

Hidden Markup – The Digital Work Environment of the “Digital Dictionary of Surnames in Germany”

Franziska Horn, Jörg Hambuch, Sandra Reker

**Balisage: The Markup Conference
2-5 August 2016**



English surnames published in the Dictionary



English surnames published in the DFD (version from July, the 27th 2016),
word cloud is based on frequencies (logarithmized).



Outline

- Project Presentation
- General Description of the Work Environment Onodi
- New Onodi Features in Detail
 - Copying of UUIDs
 - Managing Bibliographical References
 - Publishing Workflow
- Conclusion



Project Presentation



Partners and Aim

- Academy of Sciences and Literature Mainz, Technische Universität Darmstadt and Johannes Gutenberg University Mainz
- preparation of the first-ever comprehensive digital dictionary of surnames in Germany

Data basis with
all 850 000
surnames
2012



DFD with 200 000
published articles

2036



Project Presentation



Features of DFD Articles

- etymology and origin
- geographical distribution of the surname
- the occurrence of the name in countries other than Germany
- morphological or semantic variants
- further reading on the topic

A screenshot of the DFD website interface. At the top, there's a navigation bar with the text "DIGITALES FAMILIENNAMENWÖRTERBUCH DEUTSCHLANDS (DFD)" and "namenforschung.net". Below the navigation bar, there are four tabs: "WÖRTERBUCH" (selected), "PROJEKTVERSTELLUNG", "MITARBEITER/INNEN", and "AKTUELLES". A green banner with white dots serves as a background for the main content area. The main content area shows the search result for the surname "Miller". Below the search term, there are several navigation links: "Allgemeines", "Etymologie", "Verbreitung", "Verwandte Artikel", "Literatur", and "Metadaten". To the right, there's a sidebar titled "Kategorien" with a list: "zu Bedeutung 1: Beruf, Nahrungsmittelherstellung, Müller". At the bottom, there's a section titled "Glossareinträge" with a link "Entrundung".

Allgemeines Etymologie Verbreitung Verwandte Artikel Literatur Metadaten

Häufigkeit 7268

Rang 512

Sprachvorkommen deutsch
englisch

Herkunftsland Deutschland
Großbritannien
USA

Kategorien

zu Bedeutung 1:

