Offene Infrastruktur für bibliothekarische Daten

Linked Open Data, JSON & OpenRefine in der Praxis

Adrian Pohl & Fabian Steeg

Metadateninfrastruktur, Hochschulbibliothekszentrum NRW (hbz)



WWW, 2023-03-28

Zentrum für Bibliotheks- und Informationswissenschaftliche Weiterbildung, TH Köln (ZBIW)

Diese Präsentation:

https://slides.lobid.org/2023-zbiw/ (PDF)



Fragen sind stets willkommen

Fragen sind stets willkommen

Hilf anderen, wo du kannst

Fragen sind stets willkommen

Hilf anderen, wo du kannst

Sei offen für unterschiedliche Fachkenntnisse & Erfahrungen

Adrian

Adrian

Seit 2008 im hbz, LOD/Metadateninfrastruktur, seit 2019 Leitung

Adrian

Seit 2008 im hbz, LOD/Metadateninfrastruktur, seit 2019 Leitung

Schwerpunkte: Datenmodellierung, Offene Standards, Kommunikation/Koordination

Fabian

Fabian

Seit 2012 im hbz, LOD/Metadateninfrastruktur

Fabian

Seit 2012 im hbz, LOD/Metadateninfrastruktur

Schwerpunkte: Webentwicklung und Datentransformation (z.B. lobid.org)

Und ihr?

Und ihr?

Wo und was arbeitet ihr?

Und ihr?

Wo und was arbeitet ihr?

Was erwartet ihr von diesem Seminar?

Agenda

- 1. Offene Infrastruktur
- 2. Linked Data & JSON-LD
- 3. OpenRefine Reconciliation

Grober Zeitplan

1. Offene Infrastruktur	lobid-Dienste und Nutzungsbeispiele	10:00–10:30
	GND, lobid-gnd, Rechercheoberfläche	10:30–11:00
2. Linked Data & JSON-LD	RDF, Linked Data	11:00–11:30
	JSON, JSON-LD, LOUD	11:30–12:00
	Daten und Abfragemöglichkeiten GND	12:00–12:30
	Pause	
	Daten und Abfragemöglichkeiten Verbundkatalog	13:30–14:00
3. OpenRefine Reconciliation	Grundlagen von OpenRefine und Reconciliation	14:00–14:30
	Verbesserung des Matching auf GND-Einträge	14:30–15:00
	Datenanreicherung auf Basis der Matches	15:00–15:30

Teil 1: Offene Infrastruktur

lobid	lobid-Dienste und Nutzungsbeispiele	10:00–10:30
GND	GND, lobid-gnd, Rechercheoberfläche	10:30–11:00





Hochschulbibliothekszentrum des Landes Nordrhein-Westfalen, seit 1973



Hochschulbibliothekszentrum des Landes Nordrhein-Westfalen, seit 1973

Dienstleistungs- und Entwicklungseinrichtung für digitale Services in Hochschulbibliotheken



Hochschulbibliothekszentrum des Landes Nordrhein-Westfalen, seit 1973

Dienstleistungs- und Entwicklungseinrichtung für digitale Services in Hochschulbibliotheken

Einige Arbeitsbereiche: Verbundkatalog, Suchportal DigiBib, Fernleihe, Konsortiale Erwerbung

Nutzung und Pflege von Infrastruktur für die Publikation strukturierter Daten im Web:

Nutzung und Pflege von Infrastruktur für die Publikation strukturierter Daten im Web:

Offene Webstandards und darauf aufsetzend kooperative Entwicklung von Spezifikationen (z.b AMB)

Nutzung und Pflege von Infrastruktur für die Publikation strukturierter Daten im Web:

Offene Webstandards und darauf aufsetzend kooperative Entwicklung von Spezifikationen (z.b AMB)

Transformation von Alt- und Fremddaten in web-kompatible Strukturen (mit Metafacture)

Nutzung und Pflege von Infrastruktur für die Publikation strukturierter Daten im Web:

Offene Webstandards und darauf aufsetzend kooperative Entwicklung von Spezifikationen (z.b AMB)

Transformation von Alt- und Fremddaten in web-kompatible Strukturen (mit Metafacture)

Publikation strukturierter Daten im Web inkl. APIs (lobid, OERSI, SkoHub)





lobid steht für Linking Open Bibliographic Data



lobid steht für Linking Open Bibliographic Data

Seit über zehn Jahren die zentrale Komponente der offenen Infrastruktur im hbz



lobid steht für Linking Open Bibliographic Data

Seit über zehn Jahren die zentrale Komponente der offenen Infrastruktur im hbz

Stellt intuitive, web-basierte Rechercheoberflächen und Schnittstellen bereit

lobid-resources: Daten des hbz-Verbundkatalogs

lobid-resources: Daten des hbz-Verbundkatalogs

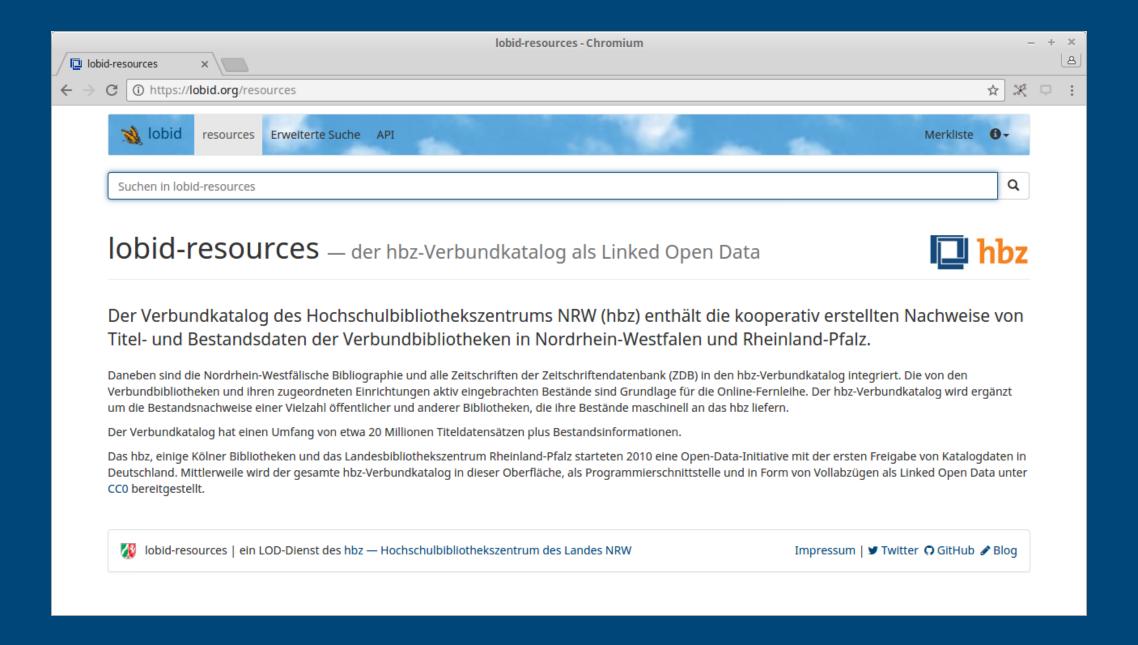
lobid-organisations: Daten des deutschsprachigen Sigelverzeichnisses und DBS-Stammdaten

lobid-resources: Daten des hbz-Verbundkatalogs

lobid-organisations: Daten des deutschsprachigen Sigelverzeichnisses und DBS-Stammdaten

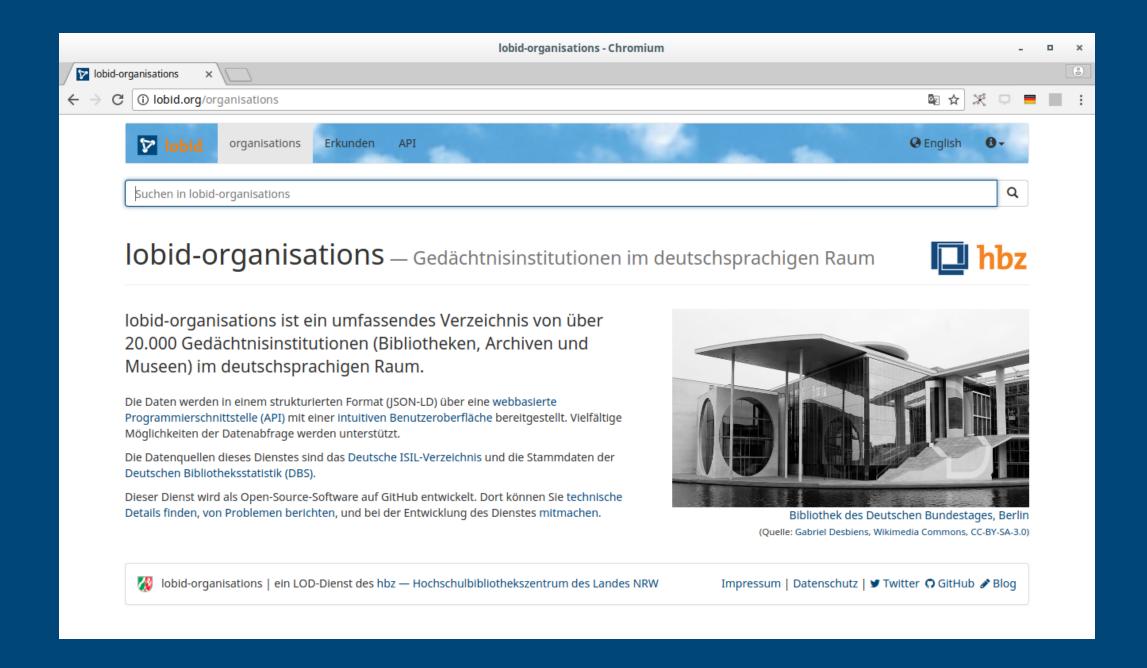
lobid-gnd: Gemeinsame Normdatei

lobid-resources



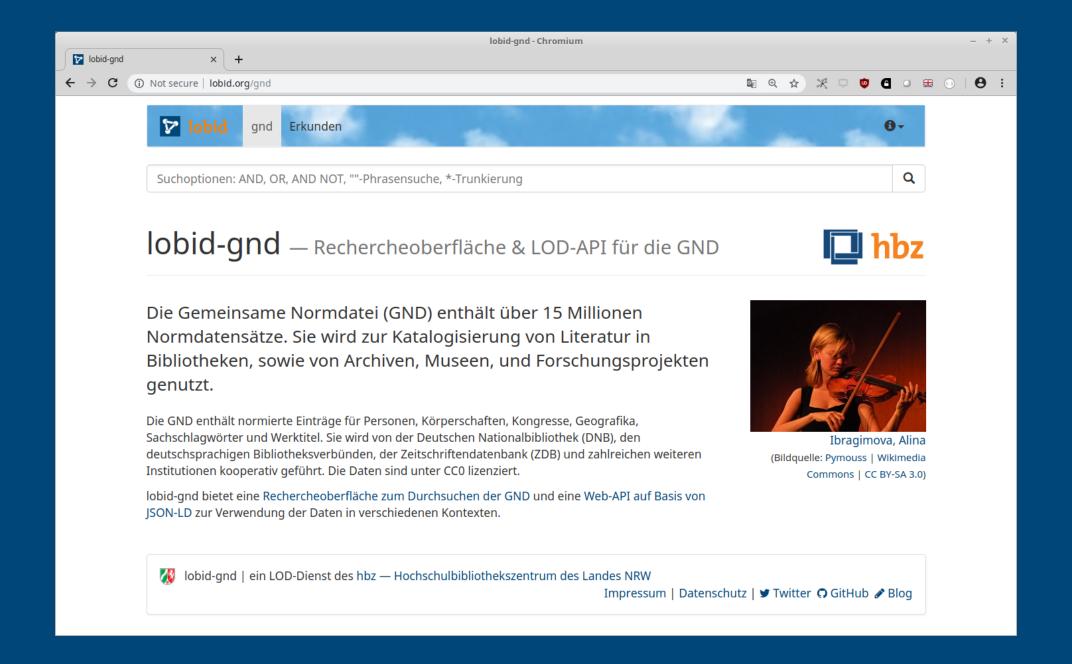
Dokumentation der lobid-resources-API: https://lobid.org/resources/api

lobid-organisations



Dokumentation der lobid-organisations-API: https://lobid.org/organisations/api

lobid-gnd



Dokumentation der lobid-gnd-API: https://lobid.org/gnd/api

lobid – ein zentraler Knoten bibliothekarischer Dateninfrastruktur



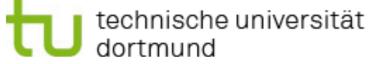
lobid: Nutzungsbeispiele



Die Nordrhein-Westfälische Bibliographie



Biographisches Portal NRW ulb Münster



bauhaus-archiv

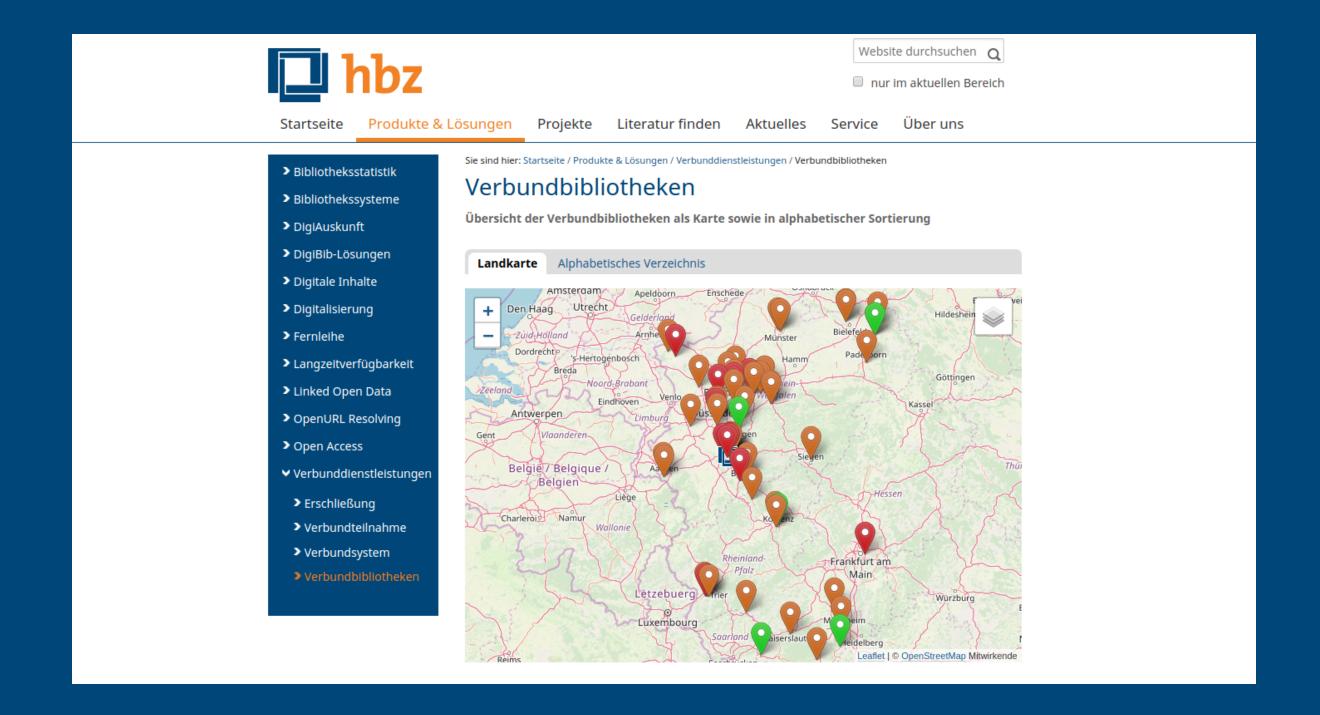
deutsches literatur archiv marbach





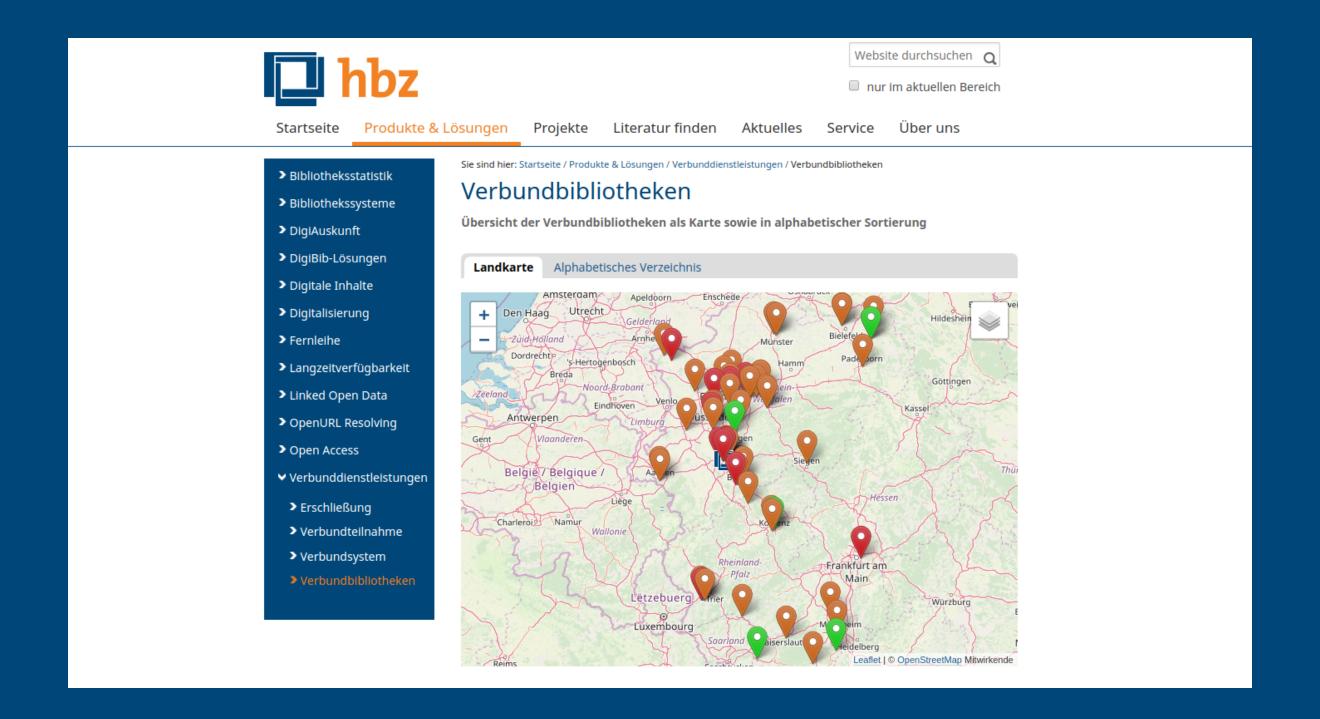
correspSearch Briefeditionen durchsuchen und vernetzen

Verbundbibliotheken auf hbz-Website



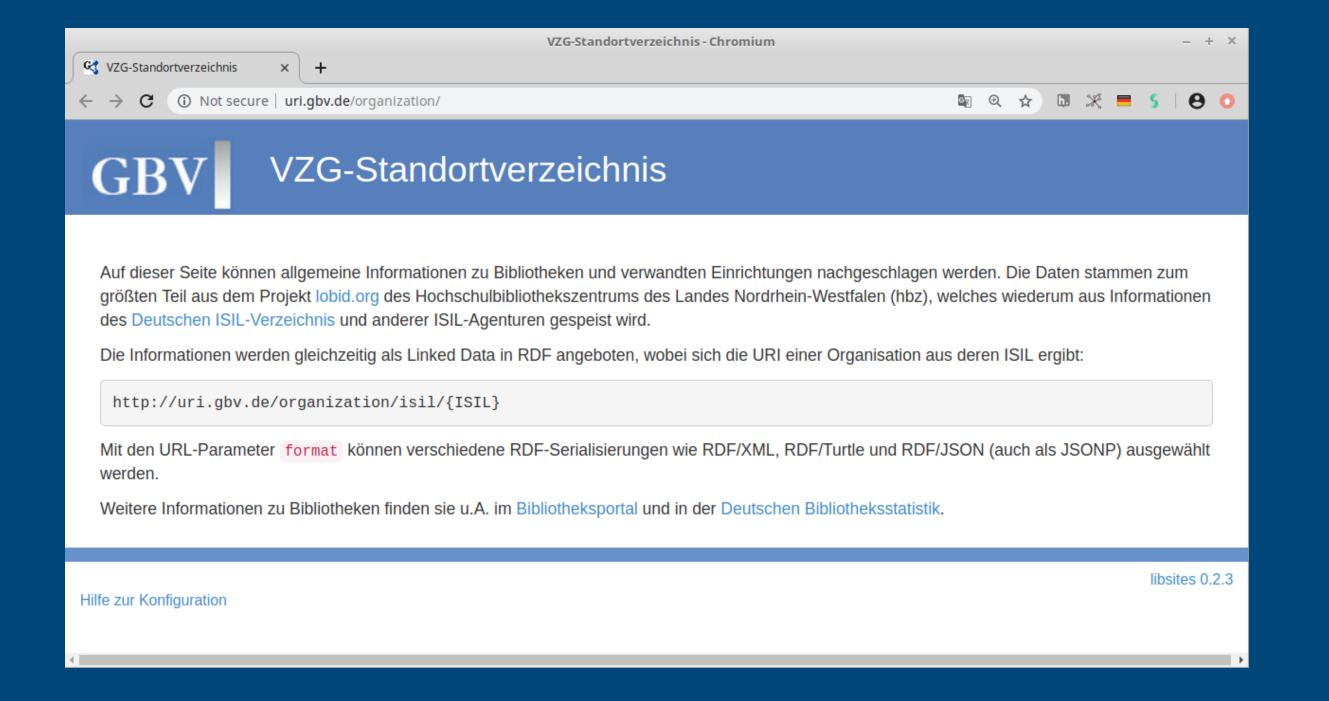
Α

Verbundbibliotheken auf hbz-Website



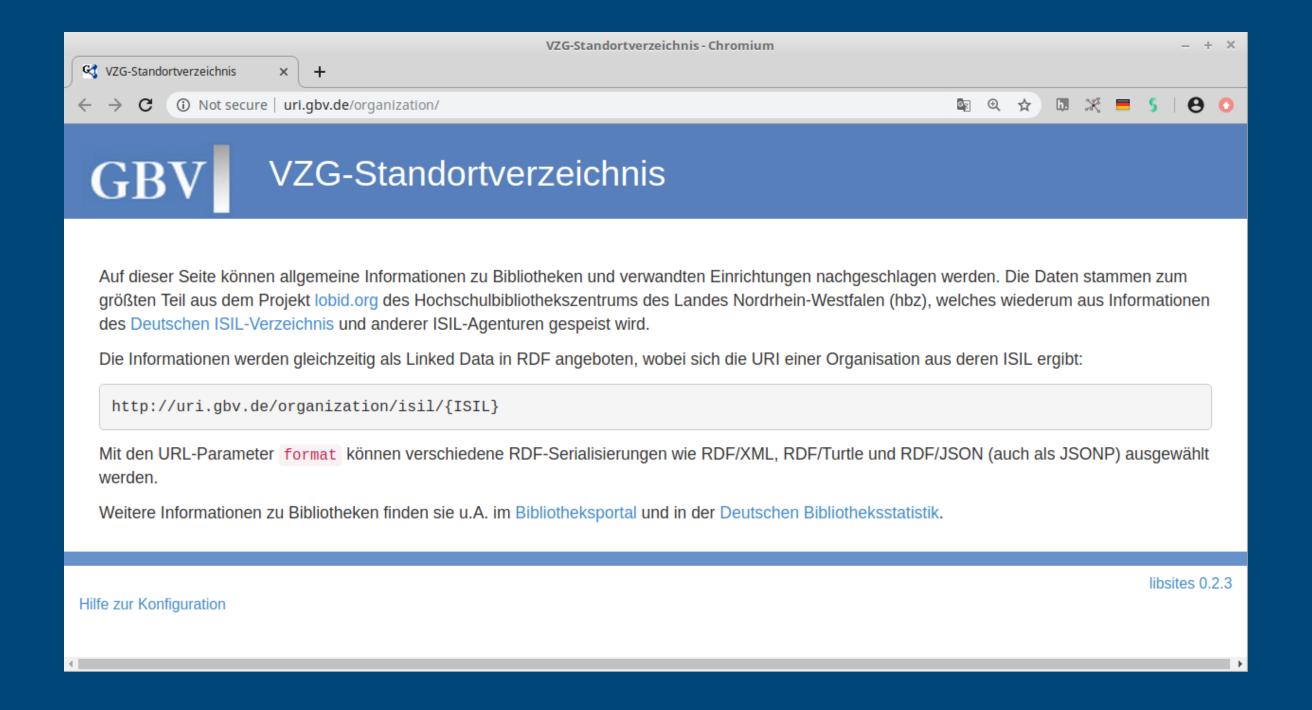
Basiert auf lobid-Organisationsdaten

VZG-Standortverzeichnis



١.

