TEI elements for formatting (e.g. separators, long dashes) and meaning (gender)
- Using LLMs to automatically do the OCR to XML procedure, BUT
  - Image quality and OCR remain problematic
  - Proper and detailed explanation of complex structure in prompting
  - Easy transformation from xlsx to XML
- Testing different Python tools for table recognition, e.g. using Aurelius Noble's workshop
- Check developments in other digitisation projects
  - XSLT (eXtensible Stylesheet Language Transformation) for automated structuring of Excel



Die Gestorbenen (in der Wohnbev.) nach Todesursachen und Alter  
Tab. 42

Todesursachen	0	1	5	15	20	30	40	50	60	70	über	Zusammen	Davon sind
	bis	80											
	1	5	15	20	30	40	50	60	70	80	J.		
Masern . . . . .	—	—	—	1	—	—	—	—	—	—	—	1	— 1
Scharlach . . . . .	—	—	—	—	—	—	—	—	—	—	—	—	— —
Diphtherie und Croup . . . . .	—	—	—	—	—	—	—	—	—	—	—	2	2 —
Keuchhusten . . . . .	—	—	1	1	—	—	—	—	—	—	—	2	— 2
Rotlauf . . . . .	—	—	—	—	—	—	—	1	—	1	—	2	— 2
Unterleibstyphus . . . . .	—	—	—	—	—	—	1	—	—	—	—	1	1 —
Kindbettfieber . . . . .	—	—	—	—	—	1	—	—	—	—	—	1	— 1
Influenza . . . . .	—	—	—	—	—	—	—	—	1	1	—	2	— 2
Croupöse Lungenentzündg.	—	—	—	—	1	3	1	—	2	1	—	9	3 6
Tuberkulose der Lungen . . . . .	—	—	—	—	—	2	2	4	—	—	—	21	13 8
” Hirnhaut . . . . .	1	—	1	—	—	1	—	1	—	—	—	4	2 2
” and. Organe . . . . .	—	1	—	—	1	1	1	—	1	—	—	5	3 2
Andere übertragbare Krankheiten . . . . .	3	—	—	—	1	—	—	1	—	—	—	5	2 3
Krankh. d. Verdauungsorg. darunter Brechdurchfall . . . . .	3	—	—	—	1	2	1	—	3	1	—	11	6 5
Krankh. der Atmungsorgane . . . . .	6	2	—	—	1	—	1	1	2	4	—	17	6 11
Krankh. d. Kreislauforgane . . . . .	1	—	—	1	1	1	1	4	15	8	—	32	15 17
Hirnschlag . . . . .	—	—	—	—	—	—	2	1	1	—	—	4	2 2
Krebs . . . . .	—	—	—	—	1	1	5	4	6	7	—	24	6 18
Frühgeburt und Lebensschwäche . . . . .	10	—	—	—	—	—	—	—	—	—	10	7 3	
Altersschwäche . . . . .	—	—	—	—	—	—	—	—	1	14	7	22	8 14
Unfall . . . . .	—	—	—	4	—	2	—	—	—	—	—	6	2 4
Selbstmord . . . . .	—	—	—	2	—	1	—	—	—	—	—	3	2 1
Fremde »Todesursachen« . . . . .	5	1	4	4	4	9	4	4	4	1	—	26	12 14
Andere Todesursachen . . . . .	5	1	4	4	4	9	4	4	4	1	—	—	— —

«Tables are tricky»

Lou Bernard via TEI-Mailing-List

</Thank you>