- Beruf
- Nahrungsmittelherstellung
- Müller

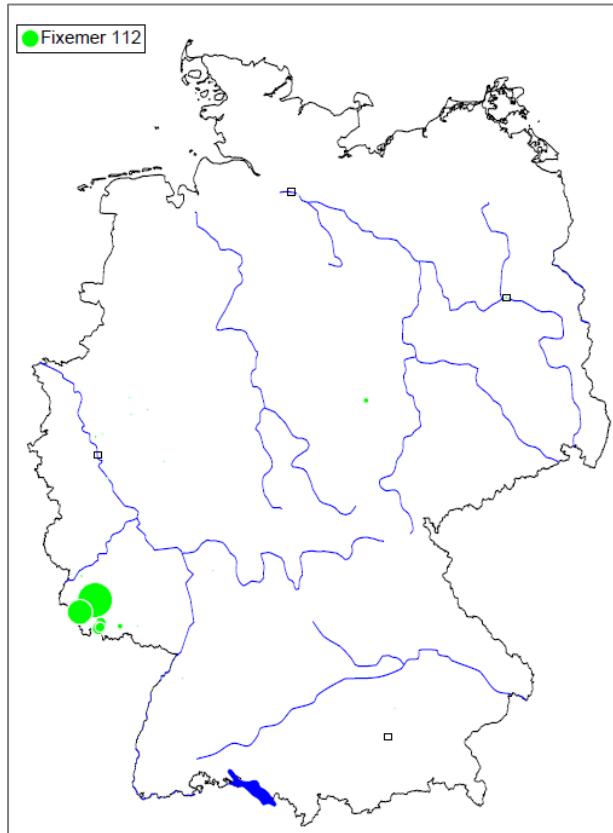
Glossareinträge

▶ Entrundung

Project Presentation



Mapping Surnames



Project Presentation

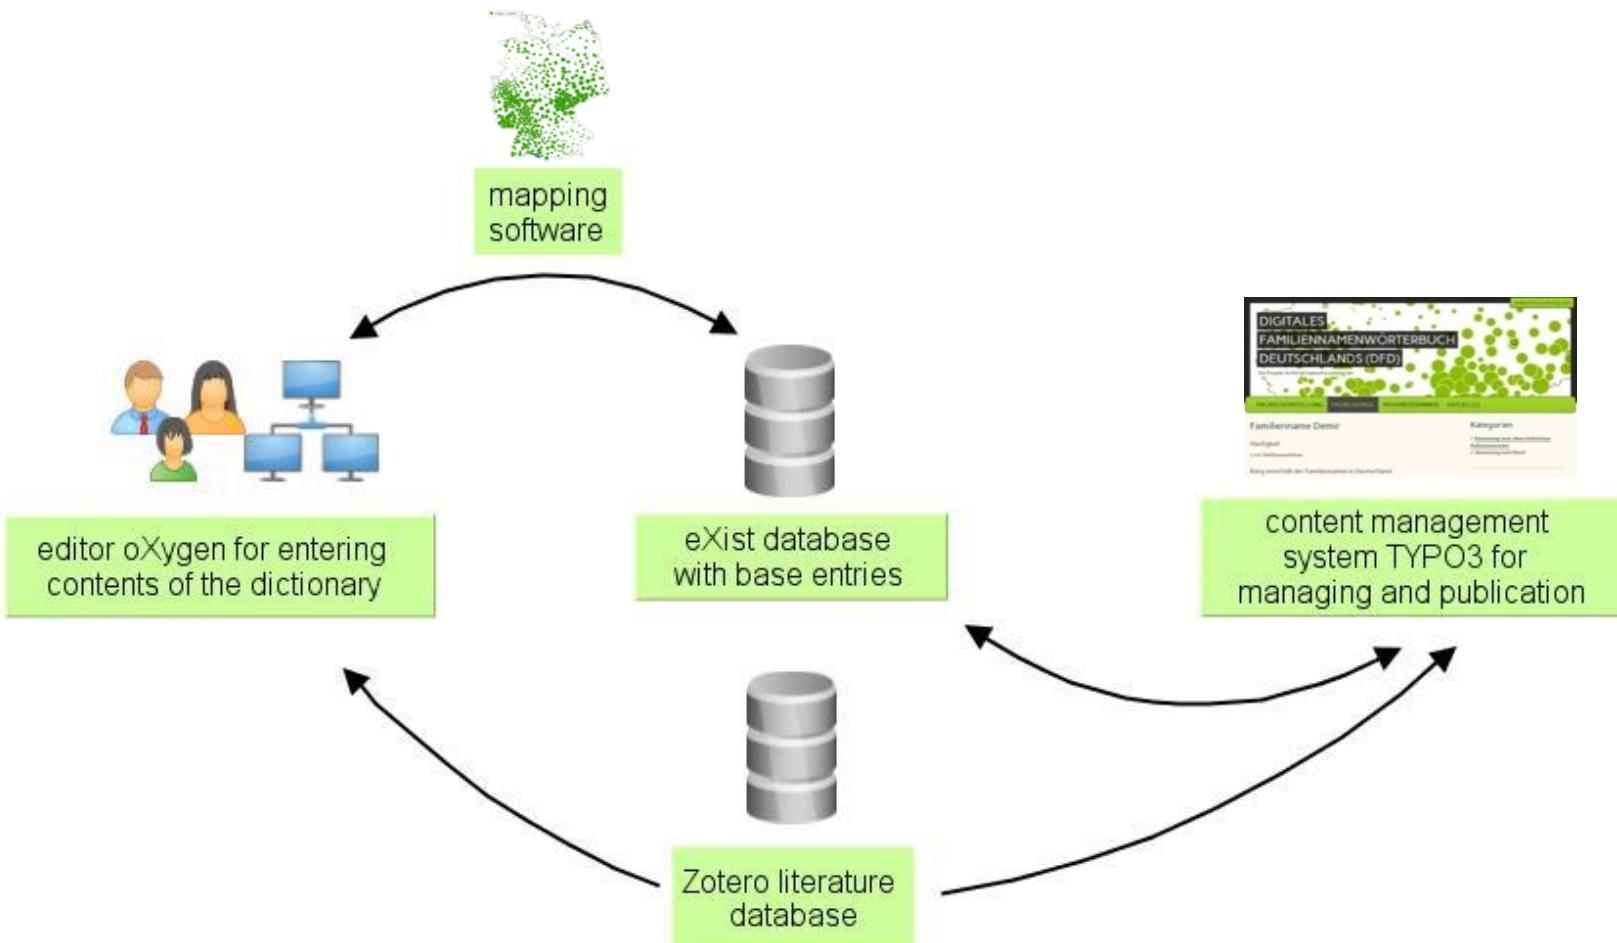


Relevance

- shortcomings of previous surname dictionaries
- resource for other research disciplines (e.g. dialectology, migration research)