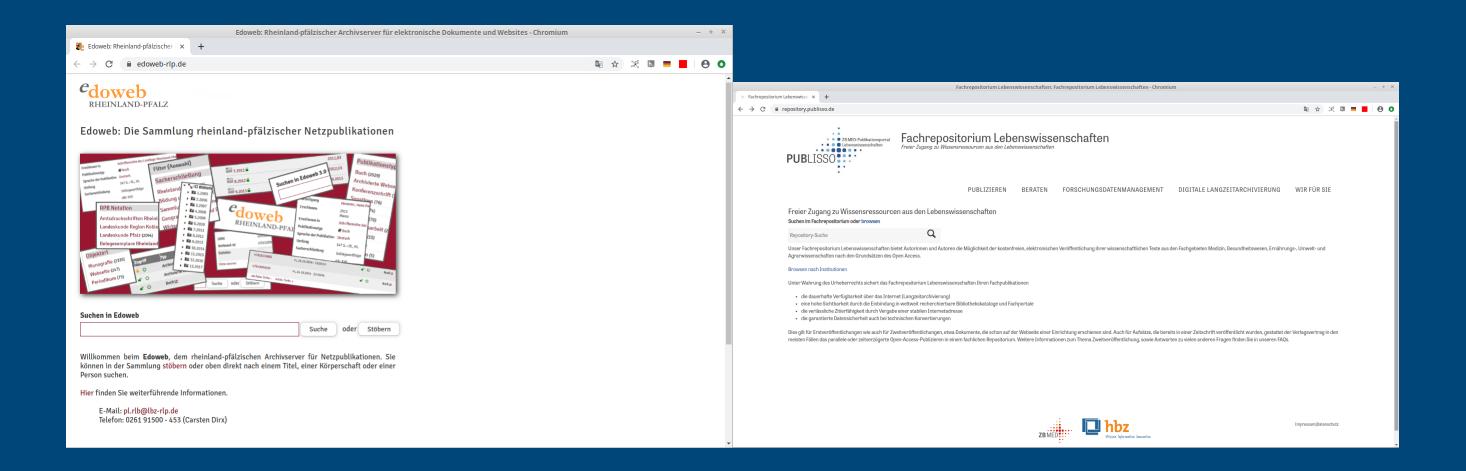
VZG-Standortverzeichnis



Basiert auf lobid-Organisationsdaten

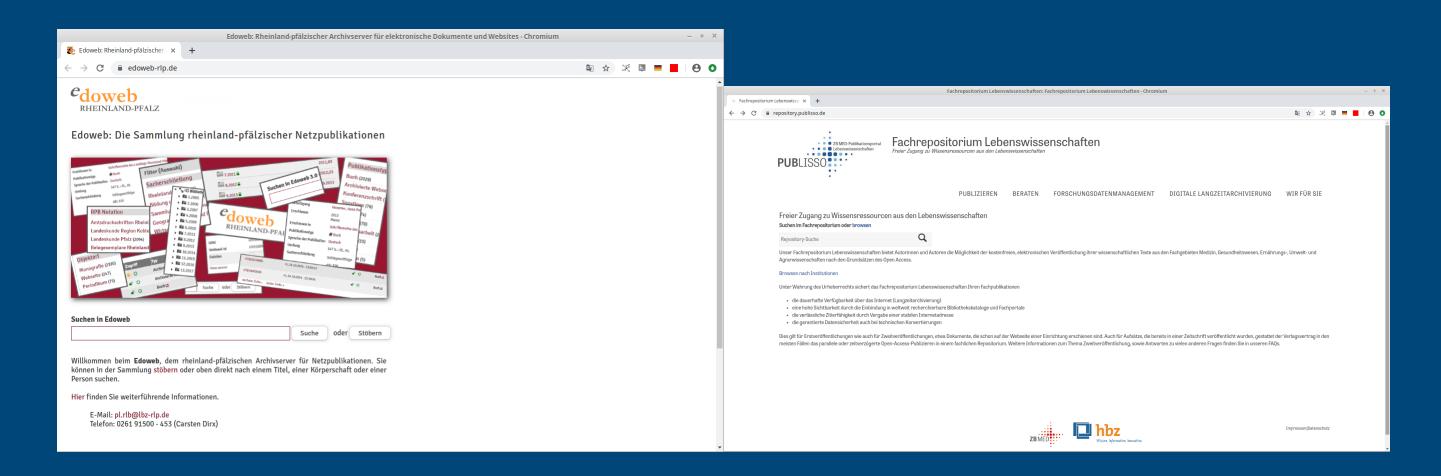


Edoweb und Fachrepositorium Lebenswisschenschaften (FRL)



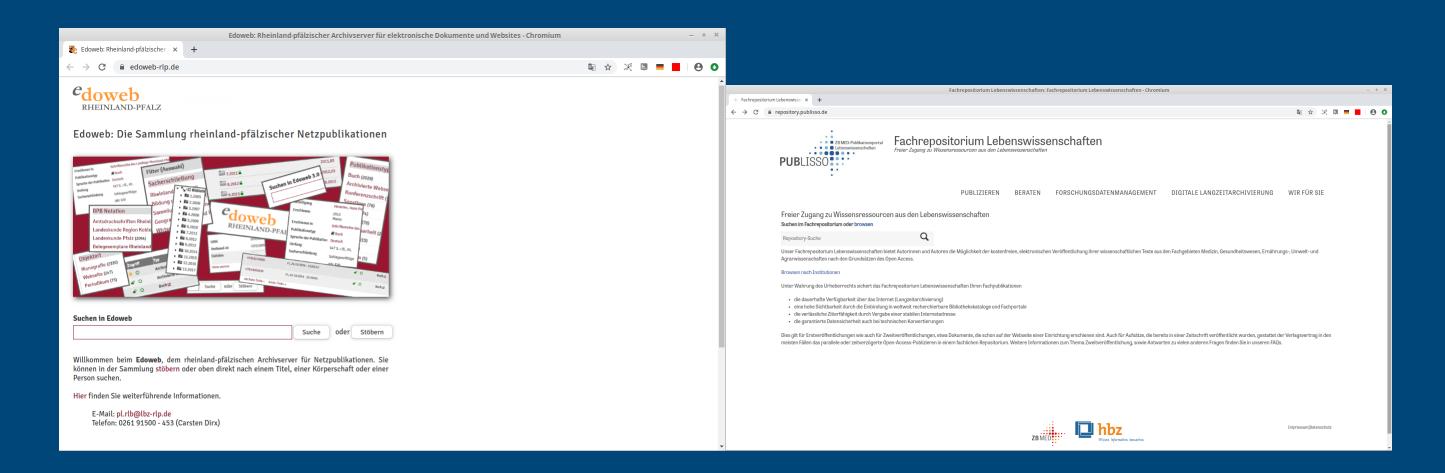
4

Edoweb und Fachrepositorium Lebenswisschenschaften (FRL)



Enge Integration der lobid-Verbunddaten und des lobid-Datenmodells

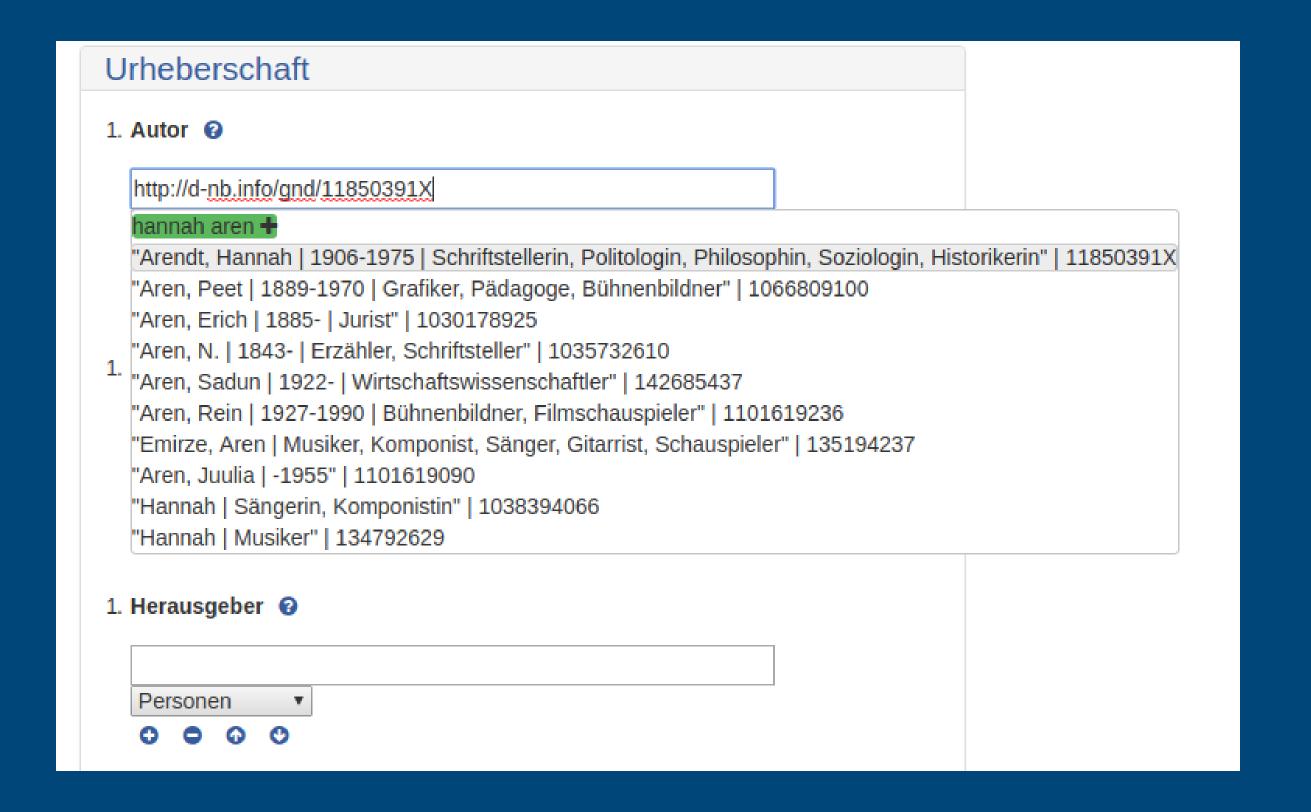
Edoweb und Fachrepositorium Lebenswisschenschaften (FRL)



Enge Integration der lobid-Verbunddaten und des lobid-Datenmodells

In Publisso auch GND-ID-Lookup via lobid

GND-Lookup im Fachrepositorium Lebenswissenschaften









Die Nordrhein-Westfälische Bibliographie







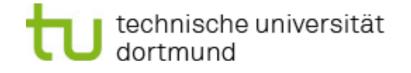
Meta-Katalog zum Nachweis landeskundlicher Literatur in Deutschland







Biographisches Portal NRW ulb Münster







correspSearch
Briefeditionen durchsuchen und vernetzen

bauhaus-archiv

deutsches literatur archiv marbach

Webanwendung, die nahezu vollständig auf lobid-Daten basiert

Webanwendung, die nahezu vollständig auf lobid-Daten basiert

Nutzt das NWBib-Subset in den lobid-Verbunddaten

Webanwendung, die nahezu vollständig auf lobid-Daten basiert

Nutzt das NWBib-Subset in den lobid-Verbunddaten

Informationen zu besitzenden Bibliotheken aus lobid-Organisationsdaten

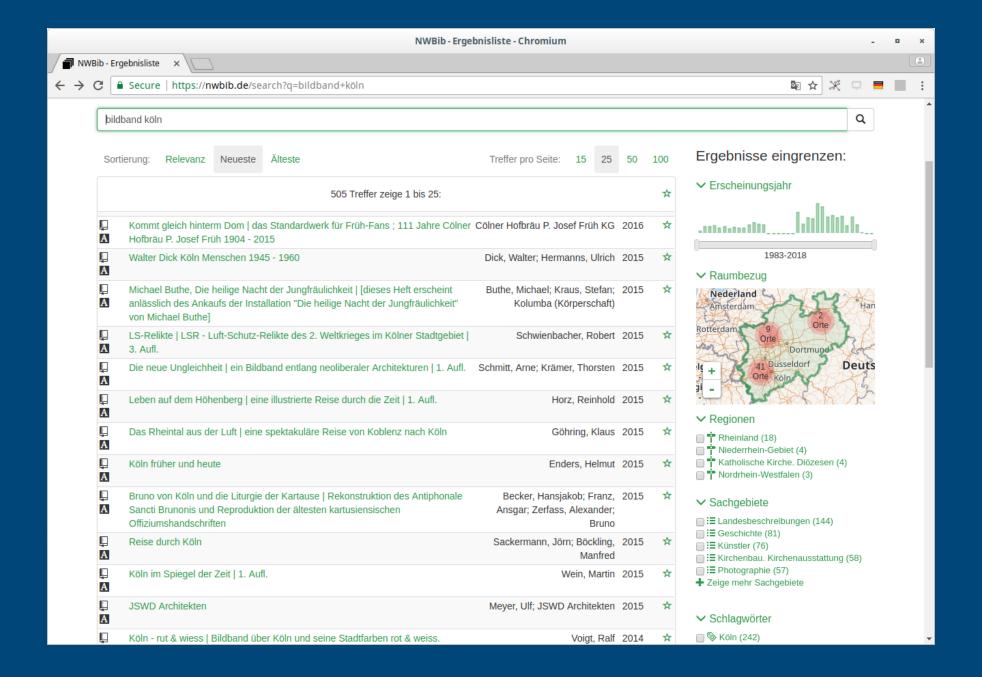
Webanwendung, die nahezu vollständig auf lobid-Daten basiert

Nutzt das NWBib-Subset in den lobid-Verbunddaten

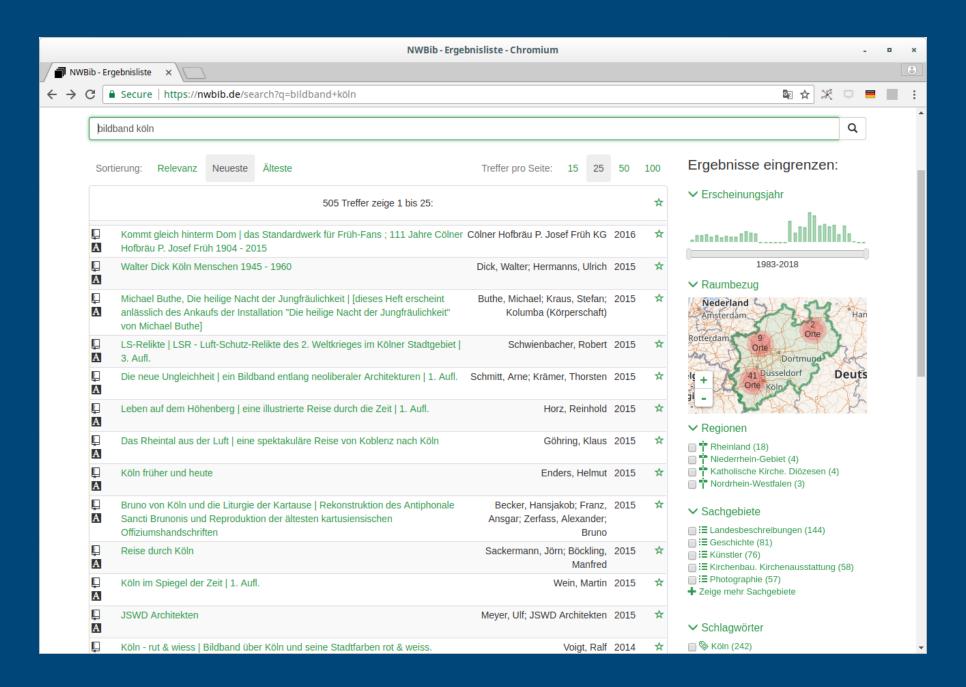
Informationen zu besitzenden Bibliotheken aus lobid-Organisationsdaten

Themenvorschläge auf Basis von lobid-gnd

NWBib-Suchergebnisliste

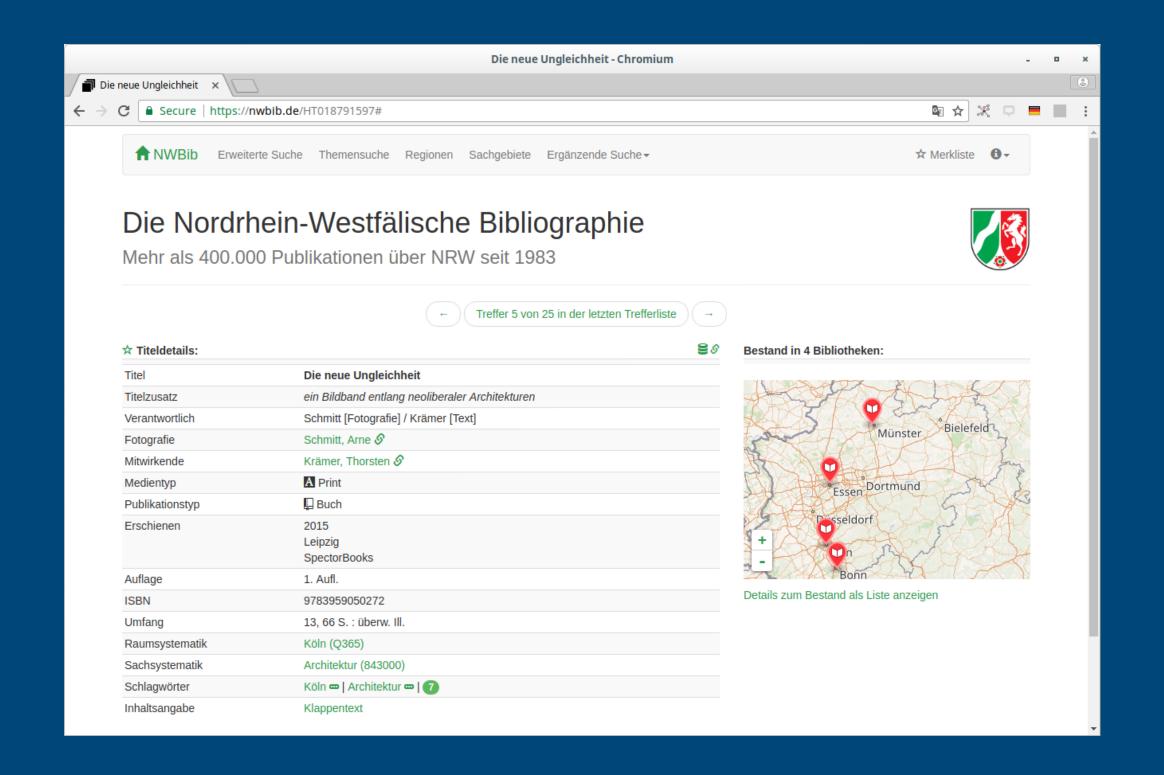


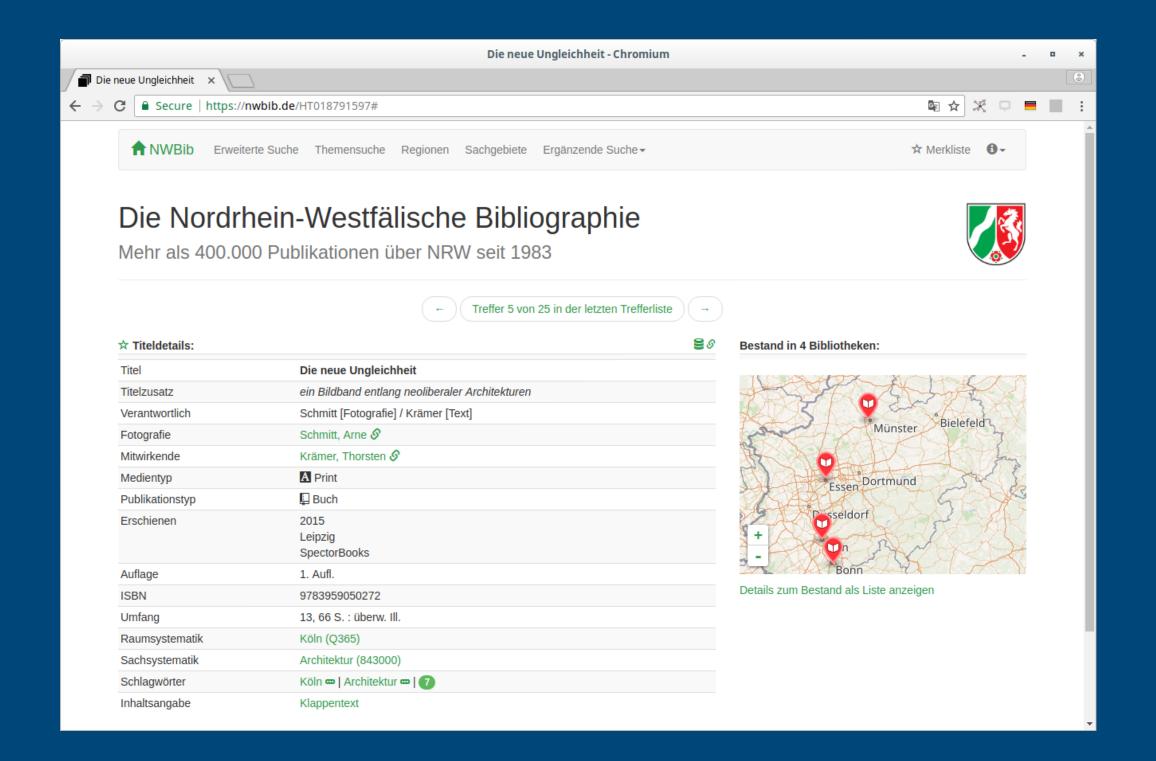
NWBib-Suchergebnisliste



Anfrage gegen das NWBib-Subset in lobid-Verbunddaten

4





Informationen zu besitzenden Bibliotheken (Name, URL, Standort) werden aus lobid geladen







Die Nordrhein-Westfälische Bibliographie











Meta-Katalog zum Nachweis landeskundlicher Literatur in Deutschland





Biographisches Portal NRW ulb Münster



technische universität dortmund





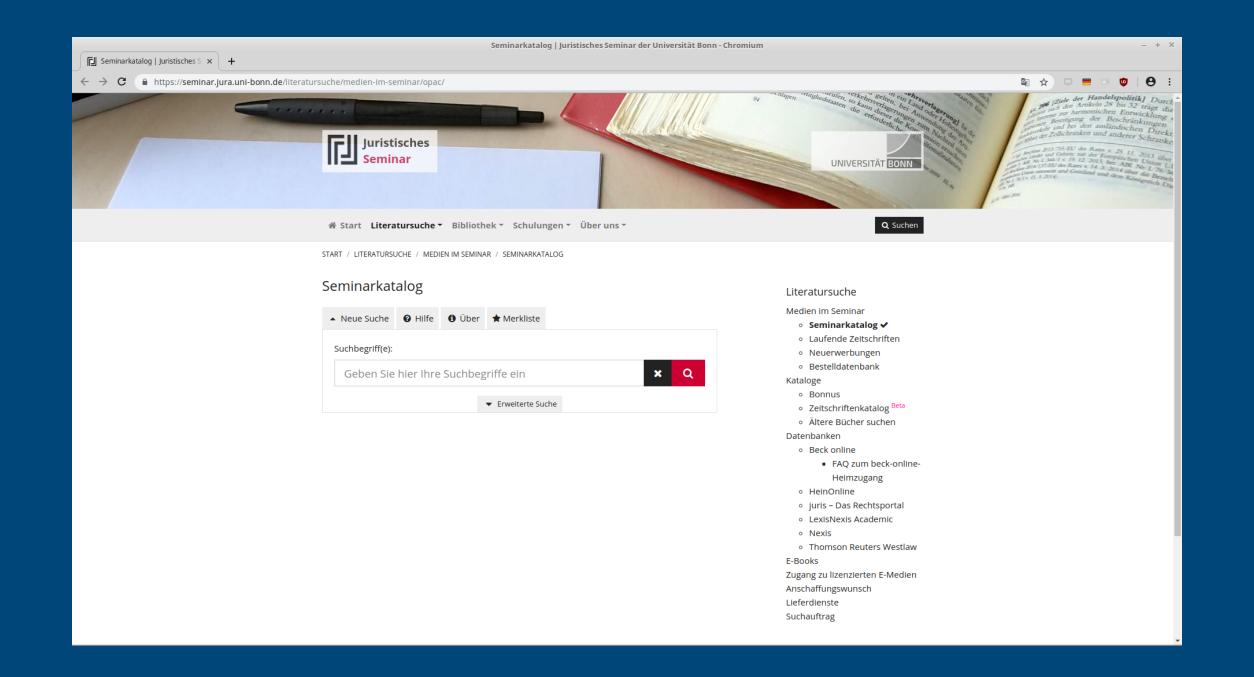
correspSearch

Briefeditionen durchsuchen und vernetzen

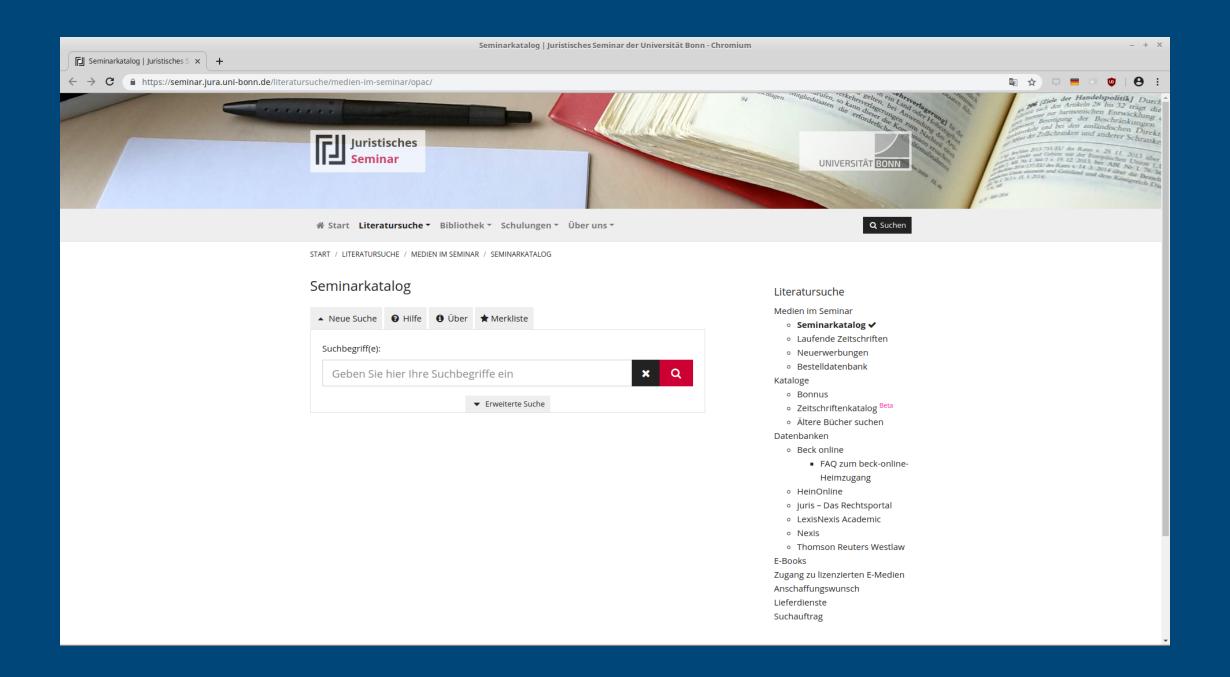
bauhaus-archiv

deutsches literatur archiv marbach

Bibliothekskatalog des Juristischen Seminars der ULB Bonn



Bibliothekskatalog des Juristischen Seminars der ULB Bonn



Basiert auf täglich aktualisierten lobid-Daten

Über den Seminarkatalog

×

Inhalt

Der Seminarkatalog verzeichnet unseren Buch- und Zeitschriftenbestand soweit er elektronisch erfasst ist. Ergänzend haben wir ca. 7.000 juristische Titel elektronischer Bücher und Zeitschriften hinzugefügt:

• Buch- und Zeitschriftenbestand des Juristischen Seminars

(Quelle: lobid-resources)

· Bestellte und im Geschäftsgang befindliche Bücher

(Quelle: Juristisches Seminar)

• Rund 6.600 lizenzierte juristische eBooks und eZeitschriften

(Quelle: lobid-resources)

• Rund 500 Open Access eBooks

(Quelle: DOAB)

Herkunft der Daten

Die Daten stammen aus dem HBZ-Verbundkatalog und werden vom Hochschulbibliothekszentrum NRW (HBZ) über die *lobid-resources-API* bereitgestellt.

Weitere Daten stammen aus dem Directory of Open Access Books (DOAB).

Aktualisierung

Die Daten werden täglich (werktags) aktualisiert.







Die Nordrhein-Westfälische Bibliographie







Virtuelle Deutsche Landesbibliographie

Meta-Katalog zum Nachweis landeskundlicher Literatur in Deutschland











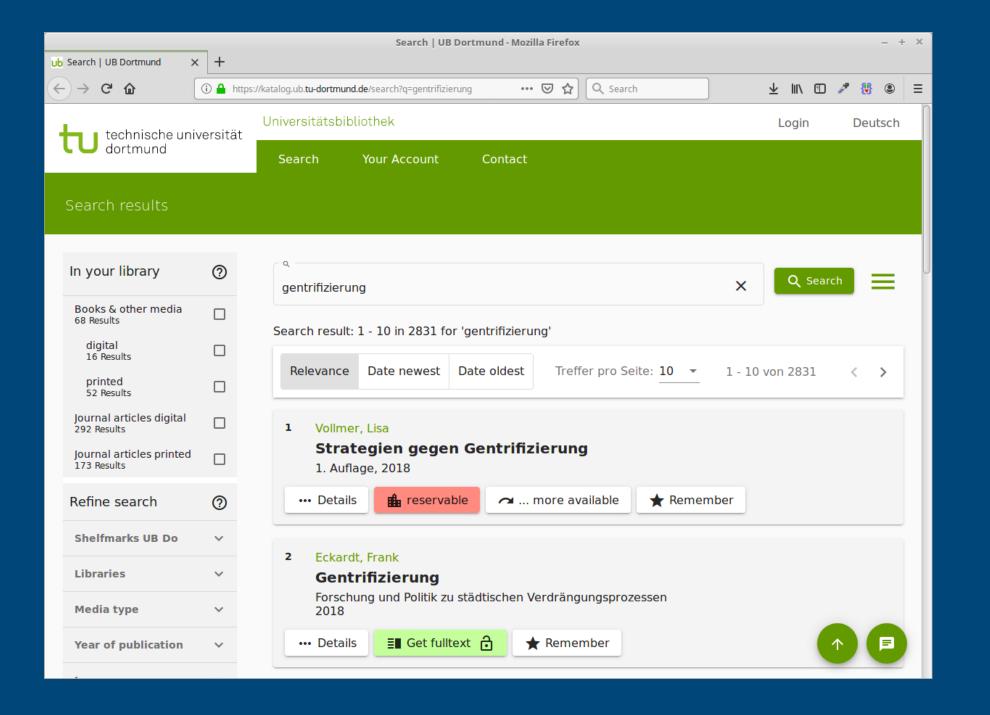


correspSearch Briefeditionen durchsuchen und vernetzen

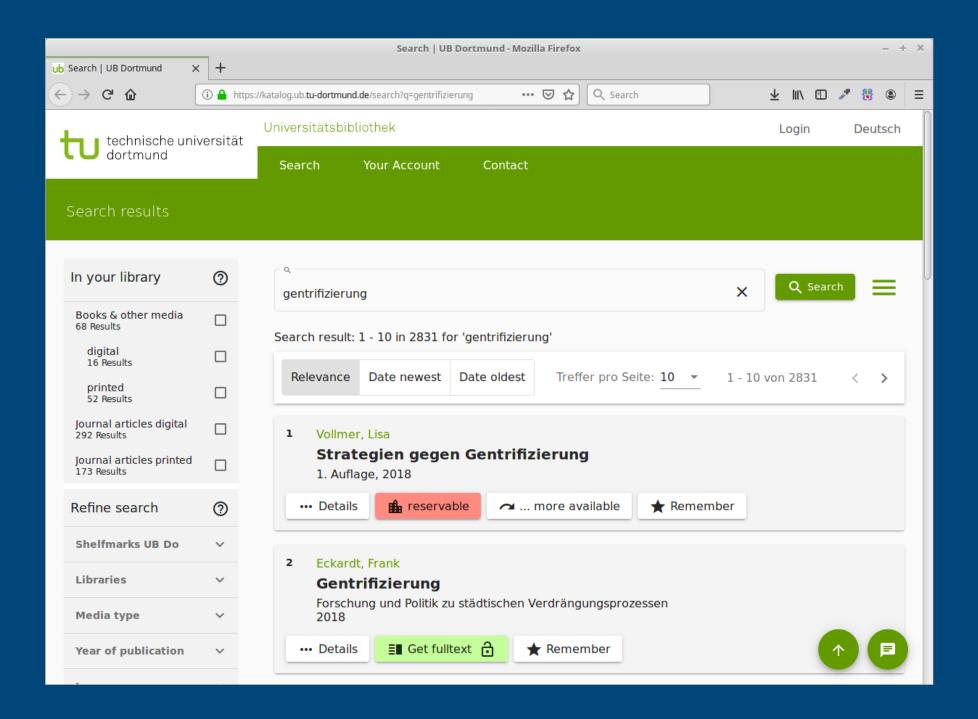
bauhaus-archiv

deutsches literatur archiv marbach

Discovery-Index der UB Dortmund



Discovery-Index der UB Dortmund



Titeldaten zu den Beständen der UB & einiger umliegender Bibliotheken werden täglich von lobid geholt, transformiert und in den Index geladen

4



correspSearch

Briefeditionen durchsuchen und vernetzen

Die Nordrhein-Westfälische Bibliographie



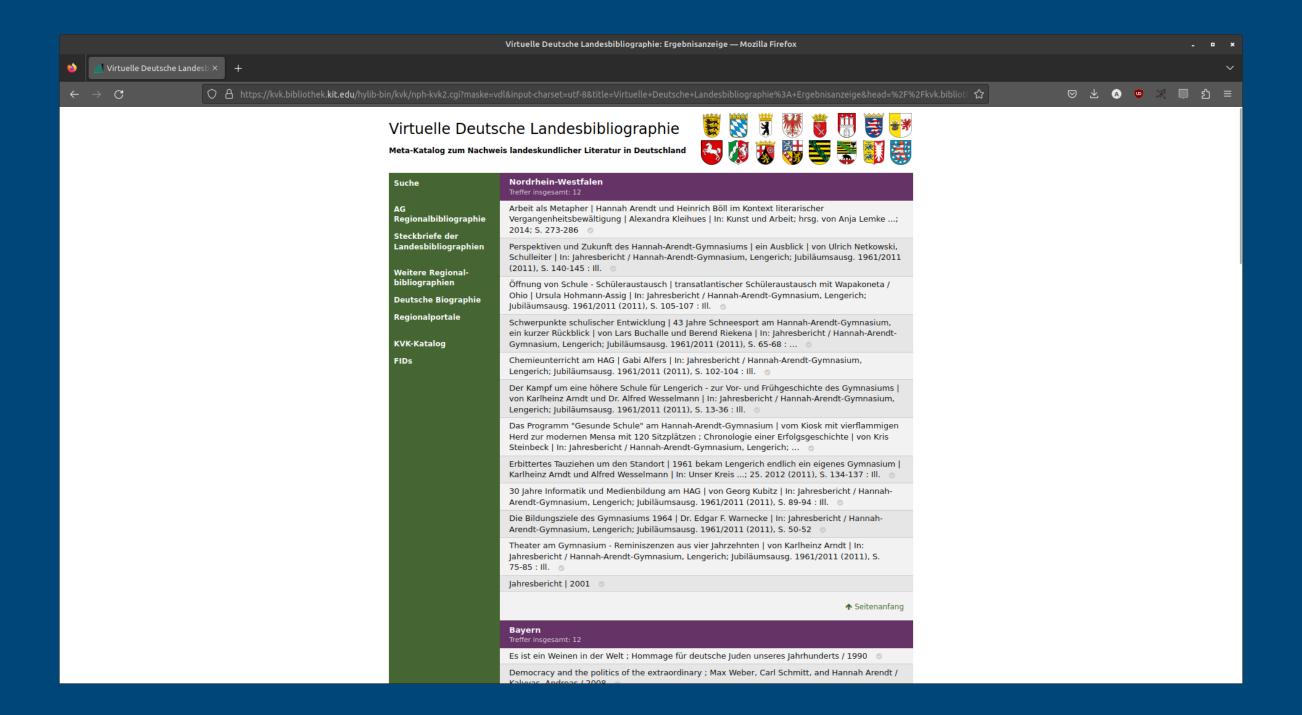
Biographisches Portal NRW ulb Münster



bauhaus-archiv

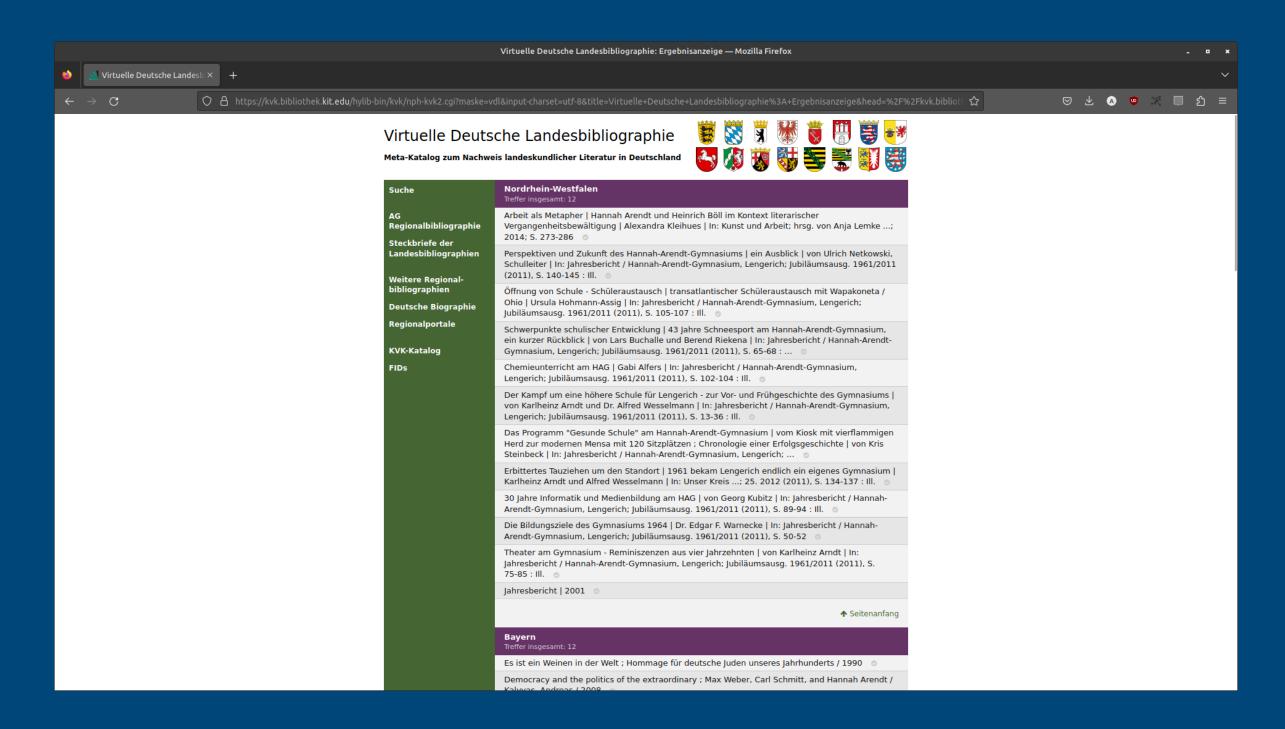
deutsches literatur archiv marbach

Virtuelle Deutsche Landesbibliographie



A

Virtuelle Deutsche Landesbibliographie



Seit 2018 ist nwbib.de in die VDL integriert











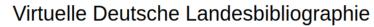
Biographisches Portal NRW ulb Münster



technische universität dortmund

bauhaus-archiv

deutsches literatur archiv marbach



Meta-Katalog zum Nachweis landeskundlicher Literatur in Deutschland









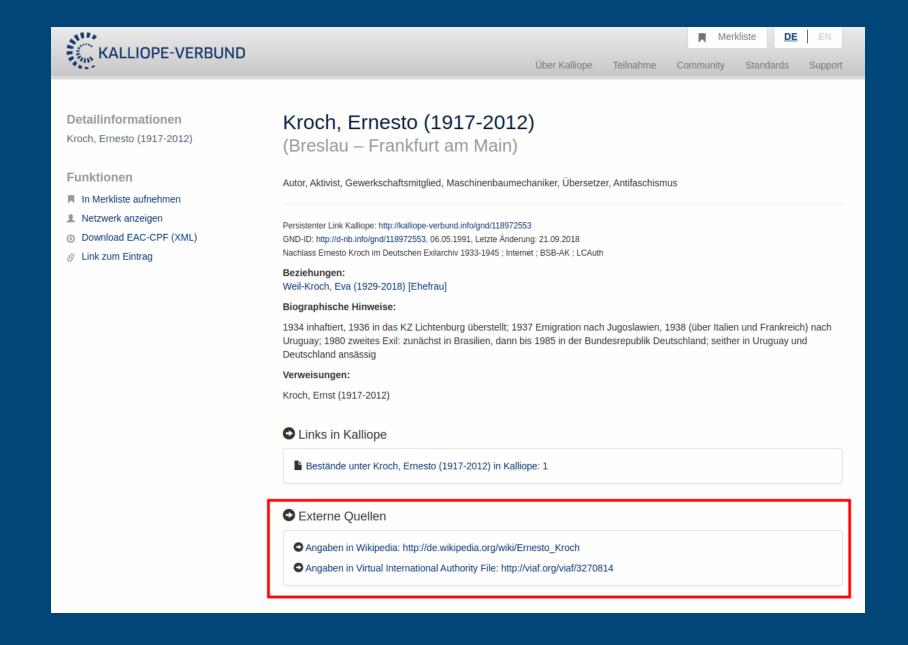
correspSearch

Briefeditionen durchsuchen und vernetzen

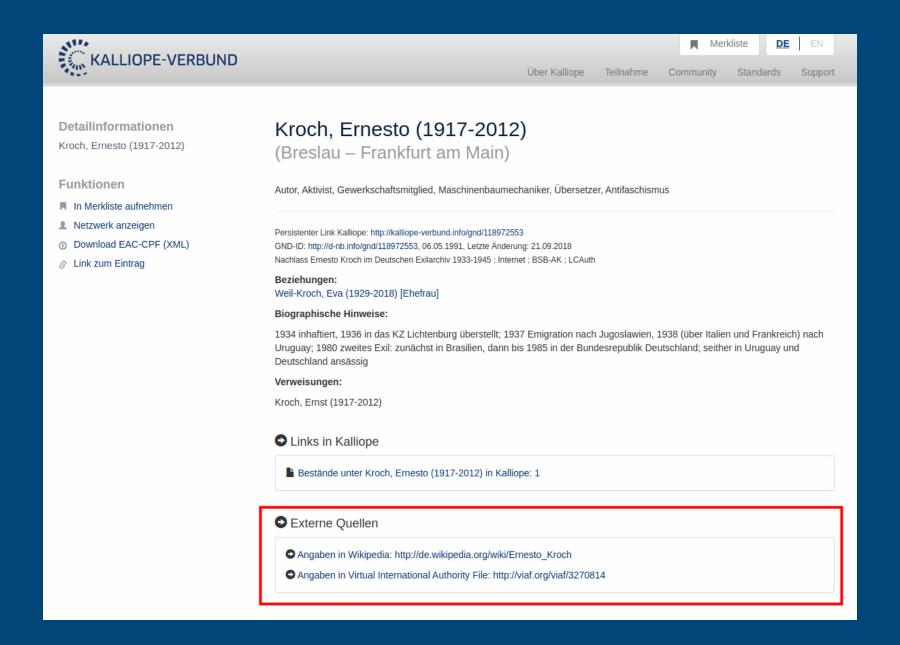




Kalliope



Kalliope



Anzeige von externen Links (z.B. Wikipedia) aus lobid-gnd auf Personenseiten

 \mathbf{A}







Die Nordrhein-Westfälische Bibliographie







Virtuelle Deutsche Landesbibliographie

Meta-Katalog zum Nachweis landeskundlicher Literatur in Deutschland





Biographisches Portal NRW ulb Münster



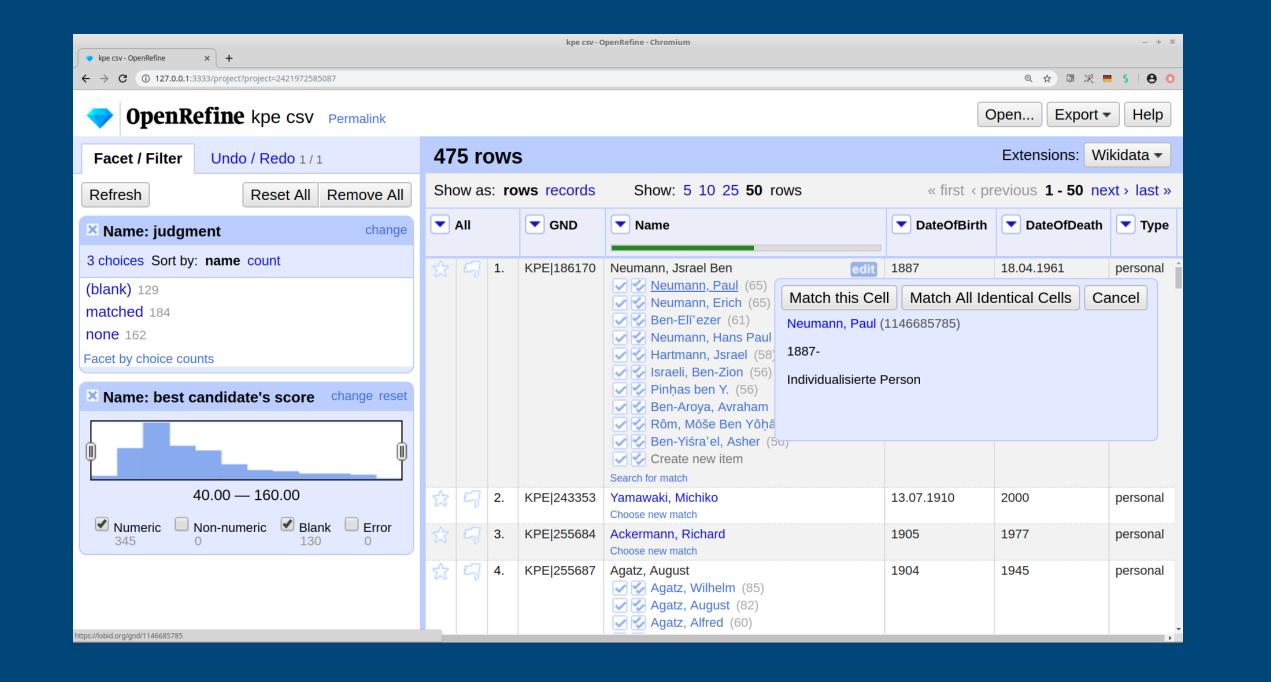
KALLIOPE-VERBUND



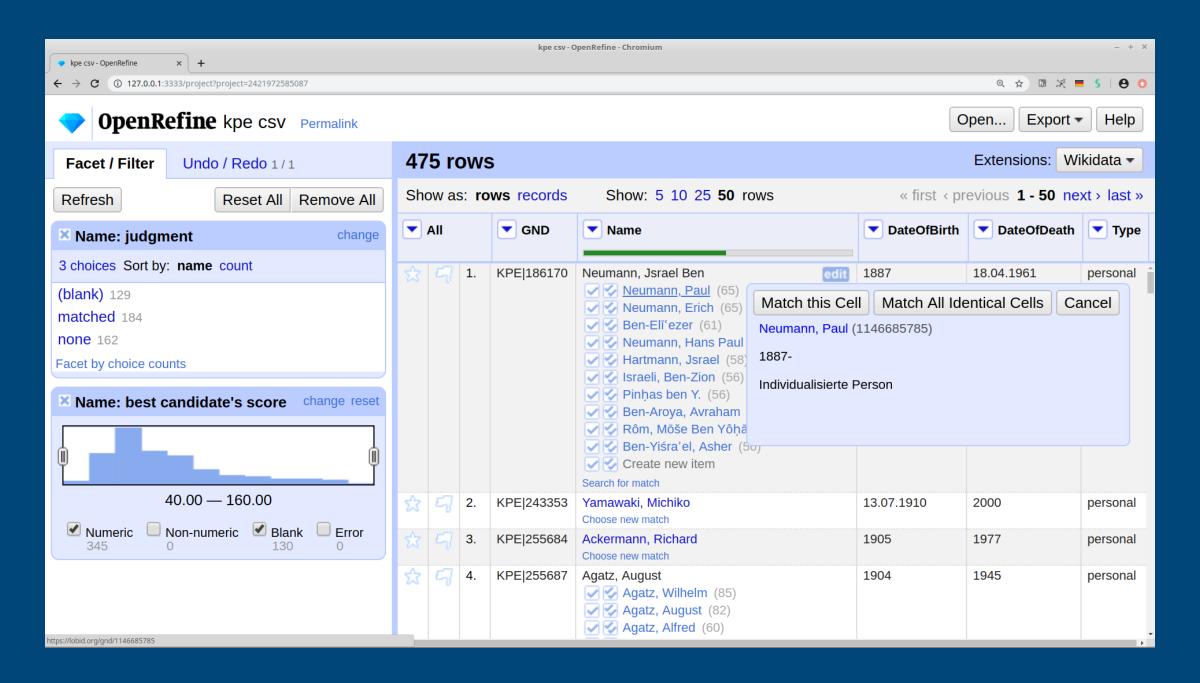
correspSearch Briefeditionen durchsuchen und vernetzen deutsches literatur archiv marbach

bauhaus-archiv

Abgleich und Anreicherung lokaler Archivdaten mit der GND



Abgleich und Anreicherung lokaler Archivdaten mit der GND



Unter Nutzung von OpenRefine und der entsprechenden lobid Reconciliation API

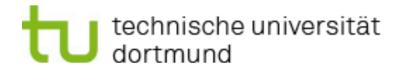


Briefeditionen durchsuchen und vernetzen

Die Nordrhein-Westfälische Bibliographie



Biographisches Portal NRW ulb Münster

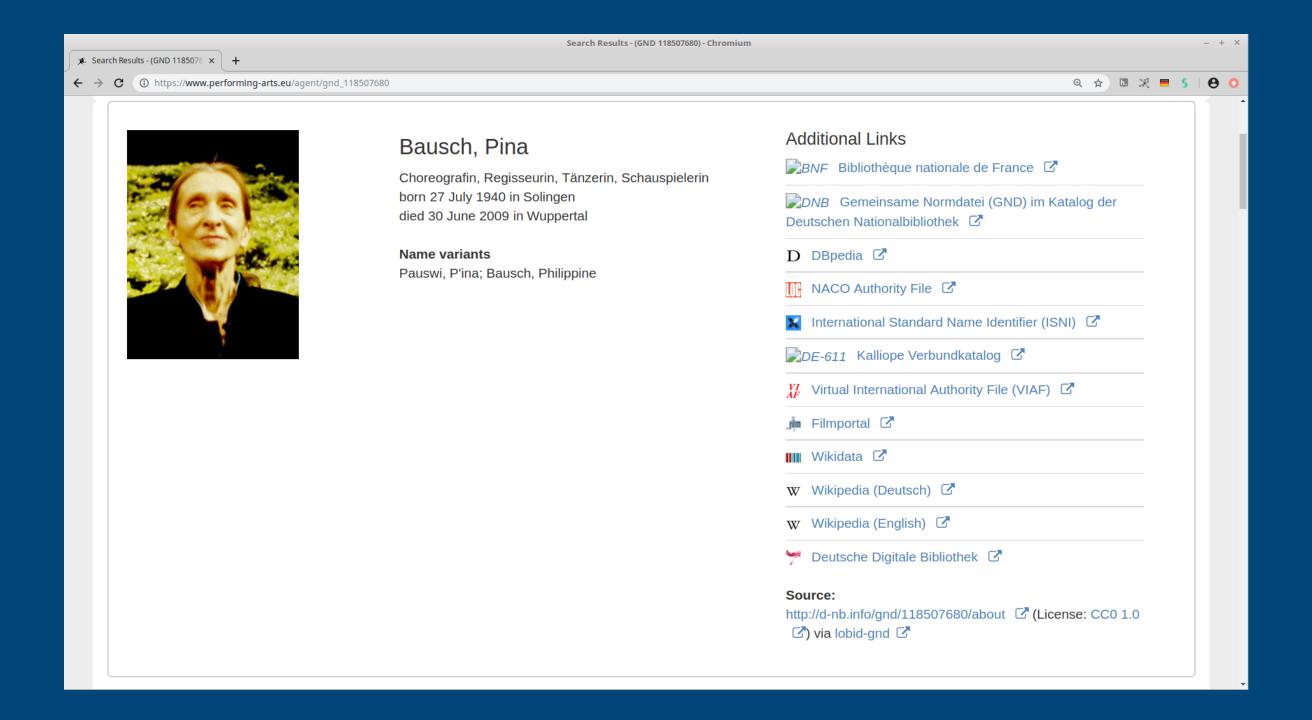


bauhaus-archiv

deutsches literatur archiv marbach

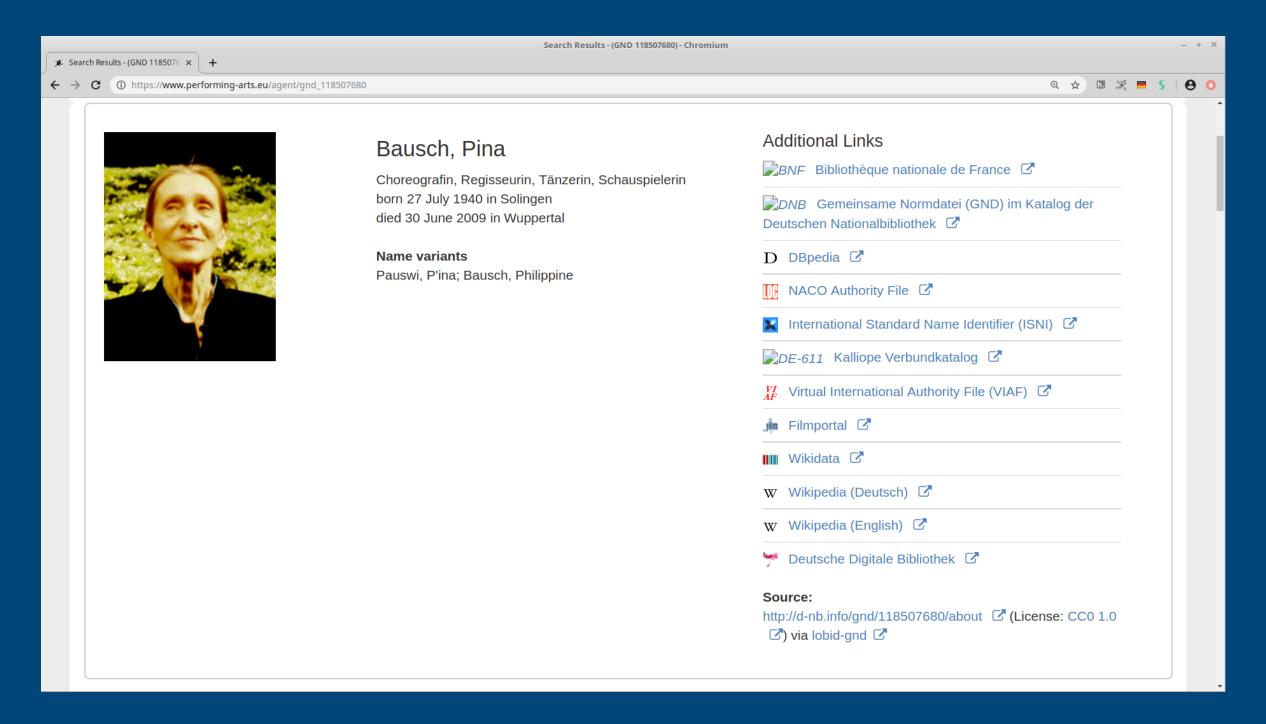
4

Infoboxen zu Personen aus der GND



4

Infoboxen zu Personen aus der GND



Außerdem Nutzung der lobid Reconciliation API zum Mappen großer Mengen von Personendaten auf die GND







Die Nordrhein-Westfälische Bibliographie



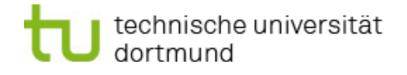
Virtuelle Deutsche Landesbibliographie

Meta-Katalog zum Nachweis landeskundlicher Literatur in Deutschland





Biographisches Portal NRW ulb Münster







correspSearch
Briefeditionen durchsuchen und vernetzen

RHEINLAND-PFALZ

bauhaus-archiv

deutsches literatur archiv marbach

Beispiel: lobid-gnd

Rechercheoberfläche & LOD-API für die GND

Normdatei für Bibliotheken im deutschsprachigen Raum

Normdatei für Bibliotheken im deutschsprachigen Raum

Datensätze für Personen, Körperschaften, Konferenzen & Veranstaltungen, Geografika, Schlagwörter, Werke

Normdatei für Bibliotheken im deutschsprachigen Raum

Datensätze für Personen, Körperschaften, Konferenzen & Veranstaltungen, Geografika, Schlagwörter, Werke

Für die formale Erfassung einer Ressource und für die inhaltliche Erschließung

Normdatei für Bibliotheken im deutschsprachigen Raum

Datensätze für Personen, Körperschaften, Konferenzen & Veranstaltungen, Geografika, Schlagwörter, Werke

Für die formale Erfassung einer Ressource und für die inhaltliche Erschließung

In den letzten Jahren wird die GND vermehrt auch von Archiven, Museen und Wissenschaftler:innen genutzt

Die GND-Kooperative

Die GND-Kooperative

Verantwortlich für die GND ist die GND-Kooperative

Die GND-Kooperative

Verantwortlich für die GND ist die GND-Kooperative

Die GND-Kooperative besteht hauptsächlich aus den deutschsprachigen Bibliotheksverbünden, den angeschlossenen Bibliotheken sowie der Deutschen Nationalbibliothek (DNB) als technischer Hoster

Die DNB publiziert die GND unter anderem als Linked Open Data (LOD) unter https://data.dnb.de/opendata/

Die DNB publiziert die GND unter anderem als Linked Open Data (LOD) unter https://data.dnb.de/opendata/