Work Environment Onodi



User Interfaces for Editing Contents in the CMS



A screenshot of the TYPO3 CMS backend interface. On the left, there's a sidebar with navigation links for 'WEB' (Seite, Liste, Papierkorb, News), 'DATEI' (Dateiliste), and 'BENUTZERWERKZEUGE' (Einstellungen). The main area shows a file tree under 'namenforschung.net/namenforschung'. A modal window is open for editing a section titled 'Überschrift'. The 'Text' tab is active, displaying a rich text editor toolbar with various styling options like bold, italic, and lists. Below the toolbar is a large text area containing a paragraph about surnames. The right side of the screen shows a vertical scroll bar with some text snippets visible.

User Interfaces for Editing Contents in the XML Editor



The screenshot shows the oXygen XML Editor interface with several UI elements highlighted:

- a)** TEI-DFD tab in the top menu bar.
- b)** Toolbar icons for file operations like Open, Save, Print, and XML/XSLT.
- c)** Kategorie input field and "neue Kategorie" button in the left sidebar.
- d)** "Bewertung des Artikels:" dropdown menu with options: Neubewertung, Präzisierung der Deutung, Erstaufnahme, Neudeutung, Erstdeutung, and Zusammenführung.
- e)** Contextual menu open over a list of TEI elements.
- f)** Gliederung (Outline) view showing the hierarchical structure of the XML document.
- g)** Datenquellen Explorer (Data Sources Explorer) view showing the project structure and files.

The main workspace displays the XML code for "Gaa.xml". The context menu (e) lists various TEI elements and their keyboard shortcuts:

- neue öffnende spitze Klammer Strg+K
- neue schließende spitze Klammer
- neue etymologische Angabe Alt+E
- neue Sprachangabe
- neue metasprachliche Angabe Strg+M
- neue Übersetzung Strg+G
- neuer Verweis Strg+L
- neue BedeutungsID
- neuer Personenname
- neuer Familiennname
- neuer Rufname
- neues Etymon
- Zitieren
- Geographische Angaben
- Grammatische Angaben
- Listen
- Erneut laden
- Tags-Anzeigemodus
- Profiling/Bedingter Text

Editing Interface and XML Code



Haupt- oder Verweisartikel?

Familienname: **Ferraro**

Formbeschreibung des Appellativs:

Häufigkeit: 208
Rang innerhalb der Familiennamen in Deutschland: 18215

Herkunft und Bedeutung

Herkunftssprache:

Herkunftsland:

Herkunftsregion:

[Regionenliste ansehen](#)

```
<text>
  <body>
    <entry type="main">
      <form>
        <orth>Ferraro</orth>
        <form type="derivate"/>
        <pron/>
      </form>
      <usg type="token">208</usg>
      <usg type="rank">18215</usg>
      <etym>
        <lang xml:lang="it"/>
        <country key="IT"/>
        <region/>
      </etym>
    </entry>
```

Editing Interface and XML Code



Haupt- oder Verweisartikel?

Familienname: **Ferraro**

Formbeschreibung des Appellativs:

Häufigkeit: 208
Rang innerhalb der Familiennamen in Deutschland: 18215

Herkunft und Bedeutung

Herkunftssprache:

Herkunftsland:

Herkunftsregion:

Regionenliste ansehen

```
3 /* Angabe der Herkunftssprache über Eingabefeld */
4 <entry> <etym> <lang>
5   color:black;
6   content:
7   oxy_label(text, "Herkunftssprache: ")
8   oxy_editor(
9     type, combo,
10    edit, "@xml:lang",
11    editable, false,
12    values, "x-DFD, x-prg-o, ar, arc, ben, bs, bg, cmn, de, da, en, et,
13    labels, "keine Angabe, altpreußisch, arabisch, aramäisch, Benga
14    line-height:2;
15  }
16
17 /* Button zum Hinzufügen einer Sprache */
18
19 <entry> <etym> <lang[xml|lang]:after>
20   content:
21   "\A"
22   oxy_editor(
23     type, button,
24     actionID, "Herkunftssprache")
25   "\A";
26 }
```

Consistent Data Input

Weblinks

[neuer Weblink](#)