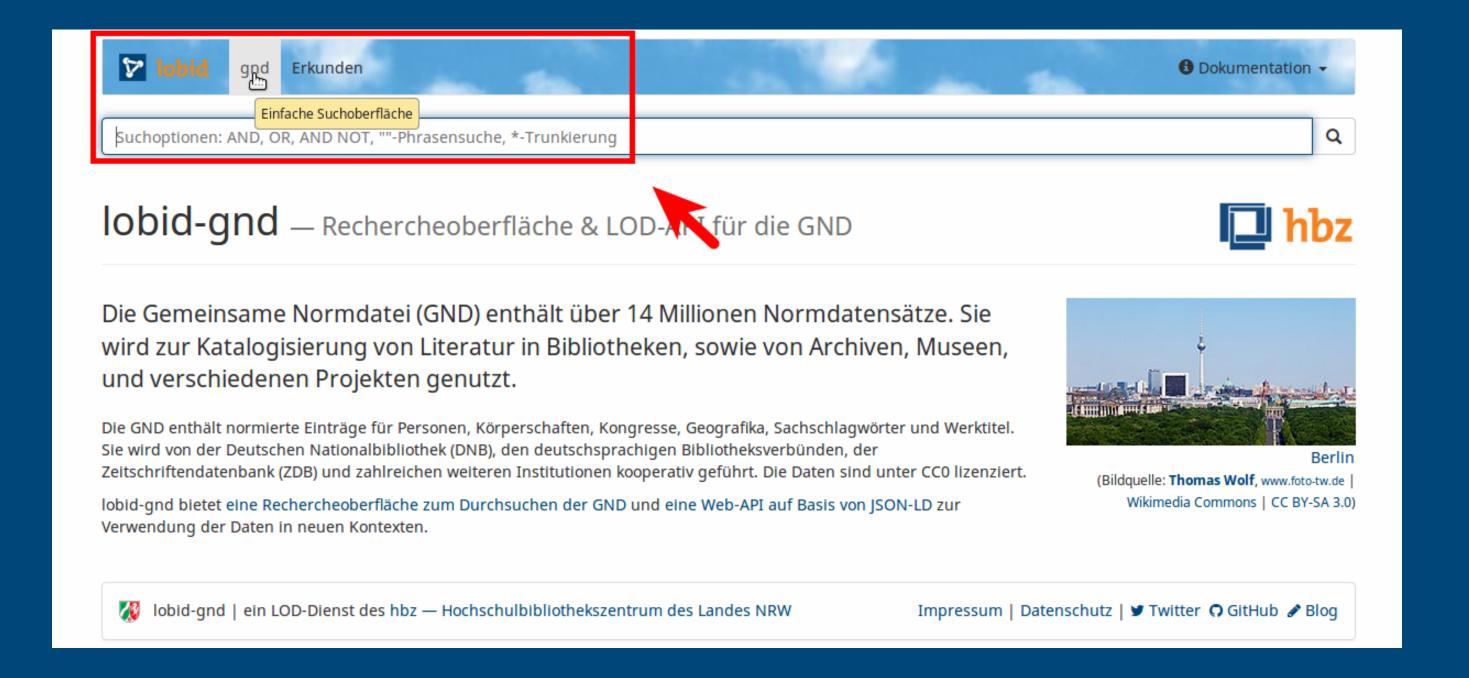
Zusätzliche Anreicherungen, z.B. Links in EntityFacts

Die DNB publiziert die GND unter anderem als Linked Open Data (LOD) unter https://data.dnb.de/opendata/

Zusätzliche Anreicherungen, z.B. Links in EntityFacts

Diese Daten bilden die Grundlage für lobid-gnd

Die Oberfläche

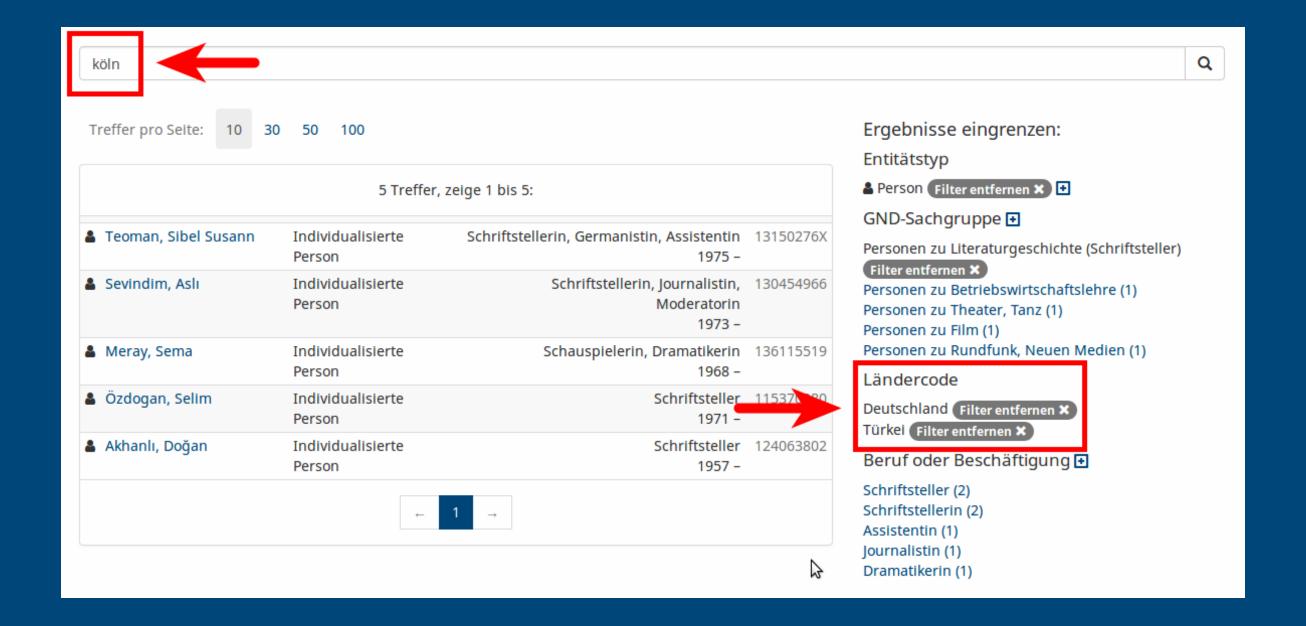


4

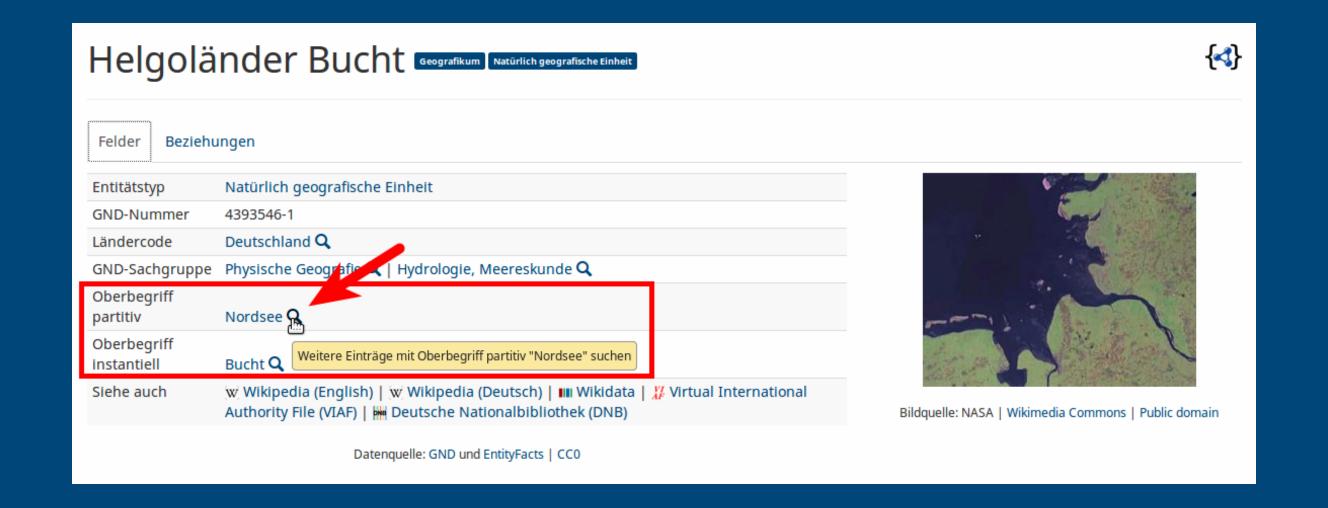
Auto Suggest



Ergebnisliste

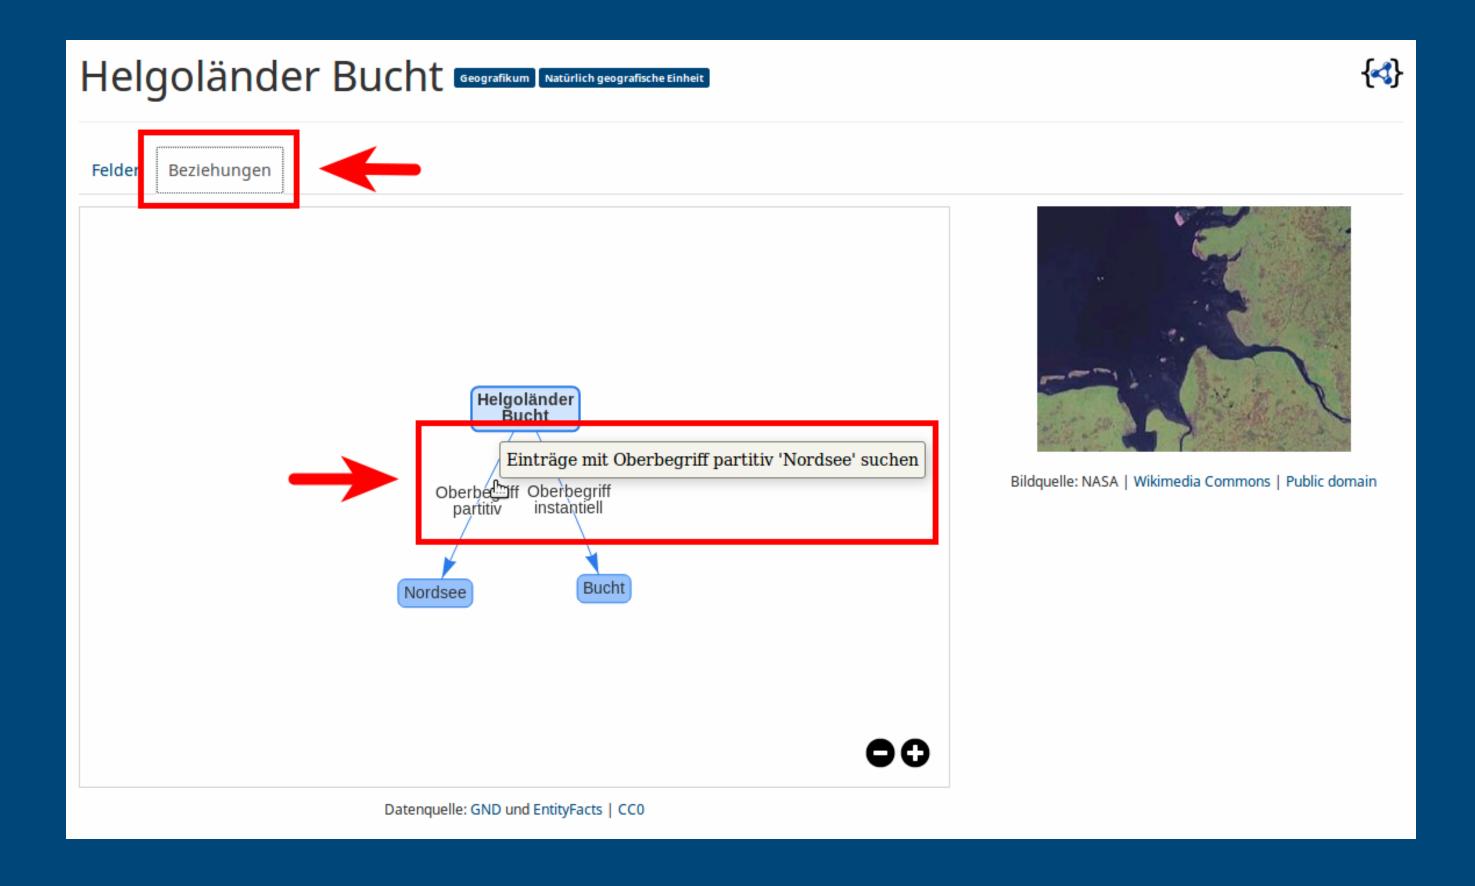


Einzeltreffer



 $oldsymbol{A}$

Beziehungsgraph



Übung

Probiert die auf den vorigen Folien beschriebene Oberfläche von lobid-gnd aus (die Screenshots verlinken auf die entsprechenden Seiten)

Teil 2: Linked Data & JSON-LD

Standards	RDF, Linked Data	11:00–11:30
APIs	JSON, JSON-LD, LOUD	11:30–12:00
lobid-gnd	Daten und Abfragemöglichkeiten GND	12:00–12:30
lobid- resources	Daten und Abfragemöglichkeiten Verbundkatalog	13:30–14:00

Übung

"Verschicke" einen Link zum Buch "With Reference to Reference" von Catherine Elgin

1: OPAC -> http://okeanos-www.hbz-nrw.de/F

2: lobid-resources -> https://lobid.org/resources

Überführung traditioneller bibl. Praktiken in das Web

Überführung traditioneller bibl. Praktiken in das Web

Sichtbarkeit und Auffindbarkeit im Web erreichen

Überführung traditioneller bibl. Praktiken in das Web Sichtbarkeit und Auffindbarkeit im Web erreichen Nachnutzbarkeit ermöglichen

Überführung traditioneller bibl. Praktiken in das Web

Sichtbarkeit und Auffindbarkeit im Web erreichen

Nachnutzbarkeit ermöglichen

Synergieeffekte durch Verlinkung mit anderen Daten

Überführung traditioneller bibl. Praktiken in das Web Sichtbarkeit und Auffindbarkeit im Web erreichen Nachnutzbarkeit ermöglichen Synergieeffekte durch Verlinkung mit anderen Daten

Verbesserung der Recherchemöglichkeiten

Überführung traditioneller bibl. Praktiken in das Web

Sichtbarkeit und Auffindbarkeit im Web erreichen

Nachnutzbarkeit ermöglichen

Synergieeffekte durch Verlinkung mit anderen Daten

Verbesserung der Recherchemöglichkeiten

Quelle: Pohl, Adrian / Ostrowski, Felix (2010): 'Linked Data' - und warum wir uns im hbz-Verbund damit beschäftigen." B.I.T. Online 13(3): S. 259-268. Preprint: http://www.hbz-nrw.de/dokumentencenter/produkte/lod/aktuell/pohl_ostrowski_2010_linked-data.pdf

LOD als politische Entscheidung

LOD als politische Entscheidung

LOD hat zum Ziel, Austausch und Nachnutzung von Daten über Systemgrenzen hinweg zu vereinfachen. Somit richtet es sich an Organisationen,

LOD als politische Entscheidung

LOD hat zum Ziel, Austausch und Nachnutzung von Daten über Systemgrenzen hinweg zu vereinfachen. Somit richtet es sich an Organisationen,

> deren Geschäftsmodell nicht darauf basiert Nutzer*innendaten zu horten,

LOD als politische Entscheidung

LOD hat zum Ziel, Austausch und Nachnutzung von Daten über Systemgrenzen hinweg zu vereinfachen. Somit richtet es sich an Organisationen,

> deren Geschäftsmodell nicht darauf basiert Nutzer*innendaten zu horten,

die nicht im kommerziellen Wettbewerb stehen,

LOD als politische Entscheidung

LOD hat zum Ziel, Austausch und Nachnutzung von Daten über Systemgrenzen hinweg zu vereinfachen. Somit richtet es sich an Organisationen,

deren Geschäftsmodell nicht darauf basiert Nutzer*innendaten zu horten,

die nicht im kommerziellen Wettbewerb stehen, die existieren, um Information zu teilen.

LOD als politische Entscheidung

LOD hat zum Ziel, Austausch und Nachnutzung von Daten über Systemgrenzen hinweg zu vereinfachen. Somit richtet es sich an Organisationen,

deren Geschäftsmodell nicht darauf basiert Nutzer*innendaten zu horten,

die nicht im kommerziellen Wettbewerb stehen, die existieren, um Information zu teilen.

Siehe auch Dorian Taylor (2022): "Linked Data is a political agenda"

Open Data

Wissen ist offen, wenn jedeR darauf frei zugreifen, es nutzen, verändern und teilen kann – eingeschränkt höchstens durch Maßnahmen, die Ursprung und Offenheit des Wissens bewahren.

Open Data

Wissen ist offen, wenn jedeR darauf frei zugreifen, es nutzen, verändern und teilen kann – eingeschränkt höchstens durch Maßnahmen, die Ursprung und Offenheit des Wissens bewahren.

http://opendefinition.org/od/2.1/de/

1. Nutze URIs als Namen für Dinge

- 1. Nutze URIs als Namen für Dinge
- 2. Nutze HTTP-URIs, so dass Menschen sie aufrufen können

- 1. Nutze URIs als Namen für Dinge
- 2. Nutze HTTP-URIs, so dass Menschen sie aufrufen können
- 3. Wenn jemand einen URI aufruft, biete nützliche Informationen an unter Nutzung der Standards (RDF, SPARQL)

- 1. Nutze URIs als Namen für Dinge
- 2. Nutze HTTP-URIs, so dass Menschen sie aufrufen können
- 3. Wenn jemand einen URI aufruft, biete nützliche Informationen an unter Nutzung der Standards (RDF, SPARQL)
- 4. Nimm Links zu anderen URIs auf, so dass weitere Dinge entdeckt werden können.

- 1. Nutze URIs als Namen für Dinge
- 2. Nutze HTTP-URIs, so dass Menschen sie aufrufen können
- 3. Wenn jemand einen URI aufruft, biete nützliche Informationen an unter Nutzung der Standards (RDF, SPARQL)
- 4. Nimm Links zu anderen URIs auf, so dass weitere Dinge entdeckt werden können.

Tim Berners-Lee (2006ff): Linked Data – Design Issues

Uniform: einheitliche Struktur (RFC 3986)

Uniform: einheitliche Struktur (RFC 3986)

Resource: ein Ding, ob digital oder nicht-digital

Uniform: einheitliche Struktur (RFC 3986)

Resource: ein Ding, ob digital oder nicht-digital

Identifier: Identifikation durch Vergabe eines Namens / ID

http://lobid.org/resources/HT002948556#!

http://lobid.org/resources/HT002948556#!

urn:nbn:de:hbz:6:2-1426138

http://lobid.org/resources/HT002948556#!

urn:nbn:de:hbz:6:2-1426138

doi:10.3278/6004804w

http://lobid.org/resources/HT002948556#!

urn:nbn:de:hbz:6:2-1426138

doi:10.3278/6004804w

https://dx.doi.org/10.3278/6004804w

Graph-basiertes Datenmodell

Graph-basiertes Datenmodell

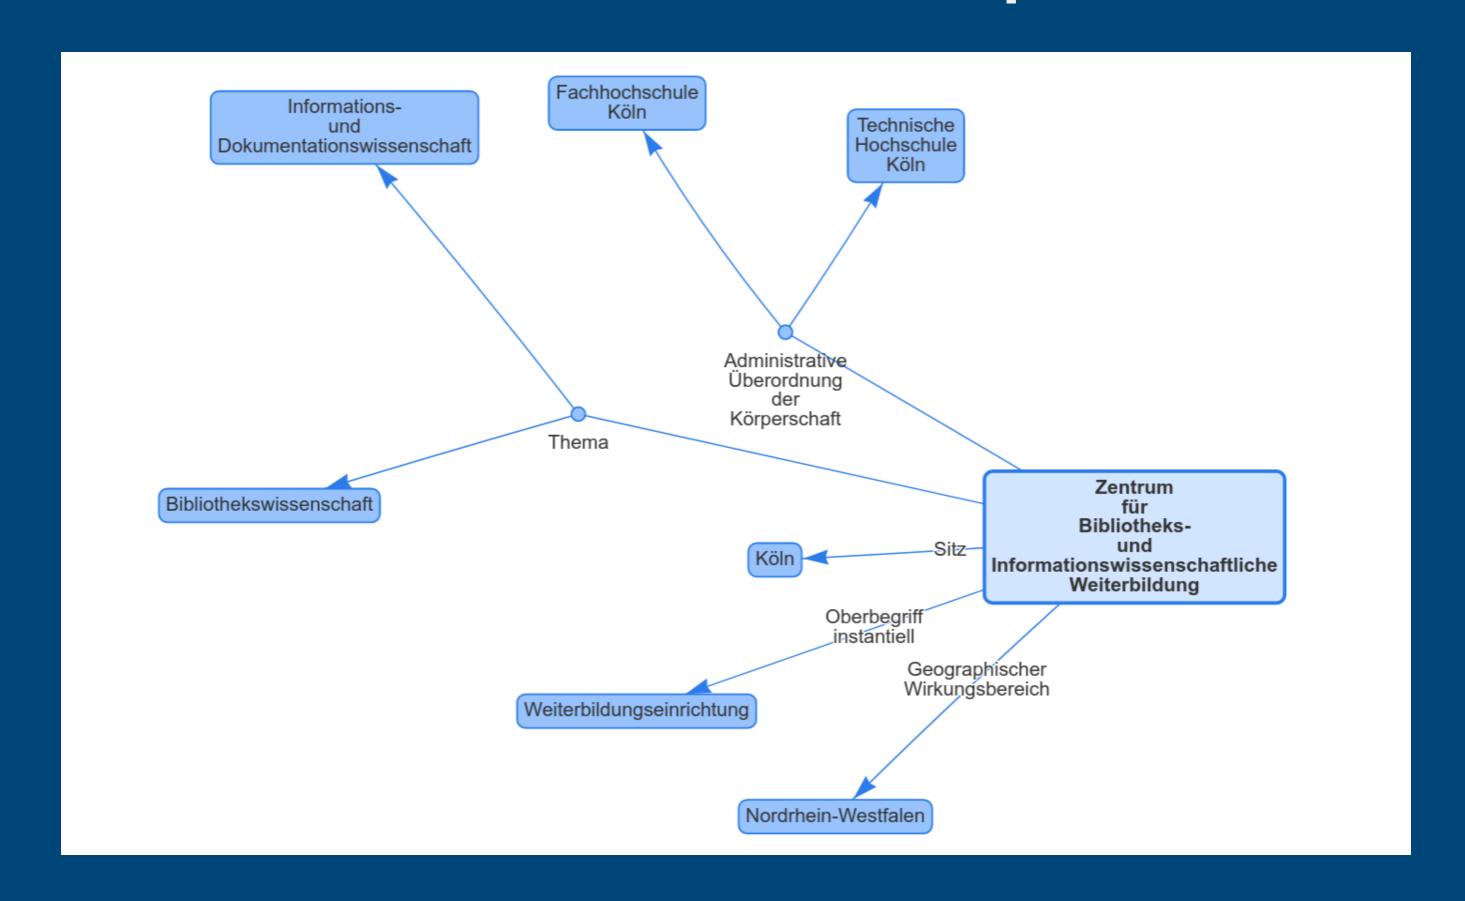
Zum Austausch von Daten über das Web, entworfen und gepflegt vom W3C

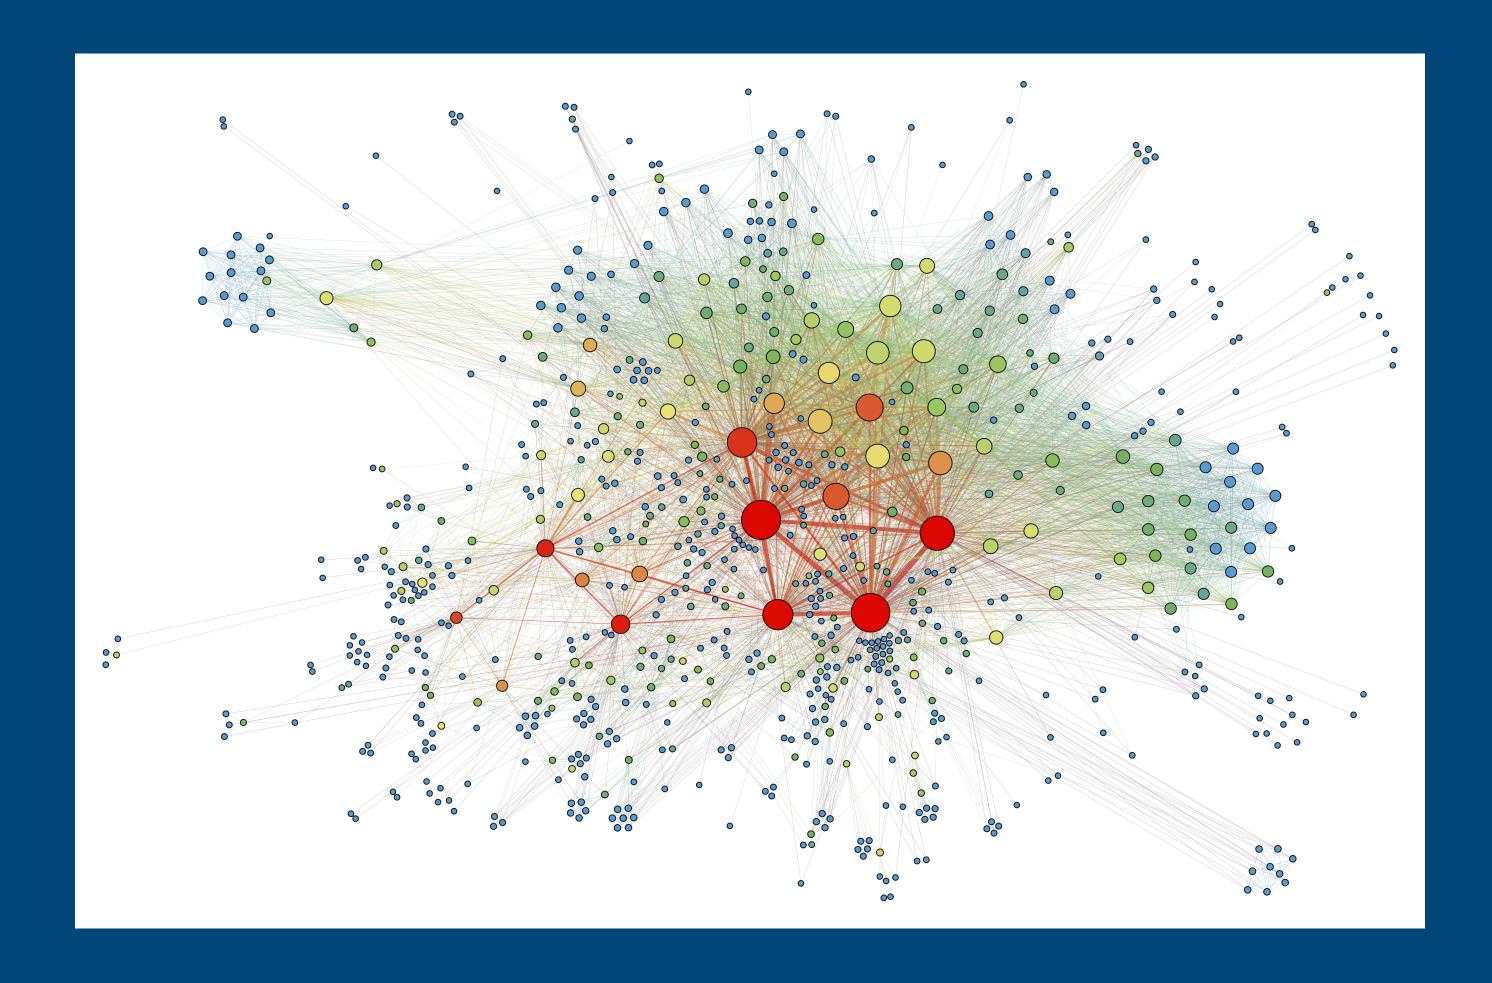
Graph-basiertes Datenmodell

Zum Austausch von Daten über das Web, entworfen und gepflegt vom W3C

Abstraktes Modell mit verschiedenen Serialisierungsformaten (RDF/XML, Turtle, JSON-LD...)

Was ist ein Graph?



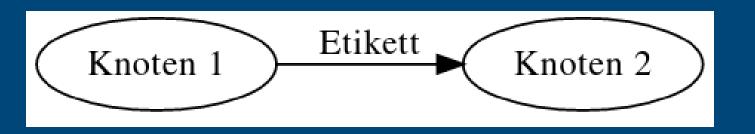


File:SocialNetworkAnalysis.png von Martin Grandjean, CC-BY-SA 4.0

RDF: ein gerichteter, beschrifteter Graph

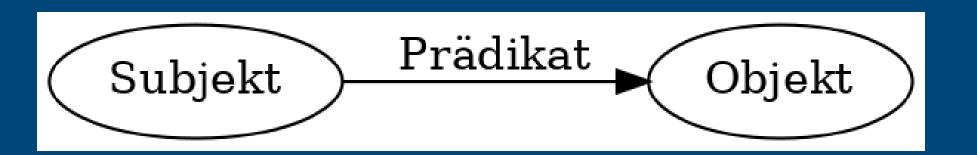
Englisch: directed labeled graph

d.h. die Kanten haben eine Richtung und ein Etikett



Tripel: Das Graph-Atom

Alle Daten in RDF existieren in Form von Tripeln mit Subjekt, Prädikat, Objekt:



Subjekt: Ressource über die eine Aussage getroffen wird

Subjekt: Ressource über die eine Aussage getroffen wird

Prädikat: Beziehung zwischen Subjekt und Objekt

Subjekt: Ressource über die eine Aussage getroffen wird

Prädikat: Beziehung zwischen Subjekt und Objekt

Objekt: Ressource, zu dem die Ressource in einer Verbindung steht oder ein Literal

URIs und Literale

URIs und Literale

Subjekt und Prädikat sind immer ein URI

URIs und Literale

Subjekt und Prädikat sind immer ein URI

Objekt ist ein URI oder ein Literal (String, Date, Integer)

Subjekt	Prädikat	Objekt
Ich	heiße	Adrian
https://orcid.org/0000- 0001-9083-7442	https://schema.org/name	"Adrian"@de
Ich	interessiere mich für	Linked Library Data
https://orcid.org/0000- 0001-9083-7442	http://xmlns.com/foaf/0.1/interest	http://www.wikidata.org/entity/Q28134421

Ein abstraktes Modell

Ein abstraktes Modell

Die verschiedenen RDF-Serialisierungen sind semantisch äquivalent

Ein abstraktes Modell

Die verschiedenen RDF-Serialisierungen sind semantisch äquivalent

Deshalb wird es ein "abstraktes" Modell genannt

N-Triples

```
<https://orcid.org/0000-0001-9083-7442> <http://www.w3.org/1999/02/22-rdf-syntax-ns#type>
<https://schema.org/namePerson> .
<https://orcid.org/0000-0001-9083-7442> <https://schema.org/namename> "Adrian"@de .
<https://orcid.org/0000-0001-9083-7442> <http://xmlns.com/foaf/0.1/interest>
<http://www.wikidata.org/entity/Q466> .
<https://orcid.org/0000-0001-9083-7442> <http://xmlns.com/foaf/0.1/interest>
<http://www.wikidata.org/entity/Q28134421> .
<https://orcid.org/0000-0001-9083-7442> <http://xmlns.com/foaf/0.1/interest>
<http://www.wikidata.org/entity/Q341> .
<https://orcid.org/0000-0001-9083-7442> <http://xmlns.com/foaf/0.1/interest>
<http://www.wikidata.org/entity/Q380962> .
<https://orcid.org/0000-0001-9083-7442> <http://xmlns.com/foaf/0.1/interest>
<http://www.wikidata.org/entity/Q380962> .
<https://orcid.org/0000-0001-9083-7442> <http://xmlns.com/foaf/0.1/interest>
<http://www.wikidata.org/entity/Q56298524> .
```

Turtle

RDF/XML

```
<?xml version="1.0" encoding="utf-8"?>
<rdf:RDF xmlns:foaf="http://xmlns.com/foaf/0.1/"
        xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
        xmlns:schema="https://schema.org/name">
        <schema:Person rdf:about="https://orcid.org/0000-0001-9083-</pre>
7442">
        <foaf:interest
rdf:resource="http://www.wikidata.org/entity/Q28134421"/>
        <foaf:interest
rdf:resource="http://www.wikidata.org/entity/Q341"/>
        <foaf:interest
rdf:resource="http://www.wikidata.org/entity/Q380962"/>
        <foaf:interest
rdf:resource="http://www.wikidata.org/entity/Q466"/>
        <foaf:interest
rdf:resource="http://www.wikidata.org/entity/Q56298524"/>
        <schema:name xml:lang="de">Adrian</schema:name>
        </schema:Person>
</rdf:RDF>
```

 Λ

RDF & The Semantic Web

RDF & The Semantic Web – cutting edge seit 1999

Linked Data

Ultimately, RDF and the Semantic Web are of no interest to Web developers. They also have a really negative public perception problem. We should stop talking about them. Let's shift the focus to be on Linked Data, explaining the problems that Web developers face today, and concrete, demonstrable solutions to those problems.

Linked Data

Ultimately, RDF and the Semantic Web are of no interest to Web developers. They also have a really negative public perception problem. We should stop talking about them. Let's shift the focus to be on Linked Data, explaining the problems that Web developers face today, and concrete, demonstrable solutions to those problems.

 Manu Sporny, damals Vorsitzender der RDFa Working Group beim W3C, der JSON-LD Community Group & Mitglied weiterer Semantic-Web-Gruppen, beim Schreiben an der JSON-LD-Spezifikation Sporny (2012)

Linked Open Usable Data



Rob Sanderson

@azaroth42

Folge ich

"Open" is not necessarily simple nor useful, just available. We need fans to get LOUD: Linked Open Useful Data:)

Tweet übersetzen

19:39 - 23. Aug. 2016

Quelle: Rob Sanderson auf Twitter

Siehe auch Rob Sanderson's Europeanatech 2018 Keynote (Slides, Aufzeichnung)

Daten werden mit existierender Software bearbeitet (ausgewertet, ergänzt, integriert etc.)

Daten werden mit existierender Software bearbeitet (ausgewertet, ergänzt, integriert etc.)

Entwicklung neuer Software zur Interaktion mit Daten

Daten werden mit existierender Software bearbeitet (ausgewertet, ergänzt, integriert etc.)

Entwicklung neuer Software zur Interaktion mit Daten

LOUD: Orientierung auf Bedürfnisse und Konventionen rund um Software (Entwicklung, Standards, etc.)

Daten werden mit existierender Software bearbeitet (ausgewertet, ergänzt, integriert etc.)

Entwicklung neuer Software zur Interaktion mit Daten

LOUD: Orientierung auf Bedürfnisse und Konventionen rund um Software (Entwicklung, Standards, etc.)

Nützliche Daten: Zielgruppe kennen & eigene Angebote auf sie ausrichten

Daten werden mit existierender Software bearbeitet (ausgewertet, ergänzt, integriert etc.)

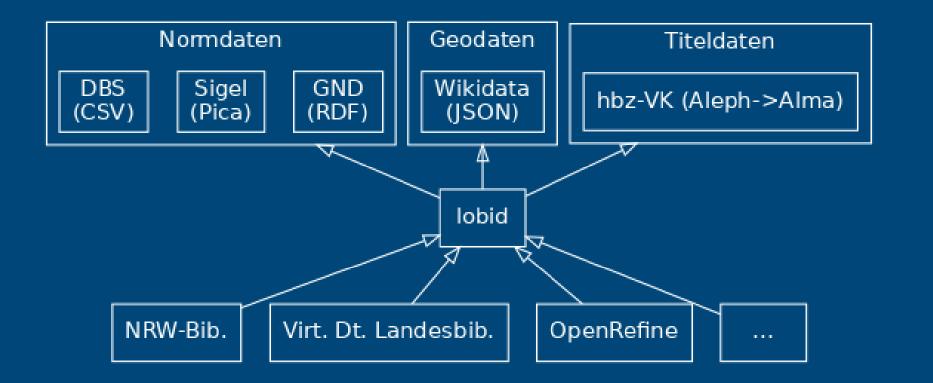
Entwicklung neuer Software zur Interaktion mit Daten

LOUD: Orientierung auf Bedürfnisse und Konventionen rund um Software (Entwicklung, Standards, etc.)

Nützliche Daten: Zielgruppe kennen & eigene Angebote auf sie ausrichten

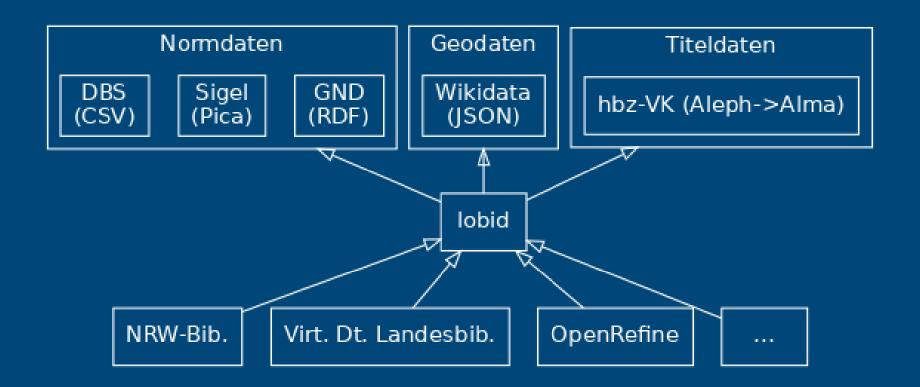
Hauptzielgruppe: Entwickler:innen oder Nutzer:innen von Software für Datenzugriff und -manipulation

Zum Bsp. lobid-Datenquellen und -Anwendungen



 $oldsymbol{r}$

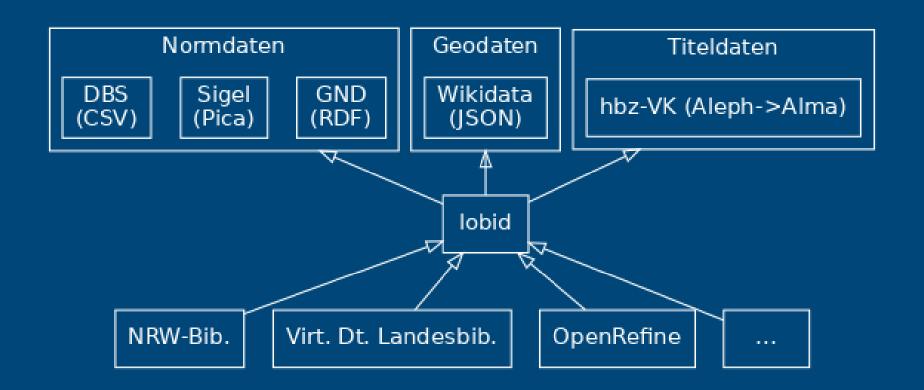
Zum Bsp. lobid-Datenquellen und -Anwendungen



Programmierschnittstellen (Application Programming Interfaces, API) entkoppeln Anwendungen von Datenquellen, Formaten und Systemen

F

Zum Bsp. lobid-Datenquellen und -Anwendungen



Programmierschnittstellen (Application Programming Interfaces, API) entkoppeln Anwendungen von Datenquellen, Formaten und Systemen

APIs ermöglichen Integration in Drittanbieter-Software

F

Und wie APIs im Web bereitstellen?

Und wie APIs im Web bereitstellen?

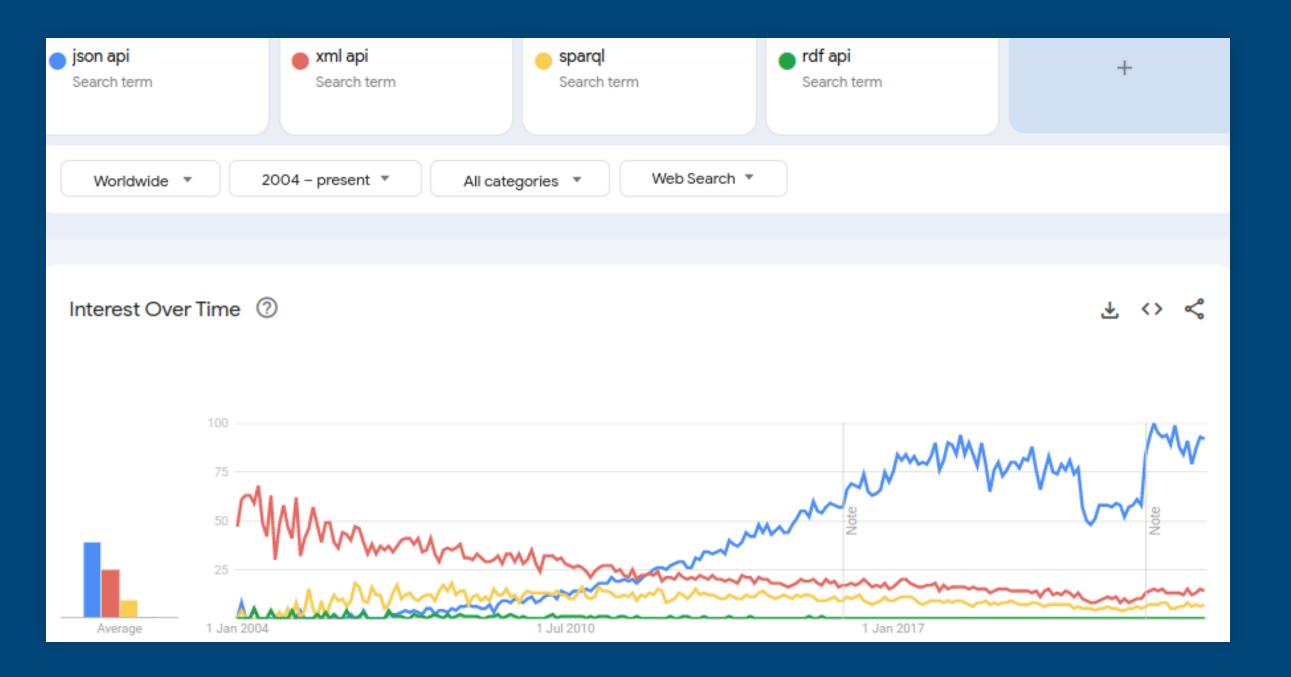
JSON über HTTP

Und wie APIs im Web bereitstellen?

JSON über HTTP

Der Web-API-Standard seit Jahren, siehe z.B. Target (2017)

The Rise and Rise of JSON



Quelle: Google Trends

 $^{\prime\prime}$

Ein einfaches Key-Value-Format für strukturierte Daten

Ein einfaches Key-Value-Format für strukturierte Daten Key ist immer ein String

Ein einfaches Key-Value-Format für strukturierte Daten

Key ist immer ein String

Value ist String, Number, Boolean, Array oder Object

•

Ein einfaches Key-Value-Format für strukturierte Daten Key ist immer ein String

Value ist String, Number, Boolean, Array oder Object

```
{ "foo": "bar" }
```

Ein einfaches Key-Value-Format für strukturierte Daten

Key ist immer ein String

Value ist String, Number, Boolean, Array oder Object

```
{ "foo": "bar" }
```

Quelle: RFC 8259

z.B. JSON über HTTP GET https://lobid.org/organisations/DE-1a

CURL

CURL

Kommandozeilen-Tool zum Datentransfer mit URLs

CURL

Kommandozeilen-Tool zum Datentransfer mit URLs

https://curl.haxx.se/download.html

CURL

Kommandozeilen-Tool zum Datentransfer mit URLs

https://curl.haxx.se/download.html

https://reqbin.com/curl

CURL

Kommandozeilen-Tool zum Datentransfer mit URLs

https://curl.haxx.se/download.html

https://reqbin.com/curl

\$ curl "https://lobid.org"

Übung: cURL

```
COPY  # Kopieren und im Terminal einfügen (s. Hinweise unten)
/Paste  # Copy  # Kopieren und im Terminal einfügen (s. Hinweise unten)
| $ curl "https://lobid.org/organisations/DE-la"

History  $ ↑ # Auf die Kommandozeilen-History zugreifen  $ curl "https://lobid.org/organisations/DE-la"
```

(Für Copy/Paste in GUI: CTRL+c bzw. CTRL+v.

Im Terminal: SHIFT+CTRL+c bzw. SHIFT+CTRL+v.)

U

Antwort

```
$ curl https://lobid.org/organisations/DE-1a
  "linkedTo" : {
    "id" : "http://lobid.org/organisations/DE-601#!",
    "label": "Verbundzentrale des GBV (VZG)"
  "rs": "110000000000",
  "address" : {
    "addressLocality" : "Berlin",
    "type" : "PostalAddress",
    "addressCountry" : "DE",
    "postalCode" : "10772"
  },
```

Antwort

```
curl https://lobid.org/organisations/DE-1a
"linkedTo" : {
  "id" : "http://lobid.org/organisations/DE-601#!",
  "label": "Verbundzentrale des GBV (VZG)"
"rs": "11000000000",
"address" : {
  "addressLocality" : "Berlin",
  "type" : "PostalAddress",
  "addressCountry" : "DE",
  "postalCode" : "10772"
},
```

Ausgabe ist lang, oft wollen wir nur bestimmte Werte

JavaScript Object Notation (JSON)

JavaScript Object Notation (JSON)

```
var options = {
  url: 'https://lobid.org/organisations/DE-la'
};

request(options, function (error, response, body) {
  var doc = JSON.parse(body);
  console.log('postal code:', doc.address.postalCode) // <--
});</pre>
```

JavaScript Object Notation (JSON)

```
var options = {
  url: 'https://lobid.org/organisations/DE-1a'
};

request(options, function (error, response, body) {
  var doc = JSON.parse(body);
  console.log('postal code:', doc.address.postalCode) // <--
});</pre>
```

> postal code: 10772

j

Ein flexibles Kommandozeilen-Tool zur JSON-Verarbeitung

Ein flexibles Kommandozeilen-Tool zur JSON-Verarbeitung

https://stedolan.github.io/jq/

Ein flexibles Kommandozeilen-Tool zur JSON-Verarbeitung

https://stedolan.github.io/jq/

https://jqplay.org/

Ein flexibles Kommandozeilen-Tool zur JSON-Verarbeitung

https://stedolan.github.io/jq/

https://jqplay.org/

\$ jq --help

Übung: JSON mit jq (1)

```
$ curl "https://lobid.org/organisations/DE-1a" \
| jq .name # filter: .name
```

Ubung: JSON mit jq (2)

Kostenträger

```
$ curl "https://lobid.org/organisations/DE-1a"
jq <???> # dt. Bezeichner für den Kostenträger
```

datum

```
Modifikations- $ curl "https://lobid.org/organisations/DE-1a"
                 jq <???> # Datum der letzten Modifikation
```

Ubung: JSON mit jq (3)

```
Kosten-
träger
```

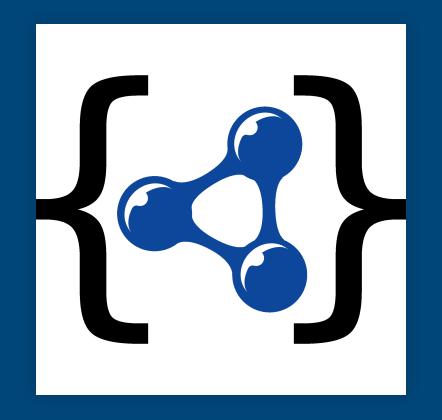
```
$ curl "https://lobid.org/organisations/DE-1a"
jq .fundertype.label.de
```

```
datum
```

```
Modifikations- $ curl "https://lobid.org/organisations/DE-1a"
                 jq .mainEntityOfPage.dateModified
```

JSON ist praktisch & verbreitet, aber was ist mit Linked Data & RDF?

JSON + Linked Data = JSON-LD



"designed to be usable directly as JSON, with no knowledge of RDF" – Es ist richtiges JSON!

"designed to be usable directly as JSON, with no knowledge of RDF" – Es ist richtiges JSON!

"also designed to be usable as RDF"

"designed to be usable directly as JSON, with no knowledge of RDF" – Es ist richtiges JSON!

"also designed to be usable as RDF"

https://www.w3.org/TR/json-ld/

JSON

```
$ curl -H "Accept: application/json"
https://api.github.com/users/acka47
```

```
"login": "acka47",
  "avatar_url":
"https://avatars2.githubusercontent.com/u/160292?v=4",
  "url": "https://api.github.com/users/acka47",
  "type": "User",
  "name": "Adrian",
  "company": "hbz",
  "location": "Cologne, Germany",
  "bio": "Metadata, RDF, vocabularies. Working at @hbz."
}
```

JSON + @id: Subject-URIs für Tripel-Struktur

```
{
  "@id": "https://github.com/users/acka47",
  "name": "Adrian",
  "location": "Cologne, Germany",
  ...
}
```

JSON + @context: URIs als eindeutige Prädikate

```
{
  "@context": "http://schema.org/",
  "name": "Adrian",  # -> http://schema.org/name
  "location": "Cologne", # -> http://schema.org/location
  ...
}
```

JSON + @context + @id = JSON-LD

```
{
  "@id": "https://github.com/users/acka47",
  "@context": "http://schema.org/",
  "name": "Adrian",
  "location": "Cologne, Germany"
}
```

JSON + @context + @id = JSON-LD

```
{
  "@id": "https://github.com/users/acka47",
  "@context": "http://schema.org/",
  "name": "Adrian",
  "location": "Cologne, Germany"
}
```

```
<https://github.com/users/acka47> <http://schema.org/location>
"Cologne, Germany" .
<https://github.com/users/acka47> <http://schema.org/name>
"Adrian" .
```

Andere RDF-Serialisierungen z.B. im JSON-LD Playground

2010-2013: lobid-Alpha-Betrieb mit RDF & SPARQL

2010-2013: lobid-Alpha-Betrieb mit RDF & SPARQL

2013-2017: lobid v1.x mit JSON-LD aber noch nicht sehr intuitiv nutzbar (JSON-LD als RDF-Serialisierung)

2010-2013: lobid-Alpha-Betrieb mit RDF & SPARQL

2013-2017: lobid v1.x mit JSON-LD aber noch nicht sehr intuitiv nutzbar (JSON-LD als RDF-Serialisierung)

seit 2017: LOUD lobid v2 plus OpenRefine-Schnittstellen

2010-2013: lobid-Alpha-Betrieb mit RDF & SPARQL

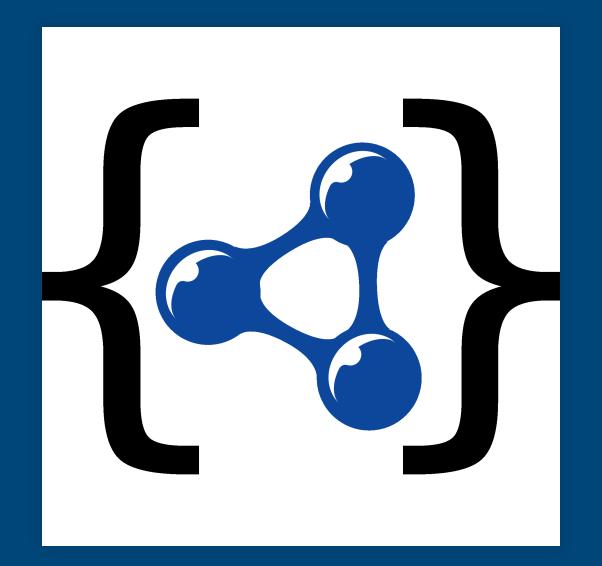
2013-2017: lobid v1.x mit JSON-LD aber noch nicht sehr intuitiv nutzbar (JSON-LD als RDF-Serialisierung)

seit 2017: LOUD lobid v2 plus OpenRefine-Schnittstellen

Von LOD zu LOUD – Erfahrungen aus zehn Jahren Linked-Open-Data-Entwicklung am hbz

Beispiel: lobid-gnd

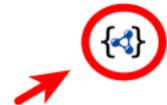
a. Die Daten



JSON-LD-Link

Suchoptionen: AND, OR, AND NOT, ""-Phrasensuche, *-Trunkierung

Arendt, Hannah Individualisierte Person Person



1906-1975 | Emigration 1933 nach Frankreich, 1941 in die USA

Felder	Beziehungen
--------	-------------

Entitätstyp	Individualisierte Person
GND-Nummer	11850391X
Beruf oder Beschäftigung	Schriftstellerin ${\bf Q}$ Politologin ${\bf Q}$ Historikerin ${\bf Q}$ Philosophin ${\bf Q}$ Soziologin ${\bf Q}$
Affiliation	Jewish Cultural Reconstruction Inc. Q
Akademischer Grad	Prof. Dr.
Ländercode	Frankreich Q Deutschland Q USA Q
GND-Sachgruppe	Personen zu Philosophie ${f Q}$ Personen zu Soziologie, Gesellschaft, Arbeit, Sozialgeschichte ${f Q}$ Personen (Politologen, Staatstheoretiker) ${f Q}$
Geschlecht	Weiblich Q
Geburtsdatum	1906-10-14
Sterbedatum	1975-12-04



Bildquelle: Barbara Niggl Radloff | Wikimedia Commons | CC BY-SA 4.0

JSON-LD-Daten

```
https://lobid.org/gnd/11850391X.json
                                                                 Q Search
        "hasGrandParent": [
           "id": "https://d-nb.info/gnd/119067159X",
           "label": "Arendt, Max"
       "gender": [
           "id": "https://d-nb.info/standards/vocab/gnd/gender#female",
10
           "label": "Weiblich"
11
12
13
14
       "relatedWork": [
15
           "id": "https://d-nb.info/gnd/4430639-8",
16
           "label": "Eichmann in Jerusalem"
17
18
19
       "dateOfDeath": [
20
21
          "1975-12-04"
22
       "placeOfDeath": [
23
24
           "id": "https://d-nb.info/gnd/4042011-5",
25
           "label": "New York, NY"
26
27
28
```

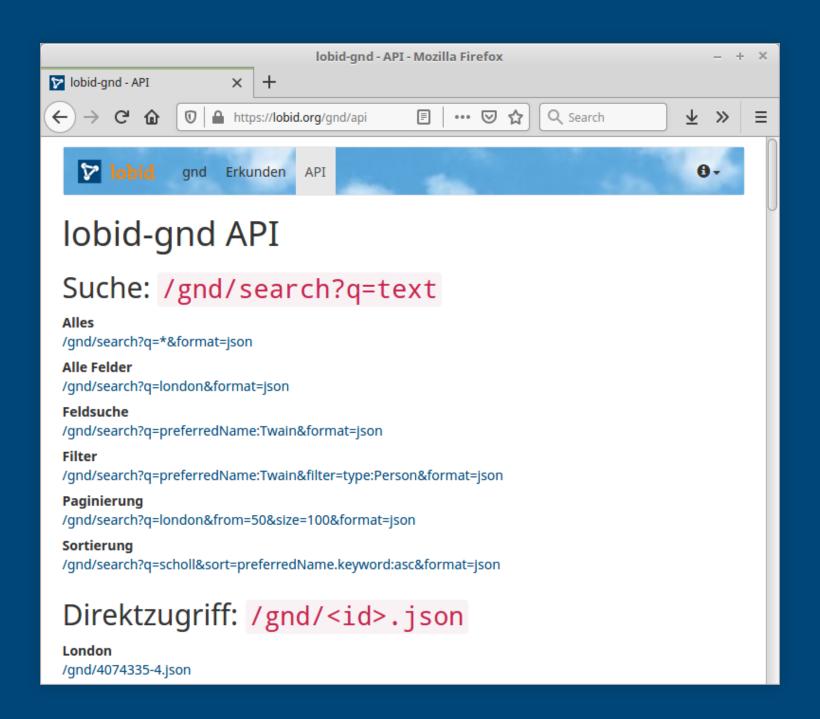
Browser-Plugin z.B. JSON Lite

JSON-LD-Daten

```
fsteeg@desk ~ 118x28
fsteeg@desk ~ $ curl -s https://lobid.org/gnd/11850391X.json | jq
 "hasGrandParent": [
      "id": "https://d-nb.info/gnd/119067159X",
      "label": "Arendt, Max"
  "gender": [
      "id": "https://d-nb.info/standards/vocab/gnd/gender#female",
      "label": "Weiblich"
 "relatedWork": [
      "id": "https://d-nb.info/gnd/4430639-8",
      "label": "Eichmann in Jerusalem"
 "dateOfDeath": [
   "1975-12-04"
 "placeOfDeath": [
      "id": "https://d-nb.info/gnd/4042011-5",
      "label": "New York, NY"
```