URL: drw-www.adw.uni-heidelberg.de/drw-cgi/zeige?term=H%C3%BCfner&index=lemmata

Artikel *Hufner, Hüfner* in: Deutsches Rechtswörterbuch

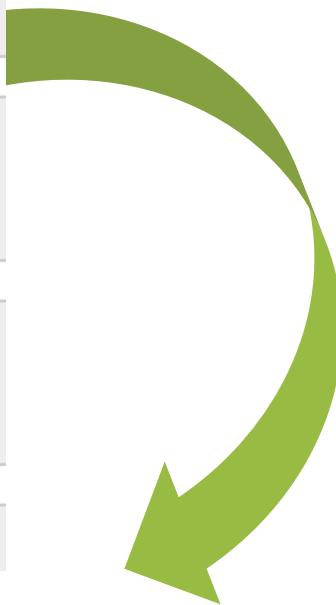
Letzter Zugriff: (2016-03-29) [neuer Weblink](#)

März	2016					
Mo	Di	Mi	Do	Fr	Sa	So
1	2	3	4	5	6	
7	8	9	10	11	12	13
14	15	16	17	18	19	20
21	22	23	24	25	26	27
28	29	30	31			

URL: <http://www.woerterbuchnetz.de/DWB?bookref=10,1867,16>

Artikel *Hufe* in: Deutsches Wörterbuch

Letzter Zugriff: (2016-03-29) [neuer Weblink](#)



```
<ref target="http://drw-www.adw.uni-heidelberg.de/drw-cgi/zeige?term=H%C3%BCfner&index=lemmata">
  <title>Artikel <mentioned>Hufner, Hüfner</mentioned> in: Deutsches
  Rechtswörterbuch</title>
  <date type="last_access" when="2016-03-29"/>
</ref>
```



Consistent Data Input



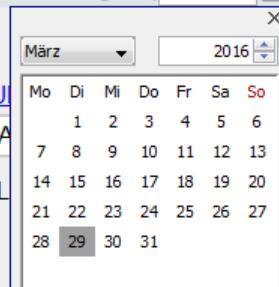
Weblinks

[neuer Weblink](#)

URL: drw-www.adw.uni-heidelberg.de/drw-cgi/zeige?term=H%FCfner&index=lemmata

Artikel *Hufner, Hüfner* in: Deutsches Rechtswörterbuch

Letzter Zugriff: (2016-03-29) [neuer Weblink](#)



URL: http://www_woerterbuchnetz_de/DWB?bookref=10,1867,16

Artikel *Hufe* in: Deutsches Wörterbuch

Letzter Zugriff: (2016-03-29) [neuer Weblink](#)

```
28 /*Weblink Datepicker in xr */
29 ▾xr > ref[target] > date:after{
30   content:
31   "("
32   oxy_editor(
33   type, datePicker,
34   edit, "@when",
35   format, "yyyy-MM-dd")
36   ")";
37 }
```



Flexibility and Customizability

Deutung unsicher:

[neue Bedeutung](#)

Nr. Motiv: ▾

Bedeutung: BedeutungsID: s_4da44dd1-e360-4694-82a9-f6e53e686c13 Benennung nach
 Herkunft zum Siedlungsnamen **Ferraro**, heute Ortsteil von Siderno, einer italienischen Stadt in der
 Provinz Reggio Calabria. (siehe Caffarelli VÖ-Jahr: Seite:

[neue Bedeutung](#)

```
<sense expand="uncertain">
<sense n="2" value="Herkunft">
<anchor xml:id="s_4da44dd1-e360-4694-82a9-f6e53e686c13"/> Benennung nach
Herkunft <etym>zum Siedlungsnamen <district>Ferraro</district></etym> heute
Ortsteil von Siderno, einer italienischen Stadt in der Provinz Reggio Calabria
<cit>
<bibl>(siehe <author><surname>Caffarelli</surname></author><date when="2008"/>,
<biblScope type="part">1</biblScope><biblScope type="pp">755</biblScope>)
</bibl>
</cit>
</sense>
</sense>
```



Flexibility and Customizability



Deutung unsicher:

[neue Bedeutung](#)

Nr. Motiv: Herkunft ▾

Bedeutung: BedeutungsID: s_4da44dd1-e360-4694-82a9-f6e53e686c13 Benennung nach
Herkunft zum Siedlungsnamen [Ferraro](#) heute Ortsteil von Siderno einer italienischen Stadt in der
Provinz Reggio Calabria (siehe Caffarelli VÖ-Jahr:

[neue Bedeutung](#)

- [Zitieren](#)
- [Geographische Angaben](#)
- [Grammatische Angaben](#)
- [neue Schreibvariante](#)
- [neuer Verweis orthographische Form](#)
- [neuer Verweis auf Ausspracheangabe](#)
- [Erneut laden](#)
- [Tags-Anzeigemodus](#)
- [Profiling/Bedingter Text](#)

vgl. "q" neue direkt zitierte Textstelle Strg+Q
neues Kurzzitat Alt+V
neuer Weblink für Literaturverweise
neues Zugriffsdatum URL Strg+L
neuer Autor
neuer Band Strg+B
neue Seitenangabe
neue Spaltenangabe
neue Kurztitelangabe
neuer dritter Beleg



New Features of Onodi



- Copying of UUIDs
- Managing Bibliographical References
- Publishing Workflow



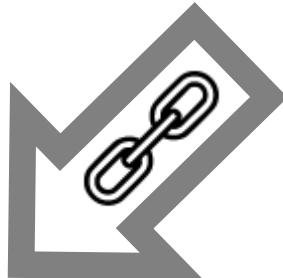
Copying of UUIDs: The Situation



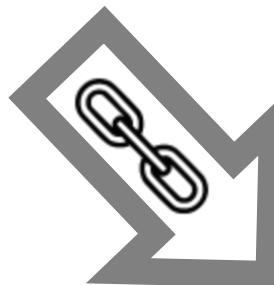
Article

Miller

dbbd95ff-8181-4c2d-acaa-59c46bf437a5



copy and paste
UUID into article



Glossary entry

Entrundung
vowel unrounded:
Müller → Miller

fcd10016-55c7-430b-a897-33e8b16ce08b

Thematic information

English
surnames

a2d70813-75b9-491b-a897-22e8e16ce60c

Copying of UUIDs: The Problem



- UUID stored in `xml:id` attribute

`xml:id="fcd10016-55c7-430b-a897-33e8b16ce08b"`

- displayed in author view as static text

```
8 ▾ TEI:before{  
9     content: "Glossar-ID: "attr(xml\:id);  
10    font-weight:bold;  
11    -oxy-editable:false;  
12 }
```

- **problem:** in oXygen's author view not selectable



Copying of UUIDs: A (Too) Simple Solution



- simple solution: switching to oXygen's text view
 - risk 1: users might invalidate the document by mistake
 - risk 2: selecting a UUID with the mouse is error-prone, characters in the beginning or at the end of the UUID might be omitted

`xml:id="fcd10016-55c7-430b-a897-33e8b16ce08b">`

`xml:id="fcd10016-55c7-430b-a897-33e8b16ce08b">`



Copying of UUIDs: The Solution



- development of custom operation in Java
- class “copyAttributeValueOperation” implements oXygen’s AuthorOperation interface

```
13             //if cursor in anchor element: ID of sense element (Bedeutungs-ID)
14     if("anchor".equals(element.getLocalName())){
15         String value = element.getAttribute("xml:id").getValue();
16         copyToClipboard(value);
17
18         JOptionPane.showMessageDialog(null, "Die Bedeutungs-ID " + value +
19                                     " wurde in die Zwischenablage
...      kopiert.");
20     }
21     else { //if cursor somewhere else: ID of article (Artikel-ID)
22         AttrValue value =
23         authorAccess.getDocumentController().getAuthorDocumentNode().getRootElement().getAttribute(
24             "xml:id");
25         copyToClipboard(value.getValue());
26
27         JOptionPane.showMessageDialog(null, "Die Artikel-ID " +
...             value.getValue() +
28                                     " wurde in die Zwischenablage
...      kopiert.");
29     }
}
```

Copying of UUIDs: The Solution



- copies value of `xml:id` attribute to clipboard
- “Copy ID” buttons trigger copy operation
- buttons placed with CSS next to any UUID

A screenshot of a software application window titled "Entrundung.xml". The main area shows a list of items with checkboxes and icons. A "Message" dialog box is overlaid on the window, containing a message about copied data and an "OK" button. A green arrow points from the CSS code on the right to the "ID kopieren" button in the message box.

/* Copy UUID */
TEI[xml:id]{
display:block;
background-color:#EEE;
content:
oxy_label(text, " ")
oxy_editor(
type, button,
actionID, "ID kopieren");
}

Entrundung.xml X

TEI

Glossar-ID: g_0cd10016-55c7-430b-a897-33e8b16ce08b

Bearbeiter (Name, Vorname):

ID kopieren

Überprüfung

Die Artikel-ID g_0cd10016-55c7-430b-a897-33e8b16ce08b wurde in die Zwischenablage kopiert.

OK

Überarbeitung

By the way: Are UUIDs valid values for `xml:id`?