Hier mit curl und jq für Formatierung und Farbe

b. Web-API



102

JSON-LD-Daten in Elasticsearch-Index

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

Für Einzeltreffer: RDF per Content Negotiation

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

Für Einzeltreffer: RDF per Content Negotiation

API für Auto Suggest

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

Für Einzeltreffer: RDF per Content Negotiation

API für Auto Suggest

API für Bulk Downloads

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

Für Einzeltreffer: RDF per Content Negotiation

API für Auto Suggest

API für Bulk Downloads

Reconciliation Service API

Übung: Suchsyntax



 J

Übung: Suchsyntax

```
Feldsuche
                   ??? # <field>:<term>
Boolsche
                   ??? # AND, OR
Suche
Trunkierung
                   ??? # Trunkieren mit *
Intervalle
                   ??? # <feld>:[* TO <???>]
Existenz
                   ??? # exists :<field>
```

Elasticsearch 'query string' Dokumentation

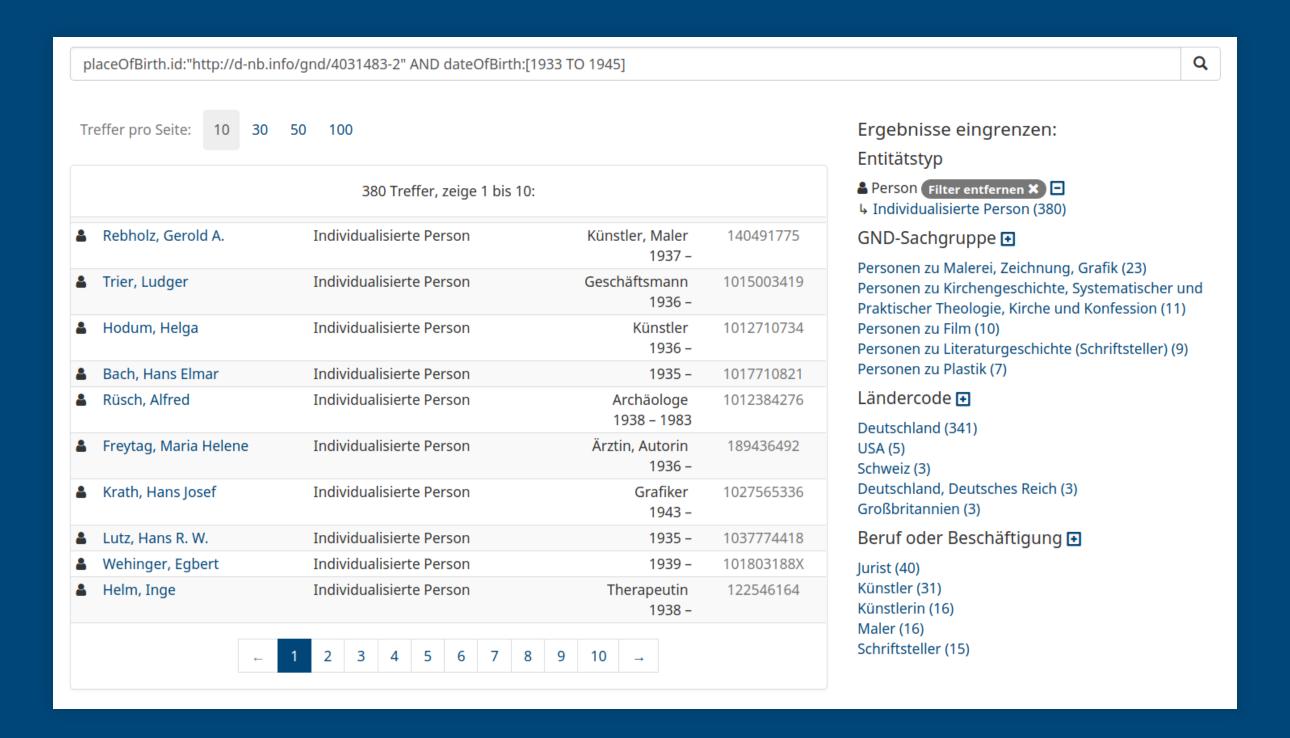
Suchsyntax: Lösungen

Feldsuche	abbreviatedNameForTheCorporateBody:zbiw
Boolsche Suche	Kunst AND (Kultur OR Wissenschaft)
Trunkierung	professionOrOccupation.label:Politiker*
Intervalle	dateOfBirth:[* TO 1500]
Existenz	_exists_:dateOfBirth

Elasticsearch 'query string' Dokumentation

Alles kombinierbar

Personen, die während der NS-Zeit in Köln geboren wurden



Übung

Suche nach allen Personen in der GND, die in Köln geboren wurden und in Düsseldorf gestorben sind

s. vorne, Rechercheoberfläche lobid-gnd | lobid-gnd: Formulierung komplexer Suchanfragen

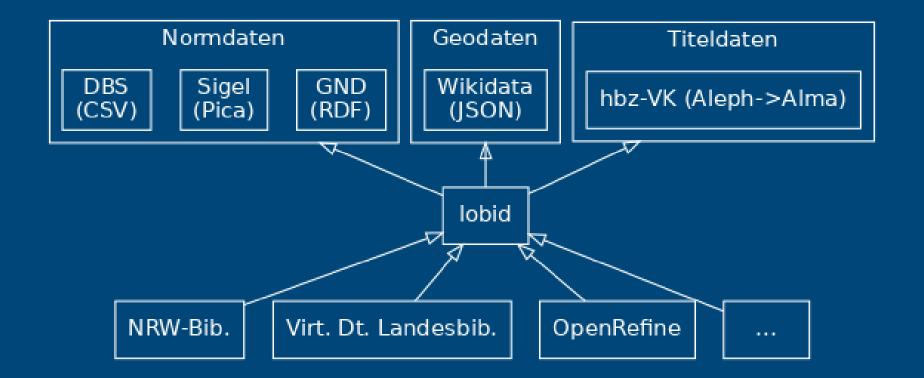
Personen, die in Köln geboren wurden und in Düsseldorf gestorben sind

placeOfBirth.id:"https://d-nb.info/gnd/4031483-2" AND placeOfDeath.id:"https://d-nb.info/gnd/4013255-9"					Q
Treffer pro Seite: 10	30 50 100			Ergebnisse eingrenzen: Entitätstyp	
21 Treffer, zeige 1 bis 10:			♣ Person (21)		
& Kemp, Willi	Individualisierte Person	Steuerberater, Fotograf, Kunstsammler 1927 – 2020	122767845	Personen zu Film (3) Personen zu Malerei, Zeichnung, Grafik Personen zu Theater, Tanz (2) Maschinell eingespielte Datensätze (Platzhalter) (1)	k (2)
Zaun, Fritz	Individualisierte Person	Dirigent, Musiker 1893 – 1966	133181332		
Fay, Joseph	Individualisierte Person	Maler, Künstler 1813 – 1875	117503371	Personen zu Betriebswirtschaftslehre (Ländercode	1)
& Elster, Hanns Martin	Individualisierte Person	Verleger, Herausgeber, Schriftsteller, Literarhistoriker 1888 – 1983	118819321	Deutschland (21) Beruf oder Beschäftigung •	
Adenauer, Ludwig	Individualisierte Person	Staatssekretär 1902 – 1971	1092700196	Schauspieler (5) Künstler (4)	
Ullrich, Martin	Individualisierte Person	Schauspieler, Sänger 1892 – 1943	1036292878	Musiker (4) Maler (3) Sänger (3)	

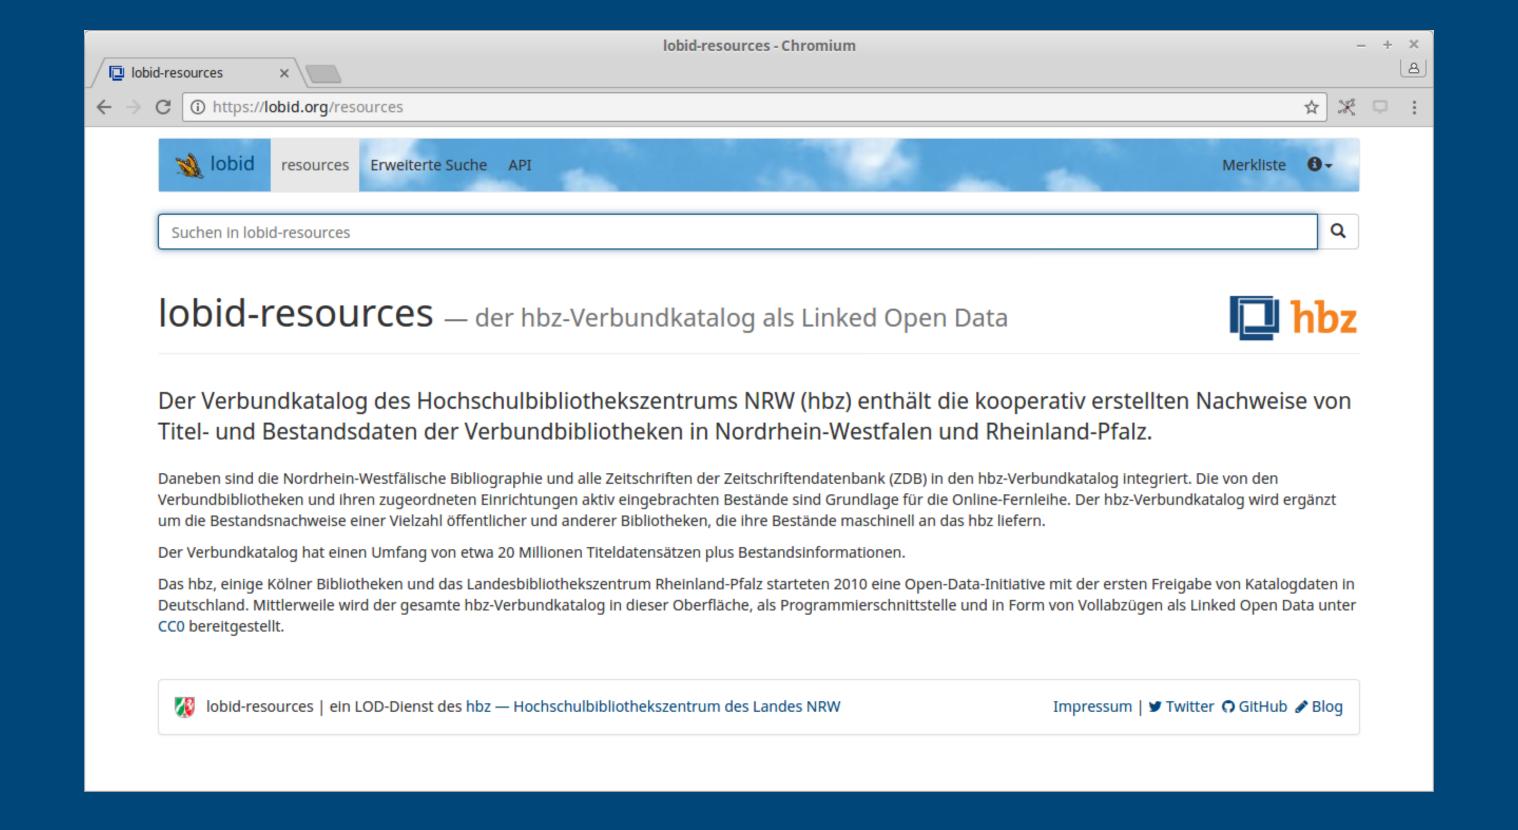
Pause

Beispiel: lobidresources

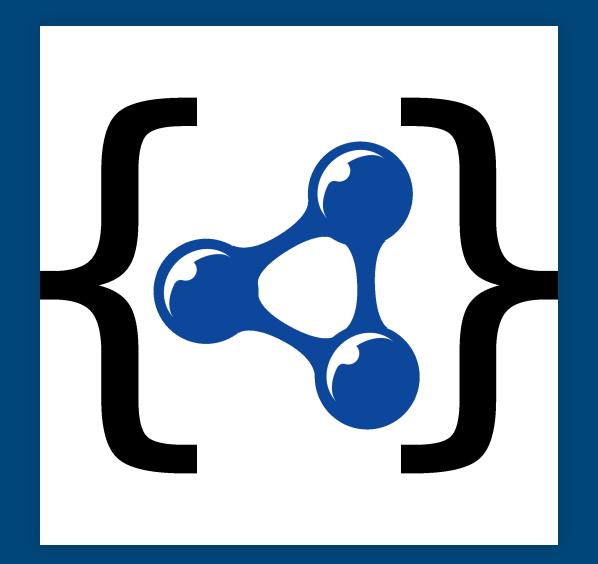
API-Kapselung: Ein großer Vorteil bei Systemmigrationen

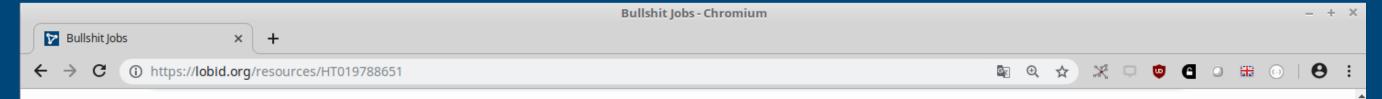


a. Die Oberfläche



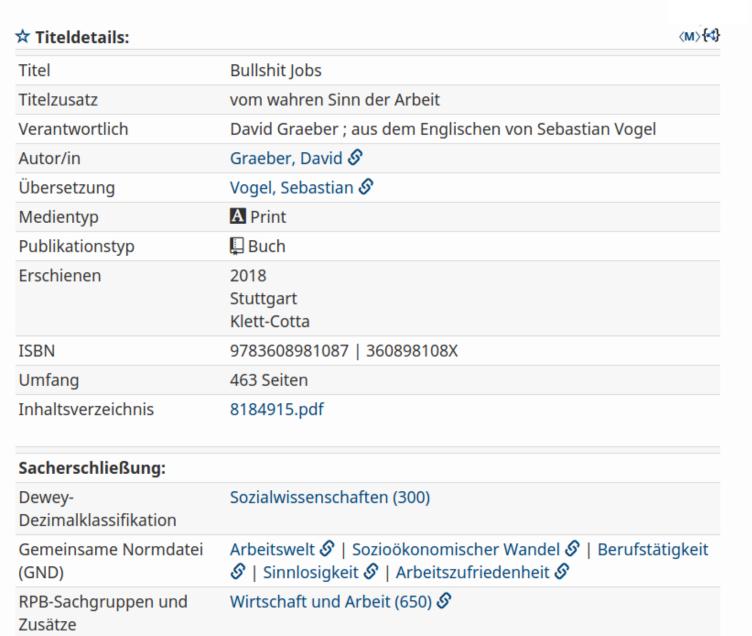
b. Die Daten



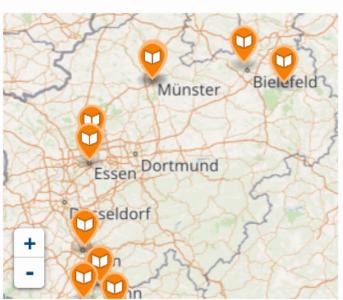


Bullshit Jobs

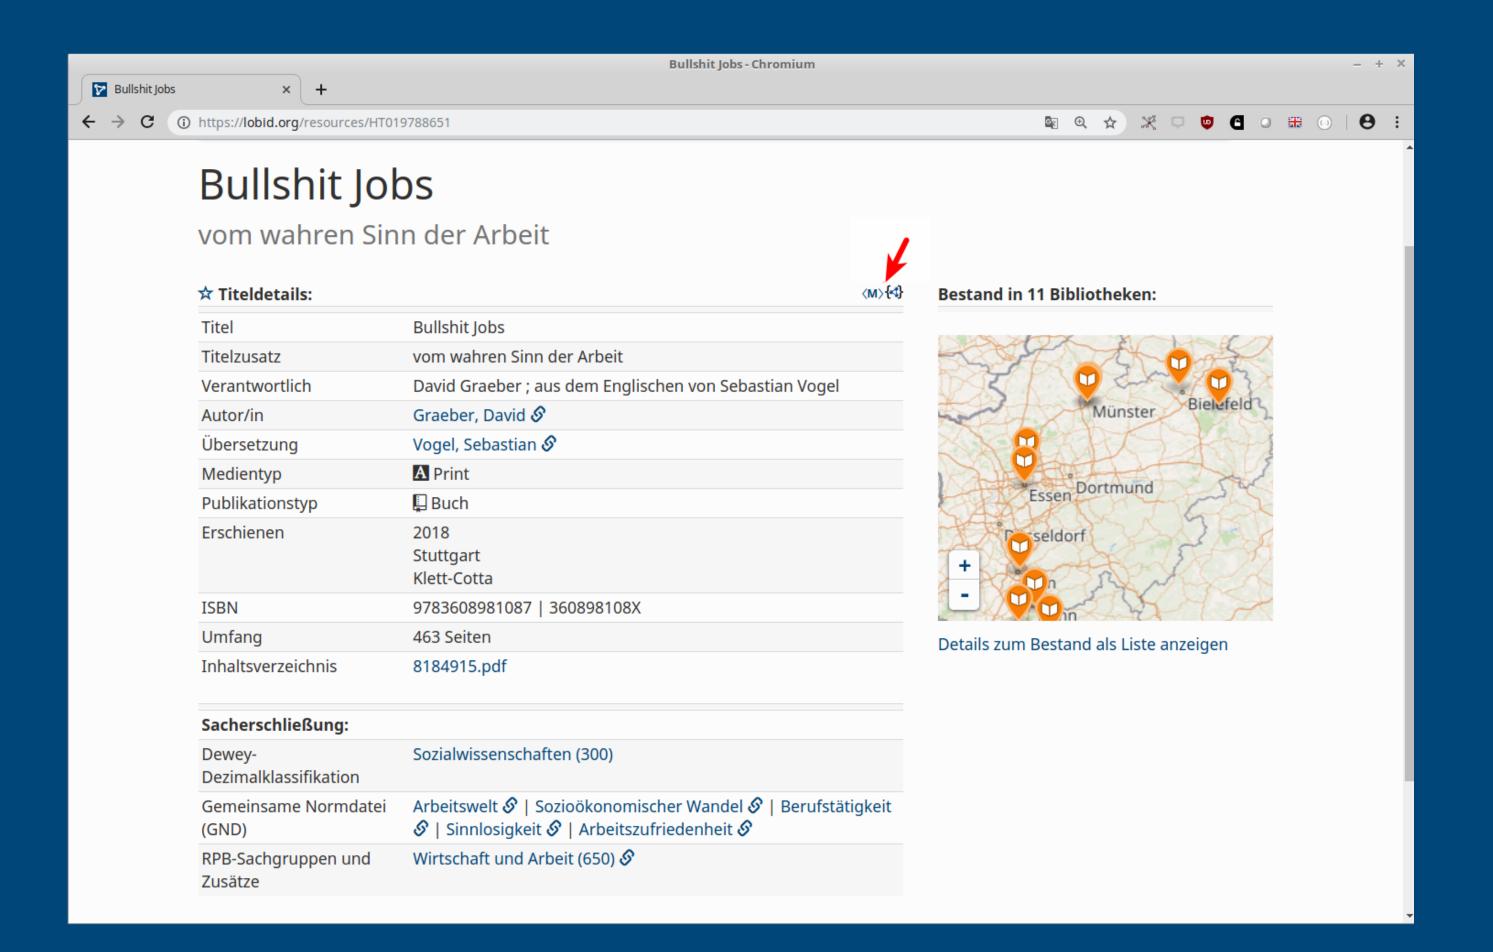
vom wahren Sinn der Arbeit



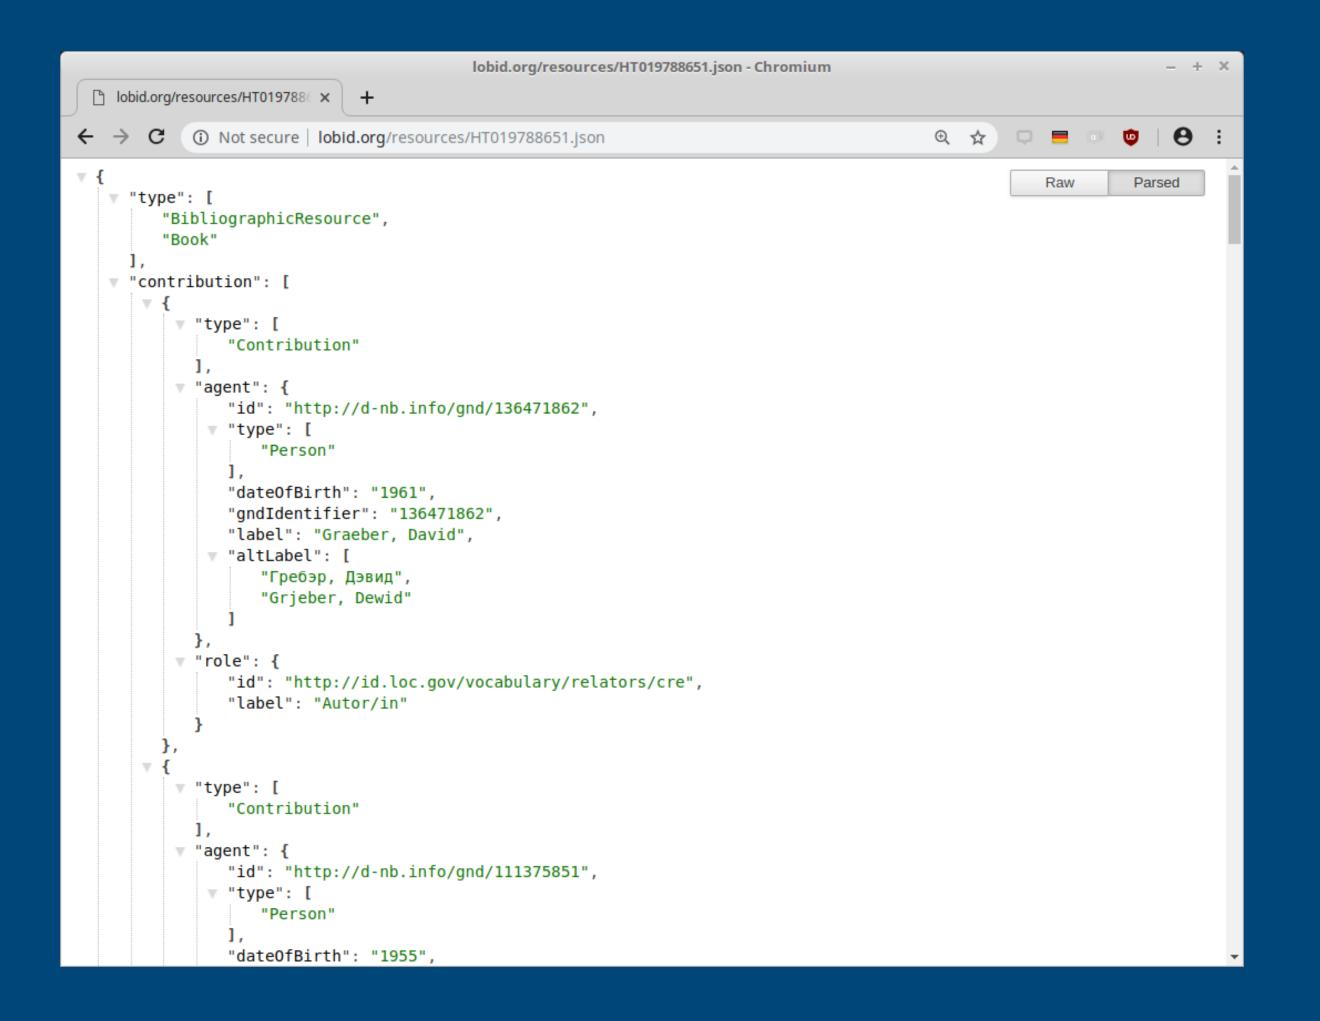
Bestand in 11 Bibliotheken:



Details zum Bestand als Liste anzeigen



Д



```
acka47@metameta~
                                                                                                                                    - + \times
Datei Bearbeiten Ansicht Suchen Terminal Hilfe
acka47@metameta ~ $ curl -H "Accept: application/json" http://lobid.org/resources/HT019788651
 "type" : [ "BibliographicResource", "Book" ],
 "contribution" : [ {
   "type" : [ "Contribution" ],
   "agent" : {
     "id" : "http://d-nb.info/gnd/136471862",
     "type" : [ "Person" ],
     "dateOfBirth" : "1961",
     "gndIdentifier" : "136471862",
     "label" : "Graeber, David",
     "altLabel" : [ "Гребэр, Дэвид", "Grjeber, Dewid" ]
   "role" : {
     "id" : "http://id.loc.gov/vocabulary/relators/cre",
     "label" : "Autor/in"
 }, {
   "type" : [ "Contribution" ],
   "agent" : {
     "id" : "http://d-nb.info/gnd/111375851",
     "type" : [ "Person" ],
     "dateOfBirth" : "1955",
     "gndIdentifier" : "111375851",
     "label" : "Vogel, Sebastian"
   "role" : {
     "id" : "http://id.loc.gov/vocabulary/relators/trl",
     "label" : "Übersetzung"
 } ],
 "extent" : "463 Seiten",
 "hasItem" : [ {
   "id" : "http://lobid.org/items/HT019788651:DE-6:001%202620#!",
   "type" : [ "Item" ],
   "heldBy" : {
     "id": "http://lobid.org/organisations/DE-6#!",
     "label" : "lobid Organisation"
   "note" : "00000045",
   "callNumber" : "001 2620",
   "label" : "001 2620"
   "id" : "http://lobid.org/items/HT019788651:DE-1032:Soz%20J%20291#!",
   "type" : [ "Item" ],
```

Tägl. Bezug der Daten über den Aleph- bzw. Alma Publishing Mechanismus

Tägl. Bezug der Daten über den Aleph- bzw. Alma Publishing Mechanismus

Konversion nach JSON-LD mit Metafacture (Morph/Aleph, Fix/Alma)

Tägl. Bezug der Daten über den Aleph- bzw. Alma Publishing Mechanismus

Konversion nach JSON-LD mit Metafacture (Morph/Aleph, Fix/Alma)

Dabei verschiedene Normalisierungsarbeiten

Tägl. Bezug der Daten über den Aleph- bzw. Alma Publishing Mechanismus

Konversion nach JSON-LD mit Metafacture (Morph/Aleph, Fix/Alma)