- auto-generated oXygen UUID: first character not always letter
- problem: invalid values for `xml:id`
- solution now: prefix `s_`, `g_` or `i_`
- solution soon: CustomUUID plugin
(<http://github.com/digicademy/CustomUUID>)

Hauptbedeutung:

neue Bedeutung

Nr. 1 Motiv: Beruf

Bedeutung: BedeutungsID **s_9248e084-fdc4-44a1-a29f-39cb8c9c09b9** Benennung nach Beruf zu () mittelhochdeutsch *smit* 'Schmied'. Gemeingermanisch handelt es sich um eine Sammelbezeichnung für Handwerker, die mit scharfem Werkzeug harte Materialien bearbeiten wie Metall aber auch Holz. Später erfolgt die Bedeutungsnazifizierung zum

Managing Bibliographical References



Screencast



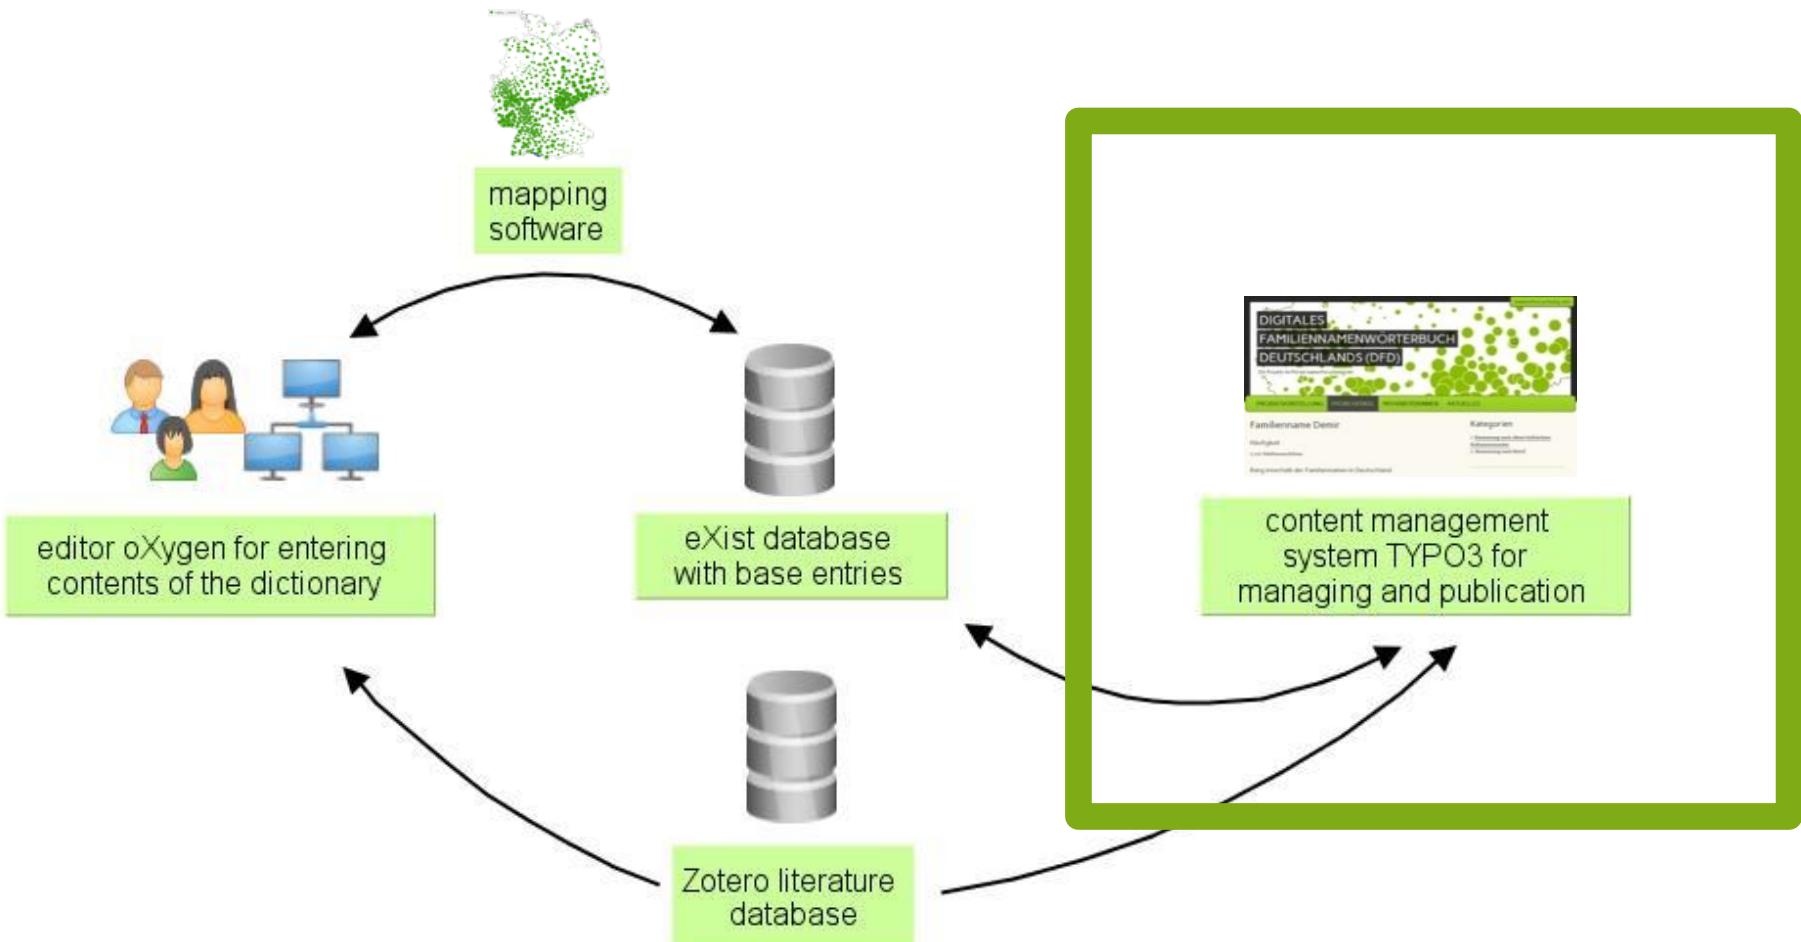
Managing Bibliographical References



- Zotero: web-based tool to organize research sources
- eXist db scheduler calls XQuery script
- retrieves bibliographical references
- stores XML file
- eXist trigger fires on update
- creates key value list für combobox
- splits XML file per letter
- selected letter in combobox is parameter for ediarum index function



Work Environment Onodi



Publishing Workflow: TYPO3 CMS



- dictionary website is driven by content management system TYPO3
- TYPO3 extension “dfd”
 - data model
 - scheduler task for retrieval of documents which are ready for publication
 - storage in TYPO3 database
 - provides plugins for search, list and detail view of dictionary contents



Publishing Workflow: Articles “Ready for Publication”



The screenshot shows a software interface for managing XML files, likely used for publishing articles. On the left, there is a sidebar titled "Publikationsschritte:" (Publication steps) with the following checklist:

- Freigabe zur Redaktion
- Überprüfung
- Überarbeitung
- Freigabe zur Publikation