Dabei verschiedene Normalisierungsarbeiten

Labels für verlinkte Ressourcen ergänzen

Tägl. Bezug der Daten über den Aleph- bzw. Alma Publishing Mechanismus

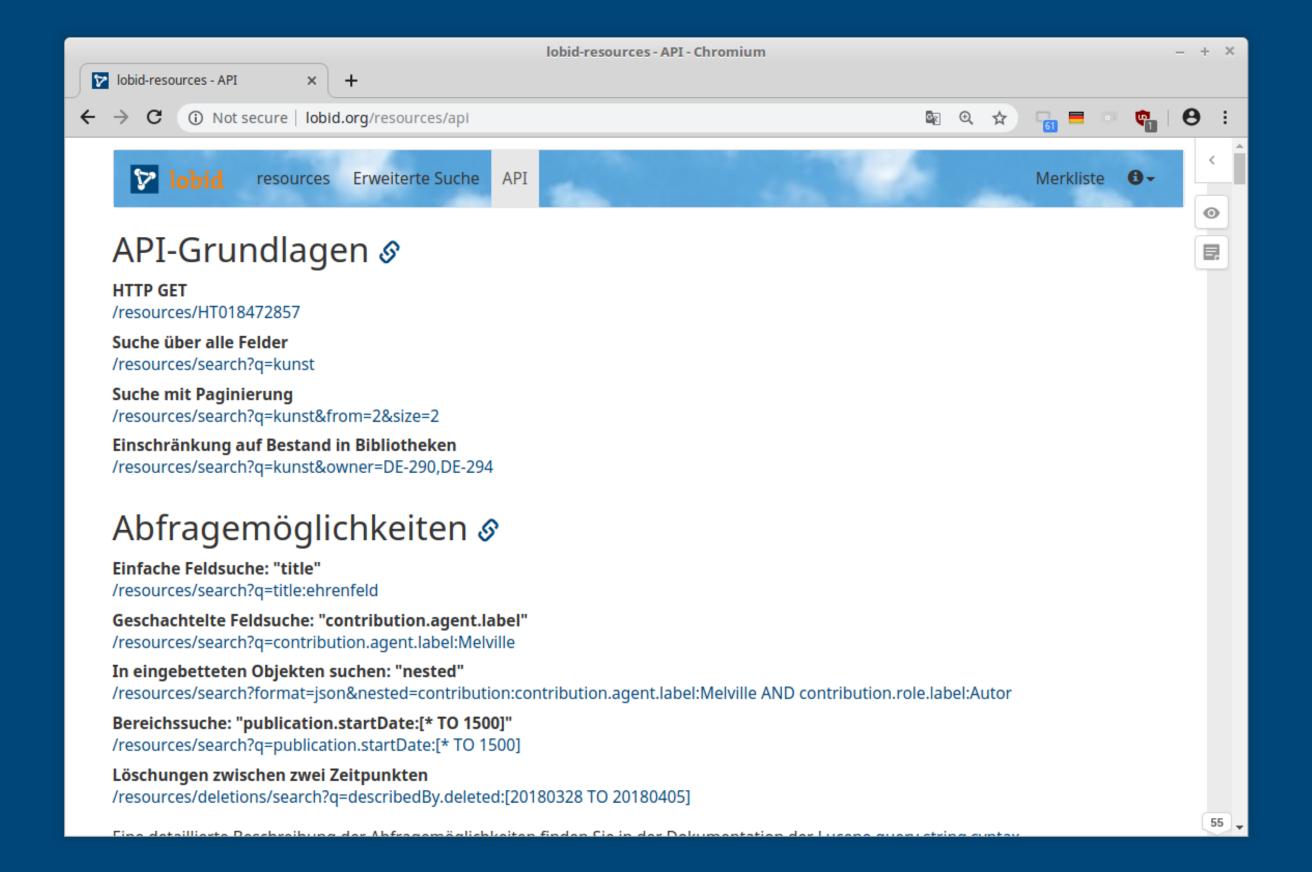
Konversion nach JSON-LD mit Metafacture (Morph/Aleph, Fix/Alma)

Dabei verschiedene Normalisierungsarbeiten

Labels für verlinkte Ressourcen ergänzen

Et voilà: Linked Open Usable Data (LOUD)

c. Web-API



JSON-LD-Daten in Elasticsearch-Index

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

API für Auto Suggest

Abfragemöglichkeiten

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

API für Auto Suggest

API für Bulk Downloads

Abfragemöglichkeiten

JSON-LD-Daten in Elasticsearch-Index

Elasticsearch- / Lucene-Suchsyntax

API für Auto Suggest

API für Bulk Downloads

Im Aufbau: Reconciliation Service API für Deduplizierungszwecke

Beispielabfragen

Ermitteln eines hbz-Titels anhand der OCLC-Nummer

oclcNumber:601339369

RDA-Titel seit 2010

```
title:rda AND
publication.startDate:[2010 TO *]
```

Online-Medien mit Bestand

```
medium.id:
"http://rdaregistry.info/termList/ RDACarrierType/1018"
AND exists :hasItem
```

ZDB-Titel, die mit einer NWBib-Systematik erschlossen sind, aber nicht der NWBib zugerechnet werden und von der ULB Bonn erstellt wurden

```
subject.source.id:
    ("https://nwbib.de/subjects" OR
        "https://nwbib.de/spatial")
AND inCollection.id:
        "http://lobid.org/resources/HT014846970#!"
AND NOT inCollection.id:
        "http://lobid.org/resources/HT014176012#!"
AND describedBy.sourceOrganization.id:
        "http://lobid.org/organisations/DE-5#!"
```

Teil 3: OpenRefine Reconciliation

Grundlagen	Grundlagen von OpenRefine und Reconciliation	14:00–14:30
Matching	Verbesserung des Matching auf GND-Einträge	14:30–15:00
Extension	Datenanreicherung auf Basis der Matches	15:00–15:30

"A powerful tool for working with messy data"

"A powerful tool for working with messy data"

"cleaning it; transforming it from one format into another; and extending it with web services and external data"

"A powerful tool for working with messy data"

"cleaning it; transforming it from one format into another; and extending it with web services and external data"

Oberfläche wie Tabellenkalkulation

"A powerful tool for working with messy data"

"cleaning it; transforming it from one format into another; and extending it with web services and external data"

Oberfläche wie Tabellenkalkulation

Läuft im Browser

Lokal, downloaden und installieren:

https://openrefine.org/download.html

Lokal, downloaden und installieren: https://openrefine.org/download.html

Gehostet, z.B. zum Ausprobieren: http://openrefine.labs.lobid.org

Wofür ist OpenRefine?

Wofür ist OpenRefine?

Gut geeigent wo UI/Tabellenkalkulation passt

Wofür ist OpenRefine?

Gut geeigent wo UI/Tabellenkalkulation passt

Fachliche Arbeit

Wofür ist OpenRefine?

Gut geeigent wo UI/Tabellenkalkulation passt

Fachliche Arbeit

Manuelle Optimierung

Wofür ist OpenRefine?

Gut geeigent wo UI/Tabellenkalkulation passt

Fachliche Arbeit

Manuelle Optimierung

Überschaubare Datenmengen

Wofür ist OpenRefine (noch) nicht?

Wofür ist OpenRefine (noch) nicht?

Bisher nicht geeignet für große Dateien, aber eine neue Architektur für größere Datenmengen ist fast fertig

Wofür ist OpenRefine (noch) nicht?

Bisher nicht geeignet für große Dateien, aber eine neue Architektur für größere Datenmengen ist fast fertig

Automatisierung ohne UI nicht mit Bordmitteln, aber mit Zusatztool möglich: openrefine-batch

Abgleichen / Matchen eigener Daten (z.B. Namen von Personen) auf GND-Einträge

Abgleichen / Matchen eigener Daten (z.B. Namen von Personen) auf GND-Einträge

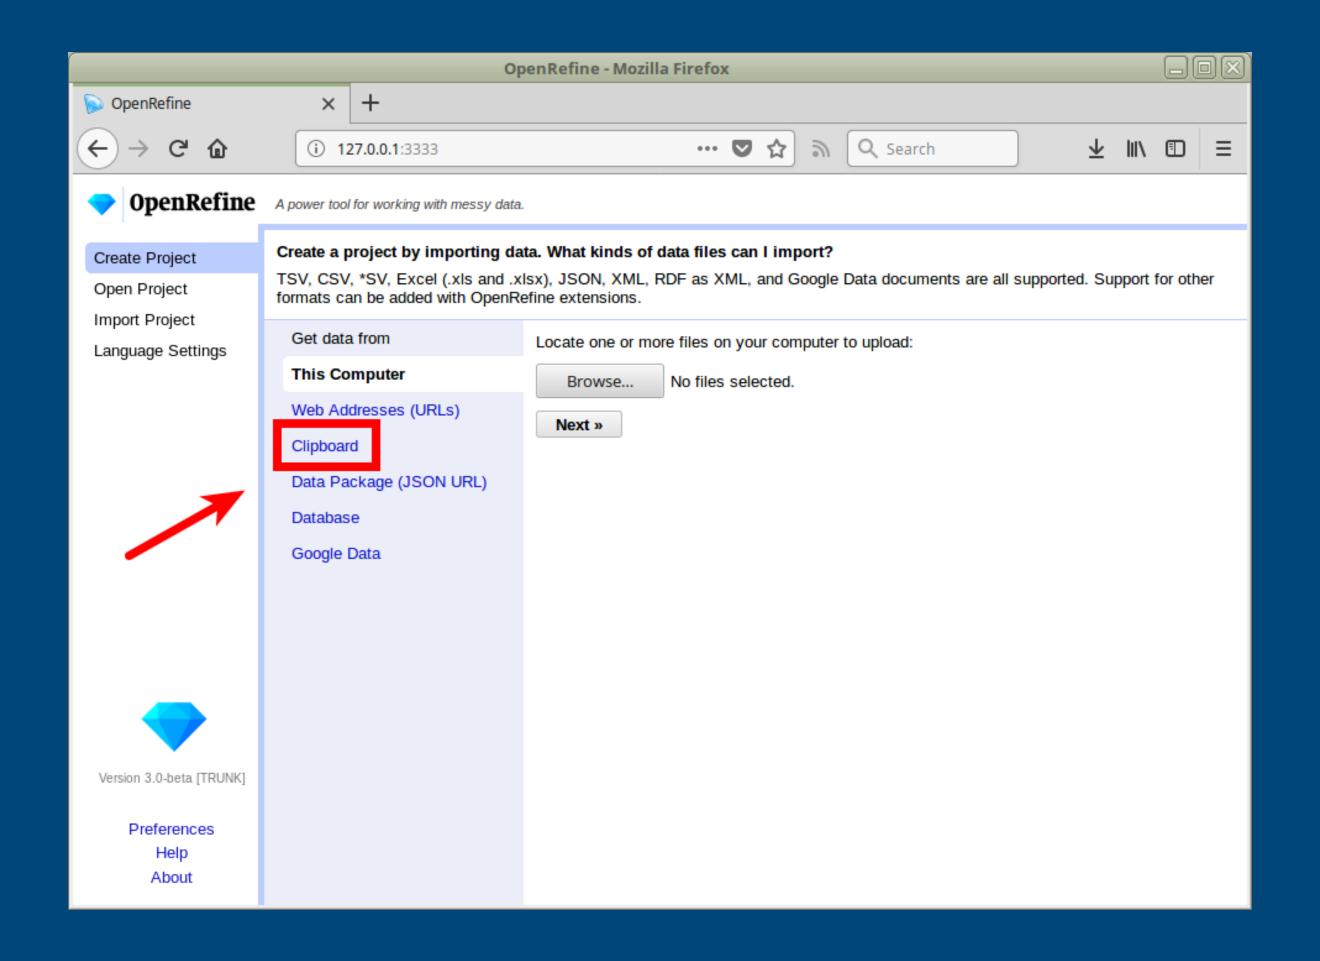
Anreicherung durch Übernahme von spezifischen Feldern der gematchten GND-Einträge

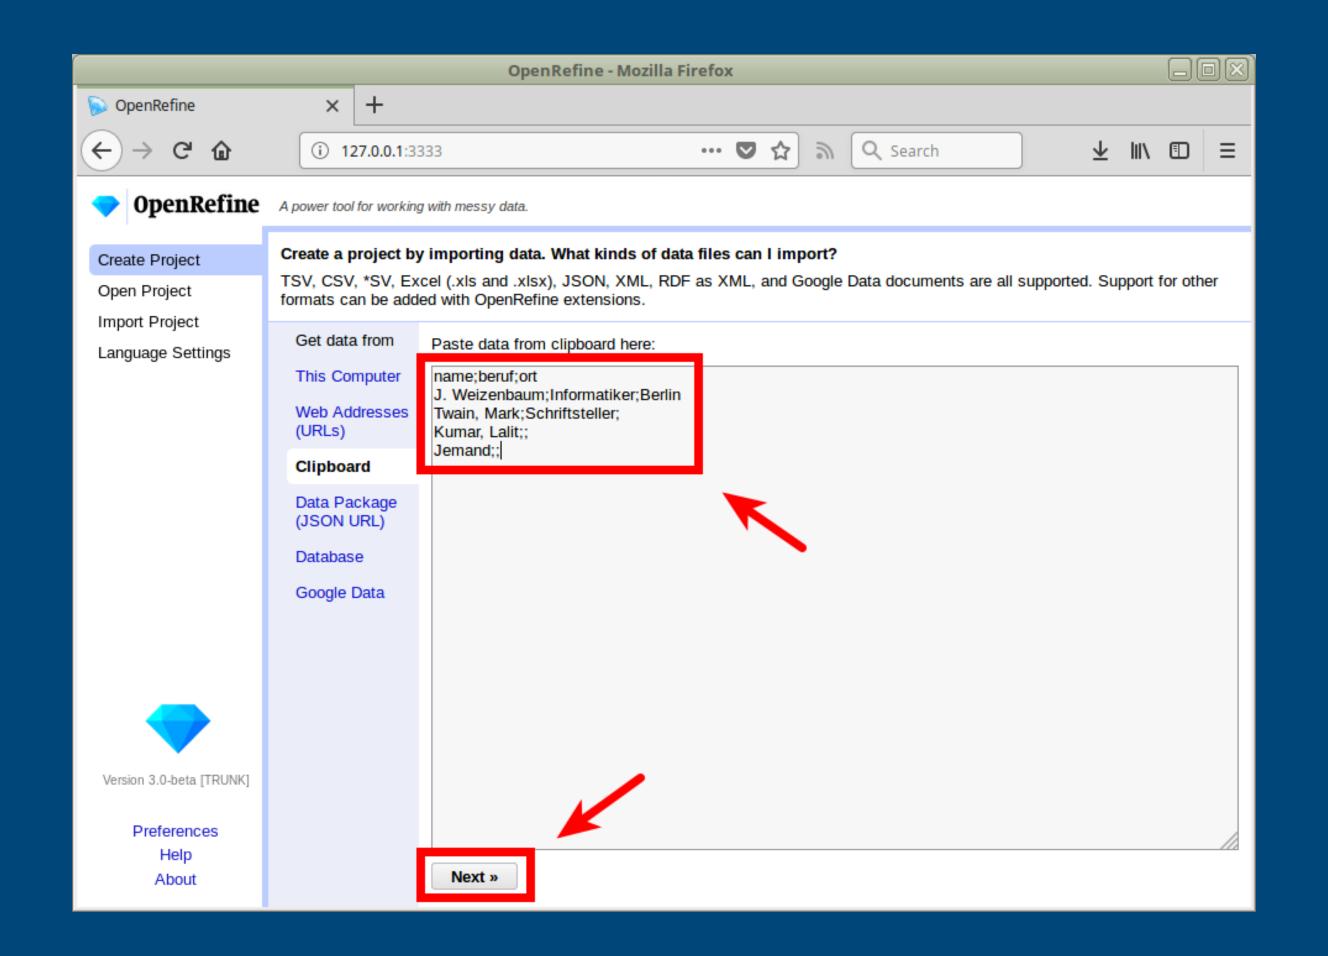
Abgleichen / Matchen eigener Daten (z.B. Namen von Personen) auf GND-Einträge

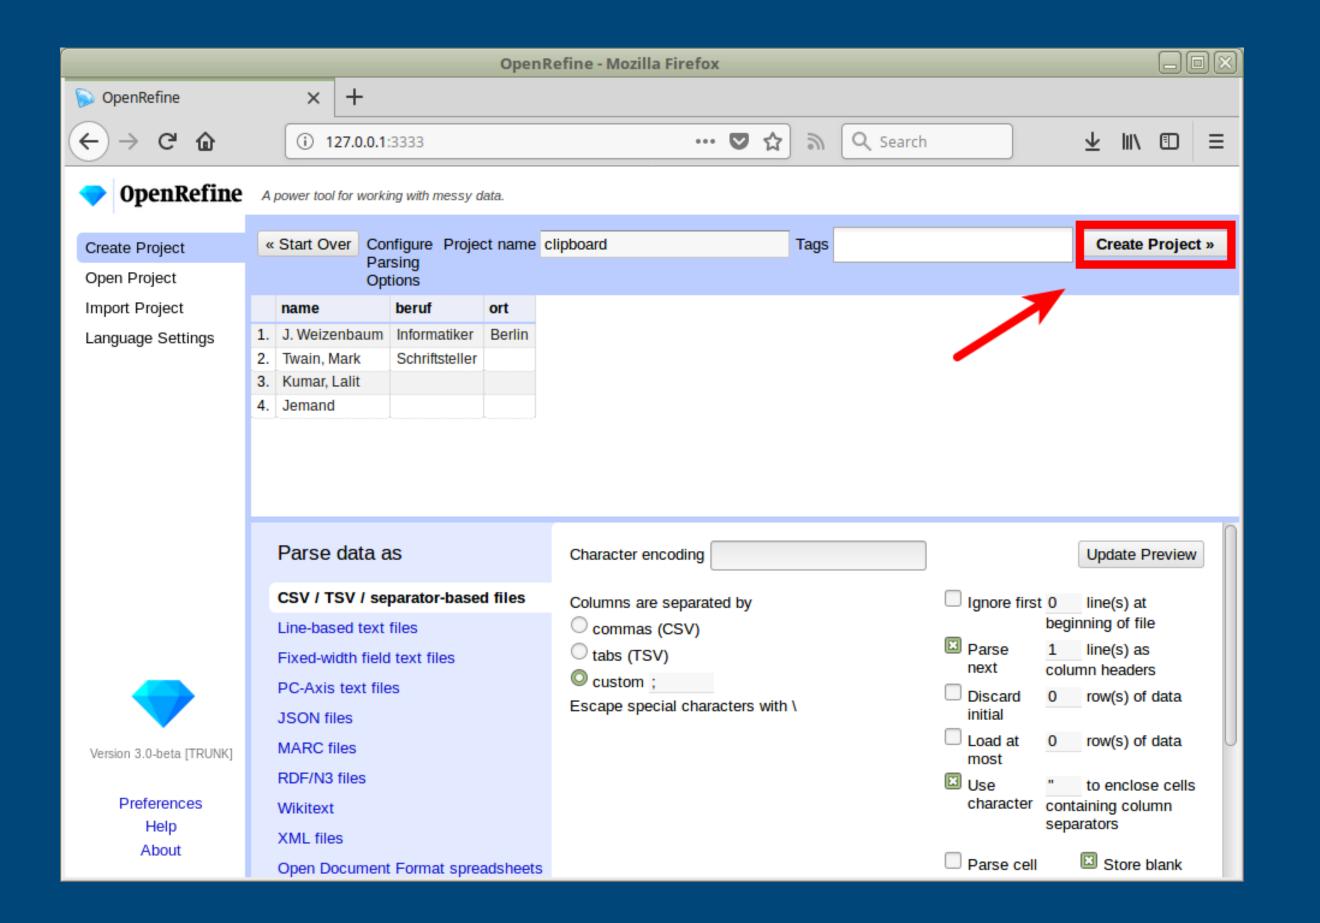
Anreicherung durch Übernahme von spezifischen Feldern der gematchten GND-Einträge

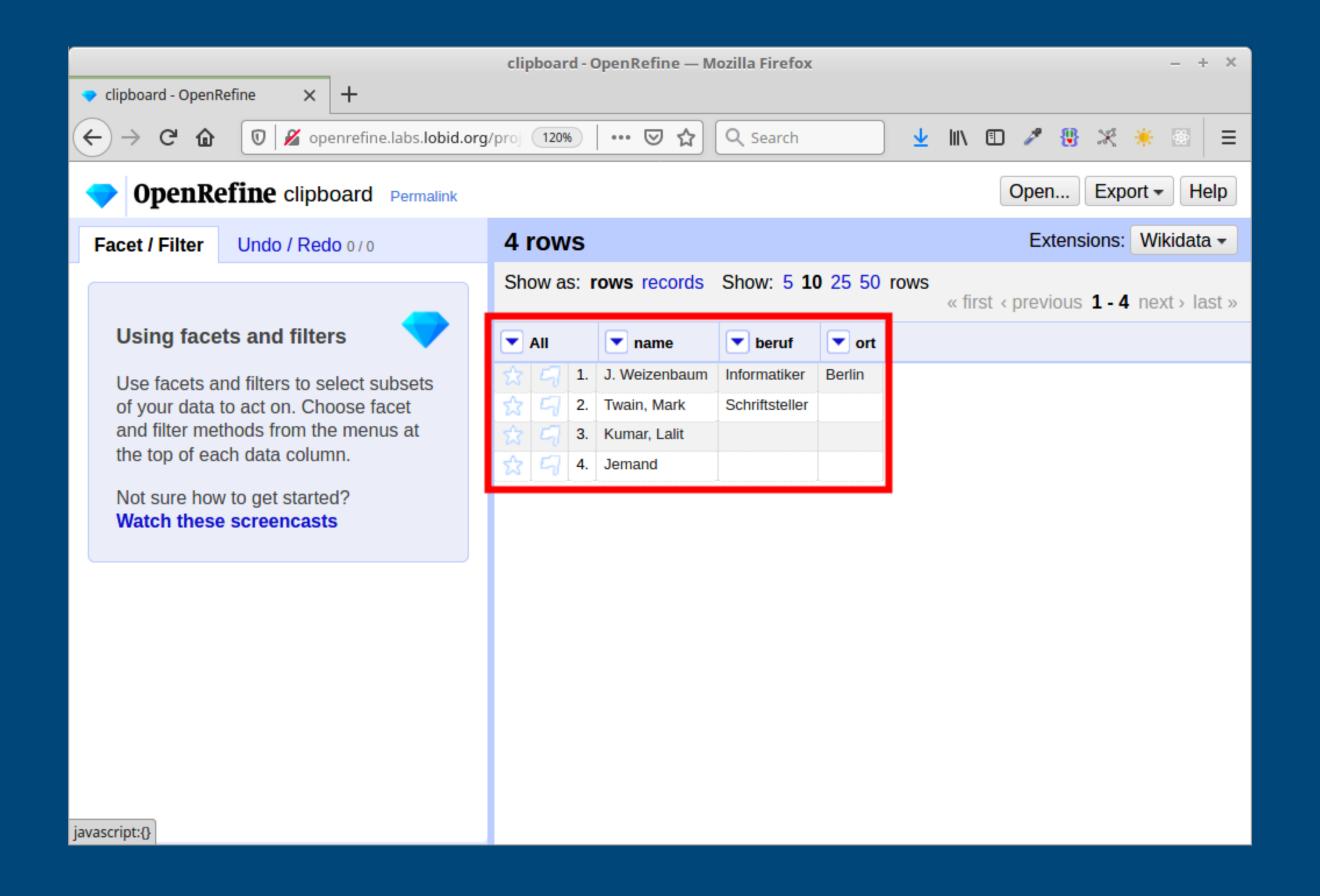
Fokus hier ist Reconciliation, auch Grundlagen von OpenRefine, aber es gibt noch viel mehr

Projekt anlegen









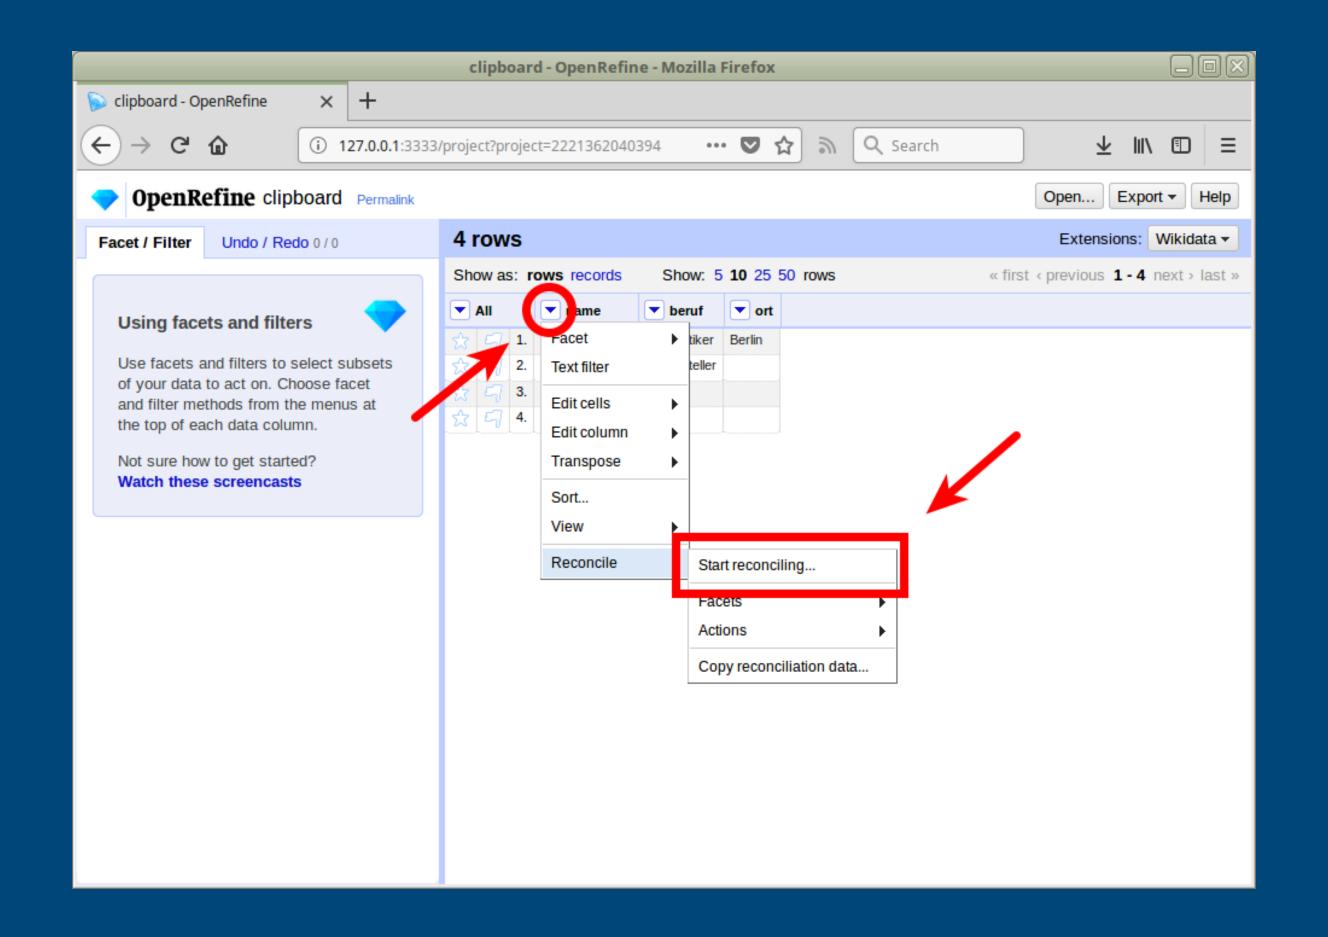
Projekt anlegen

openrefine.labs.lobid.org | localhost:3333

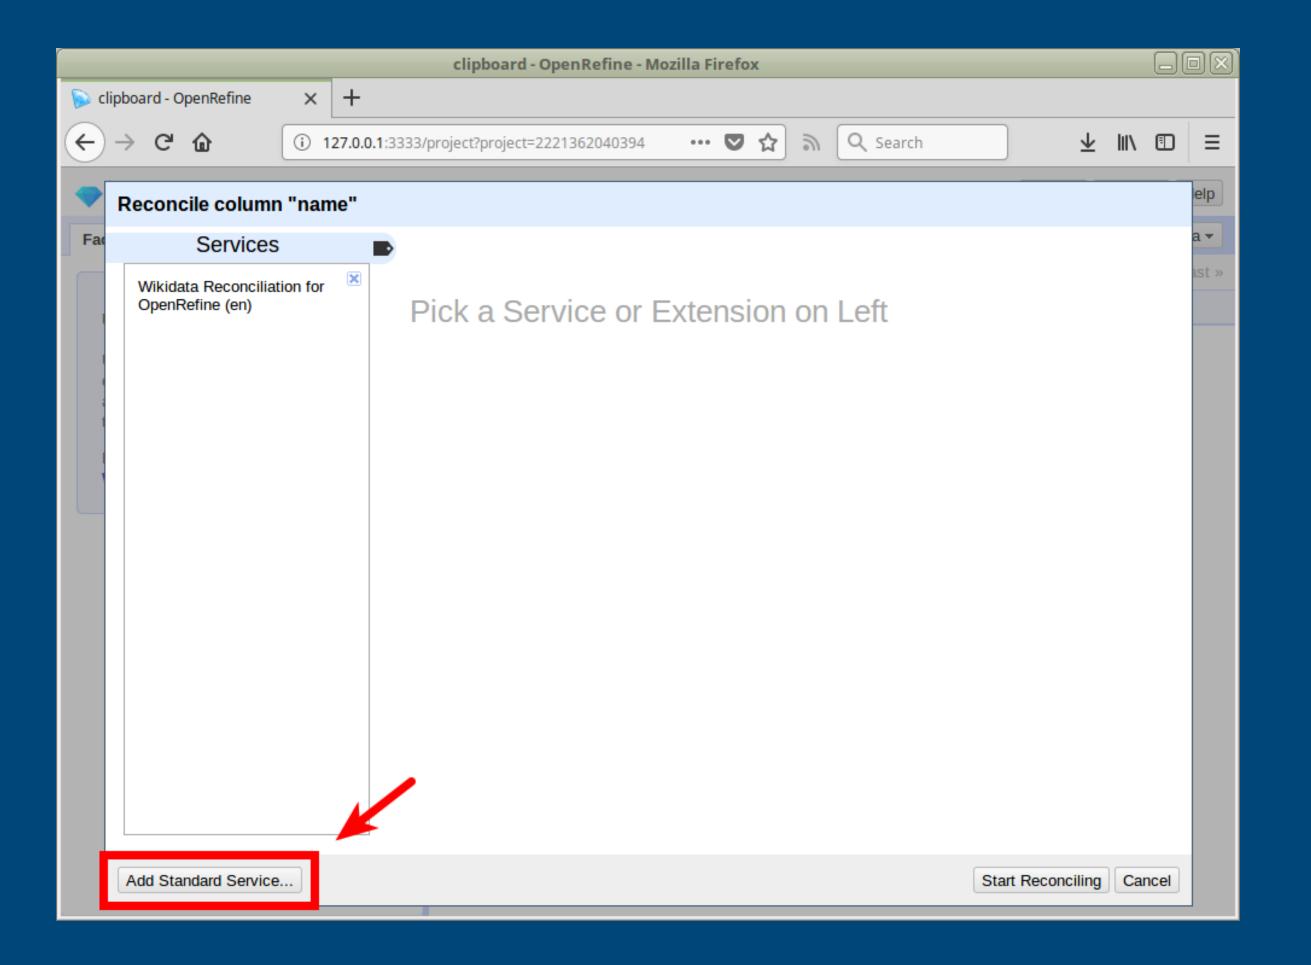
```
name;beruf;ort
J. Weizenbaum;Informatiker;Berlin
Twain, Mark;Schriftsteller;
Kumar, Lalit;;
Jemand;;
```