The main area contains two tabs: "Miller.xml" and "index.xml". The "index.xml" tab is active, displaying the following XML code:

```
<?xml version="1.0" encoding="UTF-8"?>
<index>
    <uuid name="Aydin">e7e1
    <uuid name="Brinkschmid"
    <uuid name="Brinkschnie
    <uuid name="Brinkschnie
    <uuid name="Brinkschröd
    <uuid name="Celik">dee7
    <uuid name="Demir">ddaf
    <uuid name="Ferrai">e19
    <uuid name="Ferrari">be
    <uuid name="Ferraro">b8
    <uuid name="Ferreri">e2
    <uuid name="Fexmer">b2f
    <uuid name="Fixemer">a3
    <uuid name="Fixmer">fe4
    <uuid name="Futterschne
    <uuid name="Gsottschnei
    <uuid name="Hexelschnei
    <uuid name="Hillesheim">e1372680-ed7d-440e-89b6-5600d76e9a1d</uu
    <uuid name="Hillesheimer">cb43a4c5-ce63-40da-9817-f8df650b8751</u

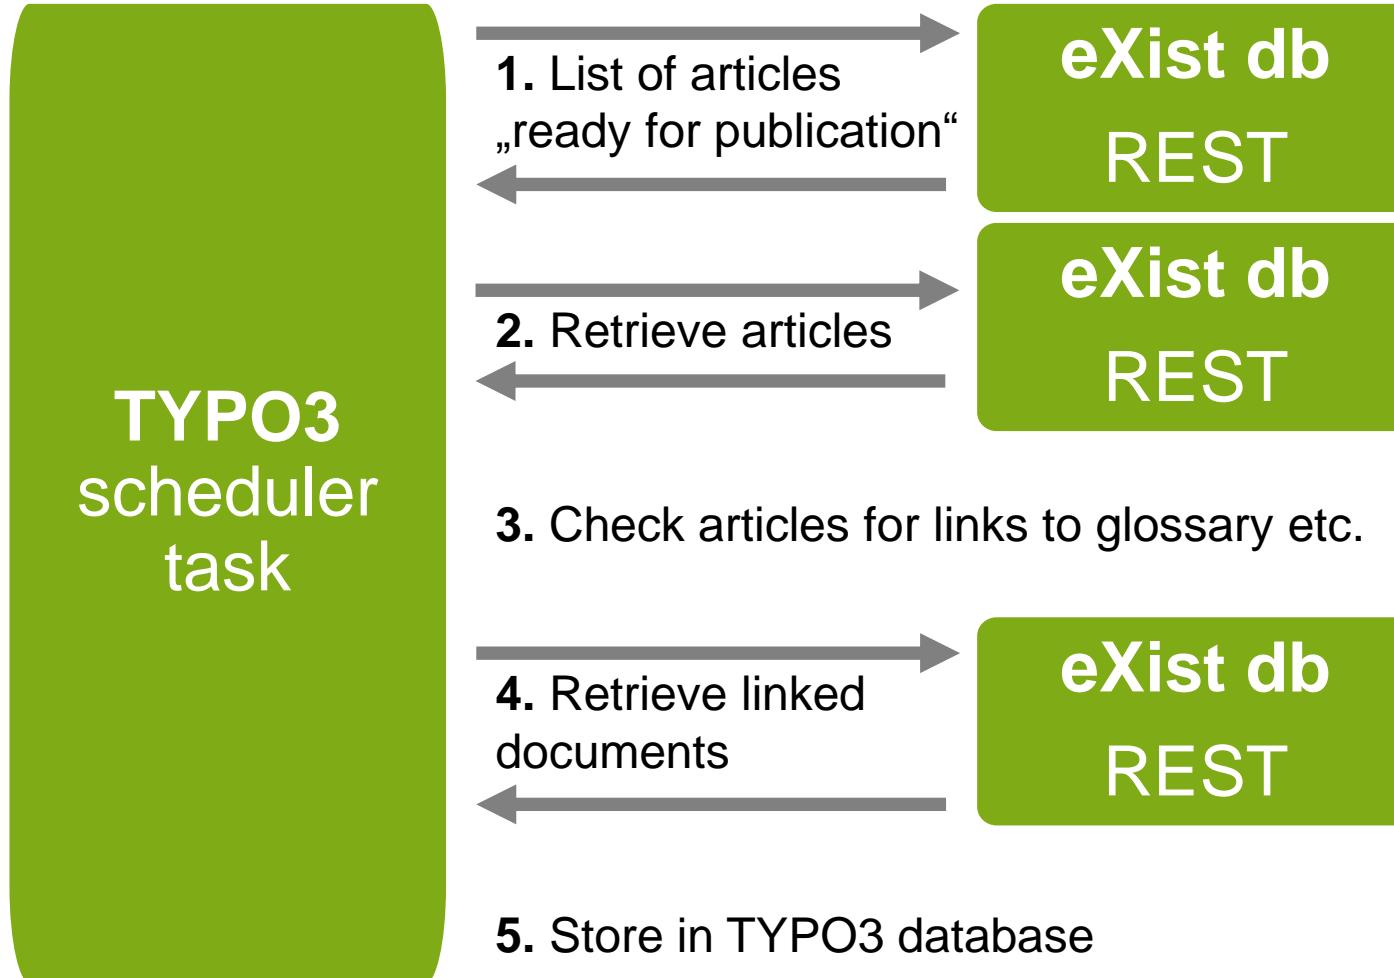
```

On the right side, there is a "Datenquellen Explorer" (Data sources explorer) window showing a file tree structure:

- webdav.namenforschung.net
 - css
 - dfd
 - names
 - resources
 - schema
- status_of_publication
 - delete
 - edit
 - publish
 - publish
 - index.xml
- status_of_publication

A yellow box highlights the "publish" folder under "status_of_publication", which contains "index.xml".

Publishing Workflow: Scheduled Retrieval Task



Conclusion

- customized, user-friendly interface
- users produce richly annotated documents – without advanced XML skills
- copying of UUIDs is easy
- bibliographical references centrally stored, easily inserted
- automated publishing process – two mouse clicks are enough

Questions?