(Daten und URL per CTRL+C in die Zwischenablage kopieren)

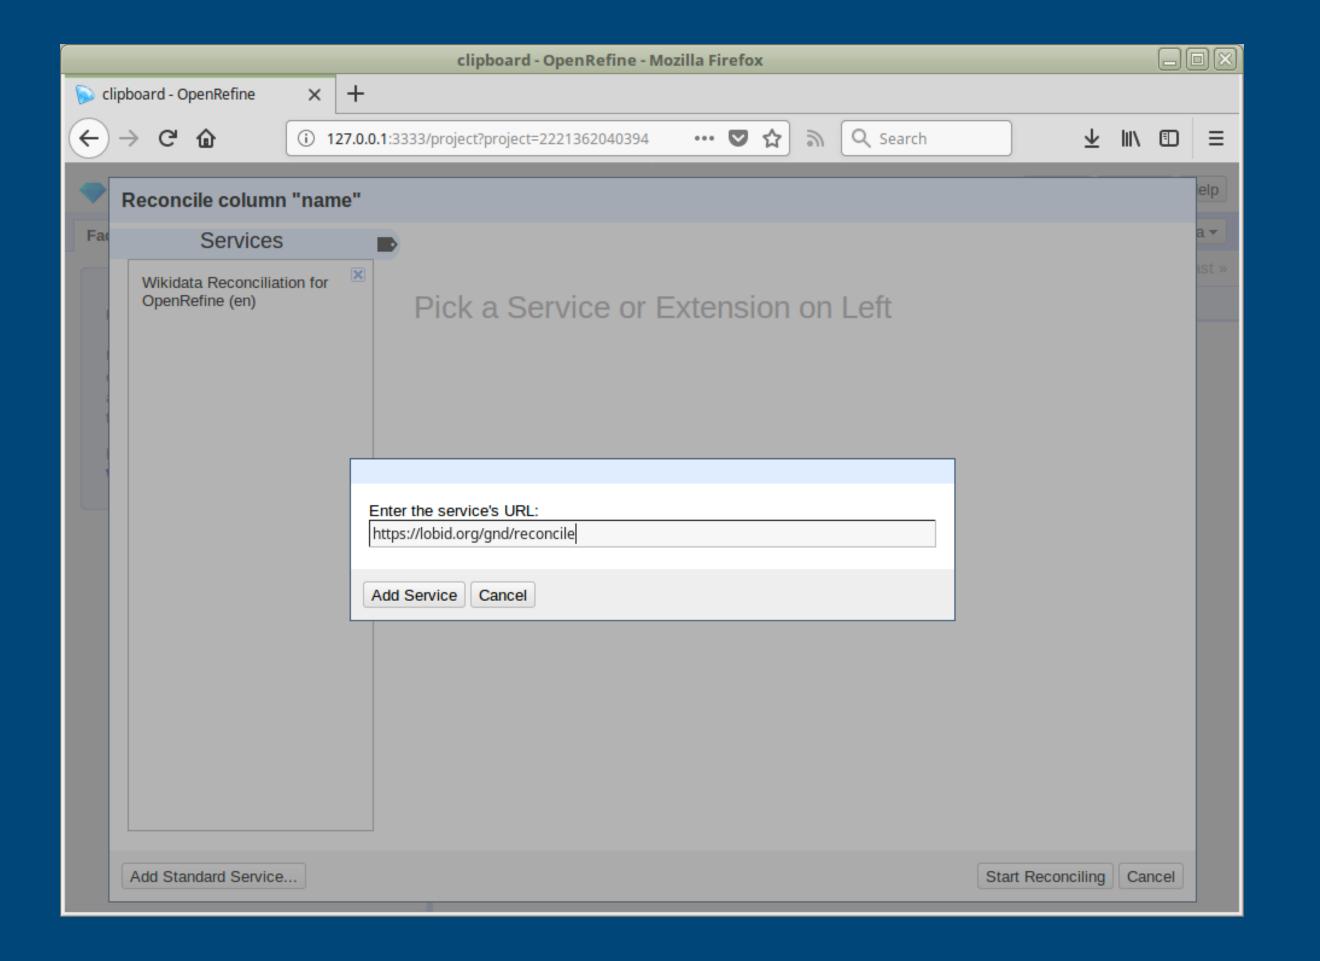
Abgleich/ Reconciliation

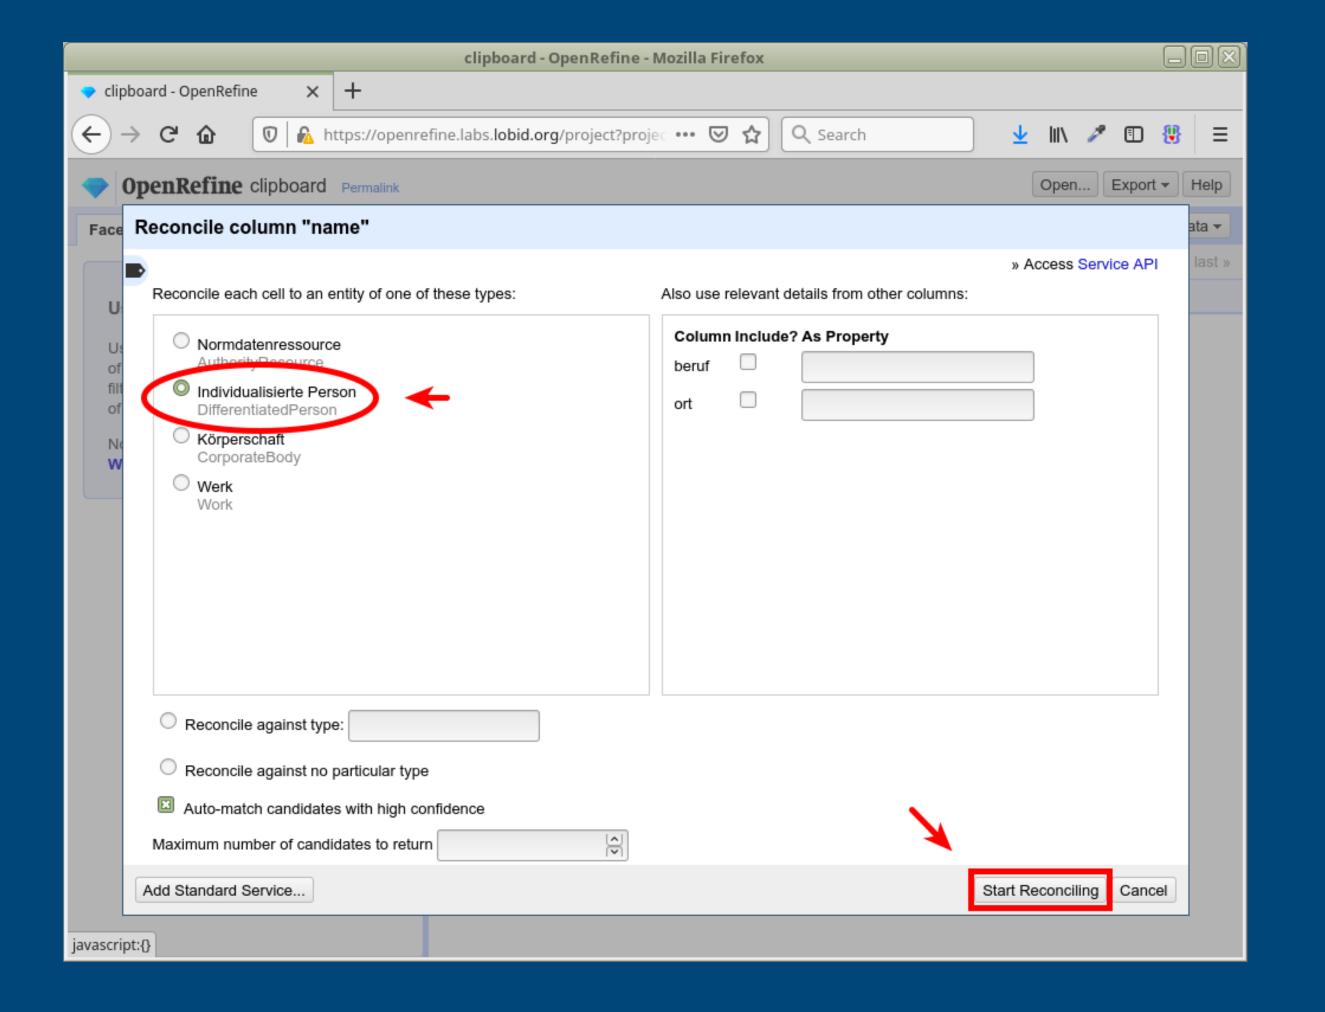


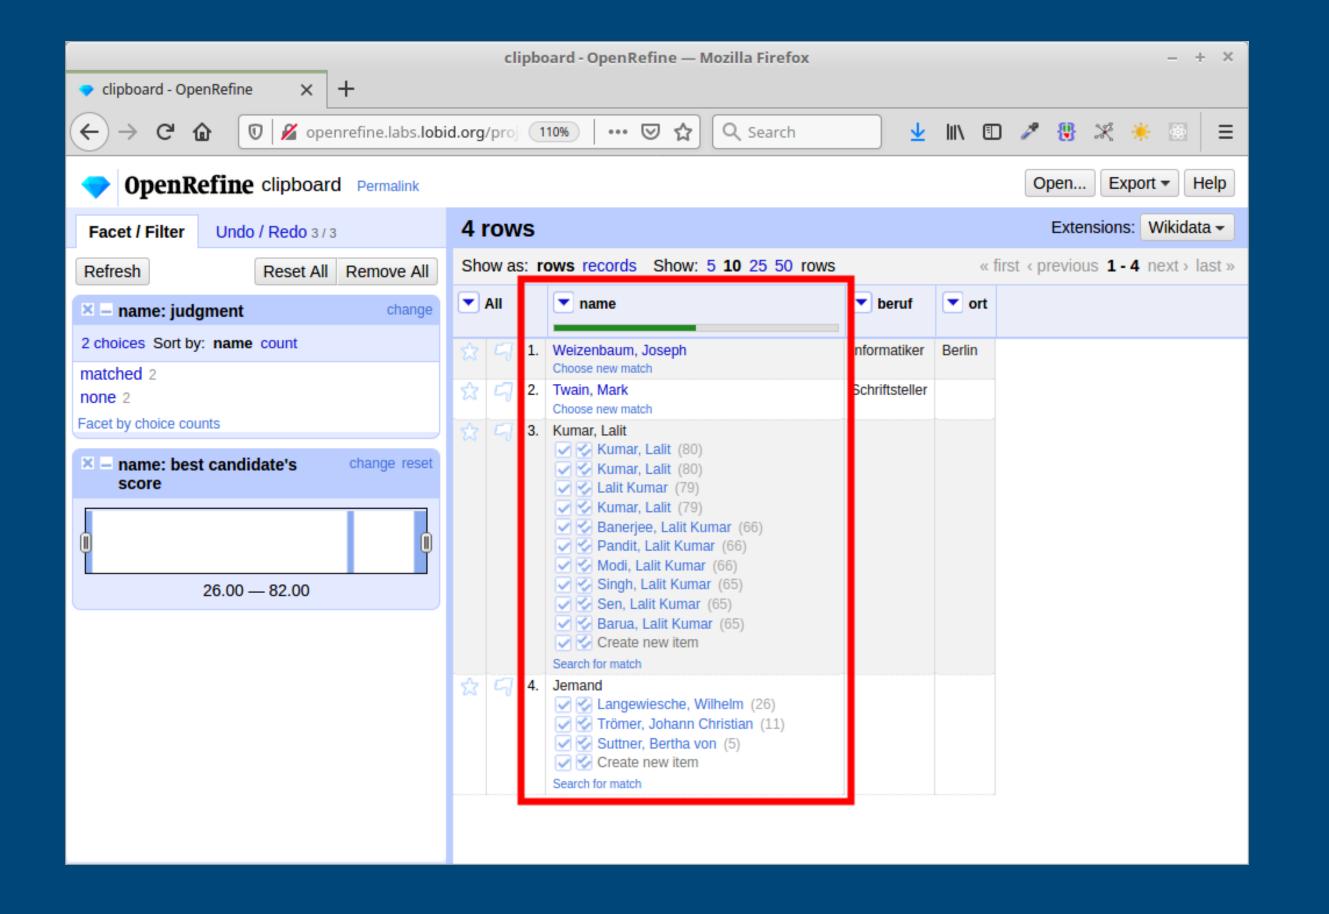
The state of the s



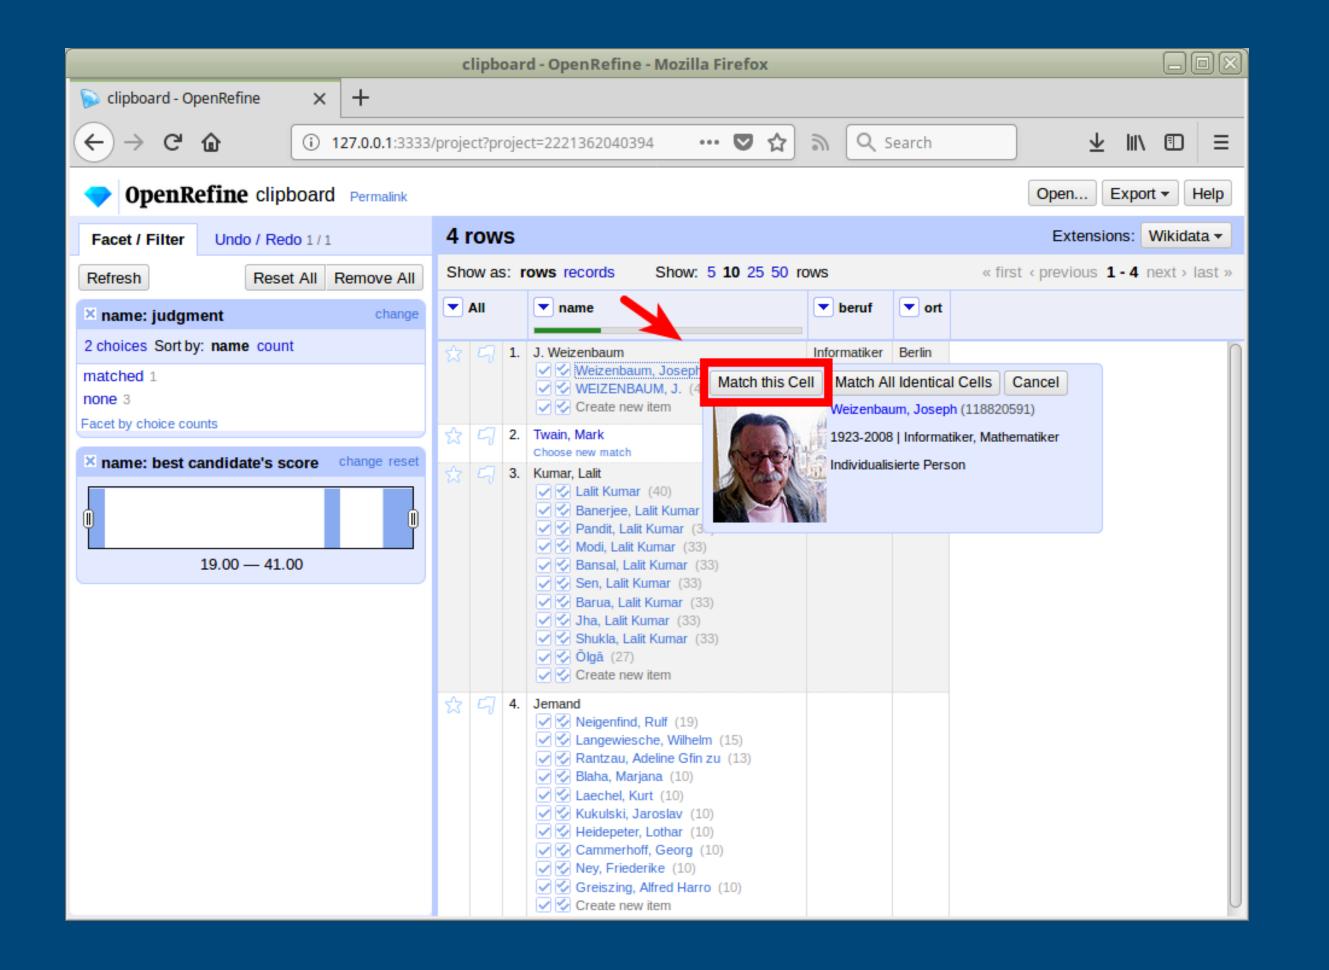
-







For the control of th



F 146

Abgleich / Reconciliation

openrefine.labs.lobid.org | localhost:3333

https://lobid.org/gnd/reconcile

(Auf openrefine.labs.lobid.org muss der Dienst nicht ergänzt werden)

Namen wurden mit GND-IDs assoziiert

Namen wurden mit GND-IDs assoziiert

Felder der GND-Entitäten stehen so zur Verfügung

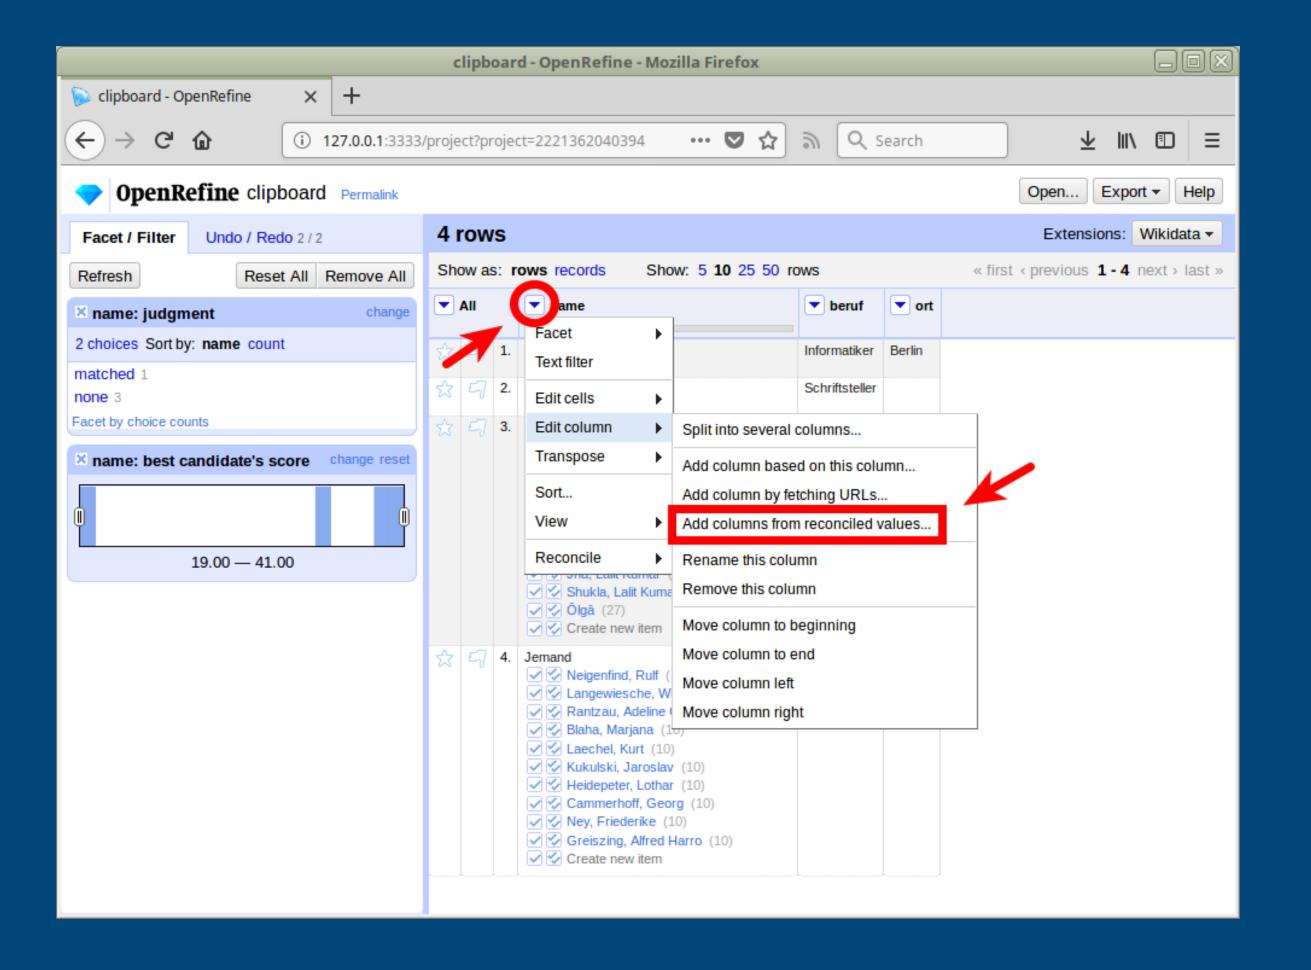
Namen wurden mit GND-IDs assoziiert

Felder der GND-Entitäten stehen so zur Verfügung

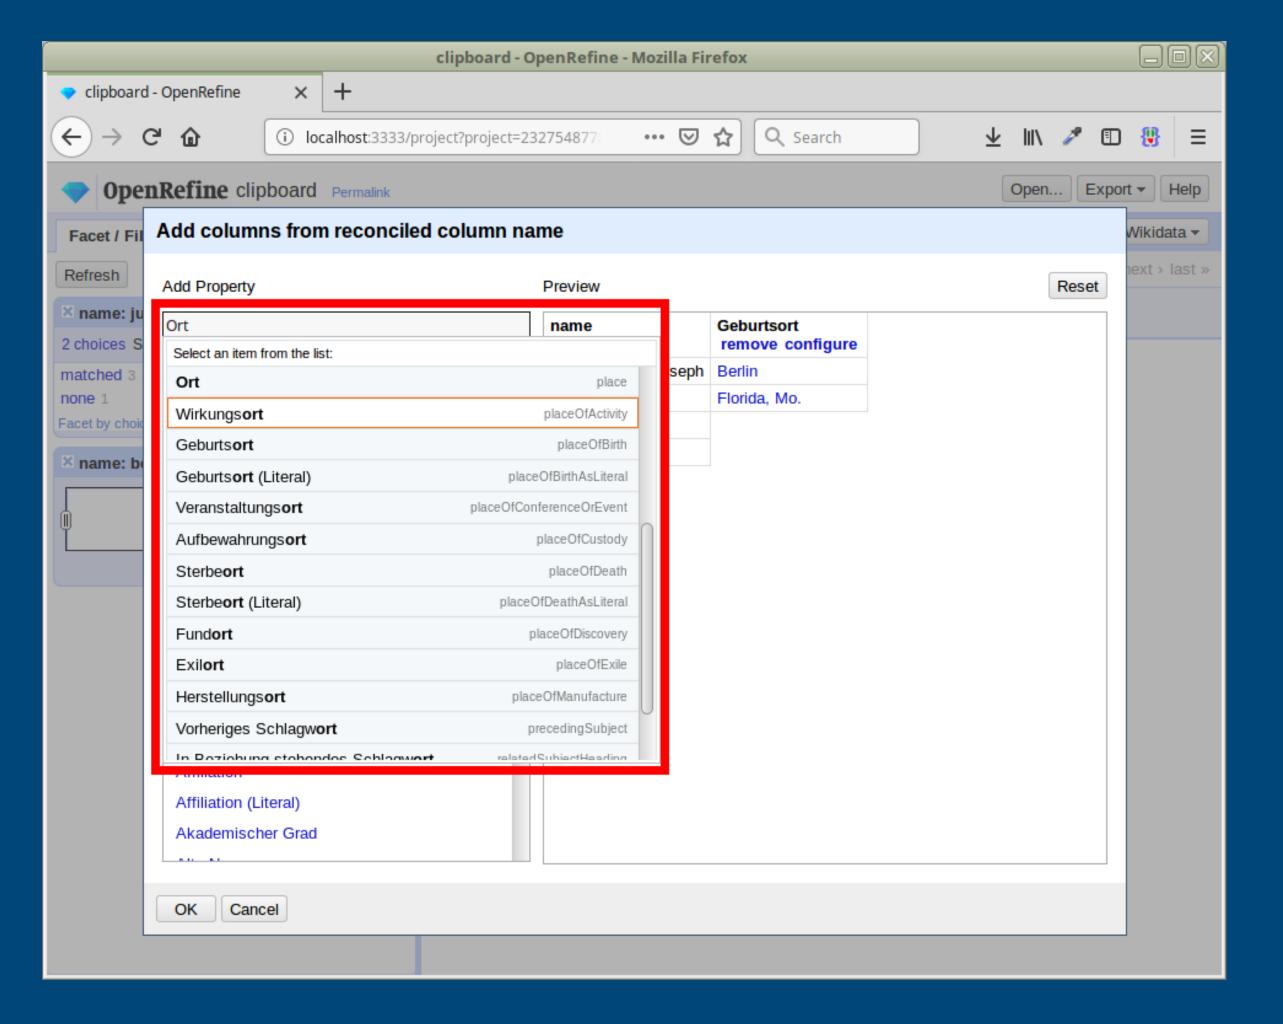
Mit diesen können wir unsere lokalen Daten anreichern

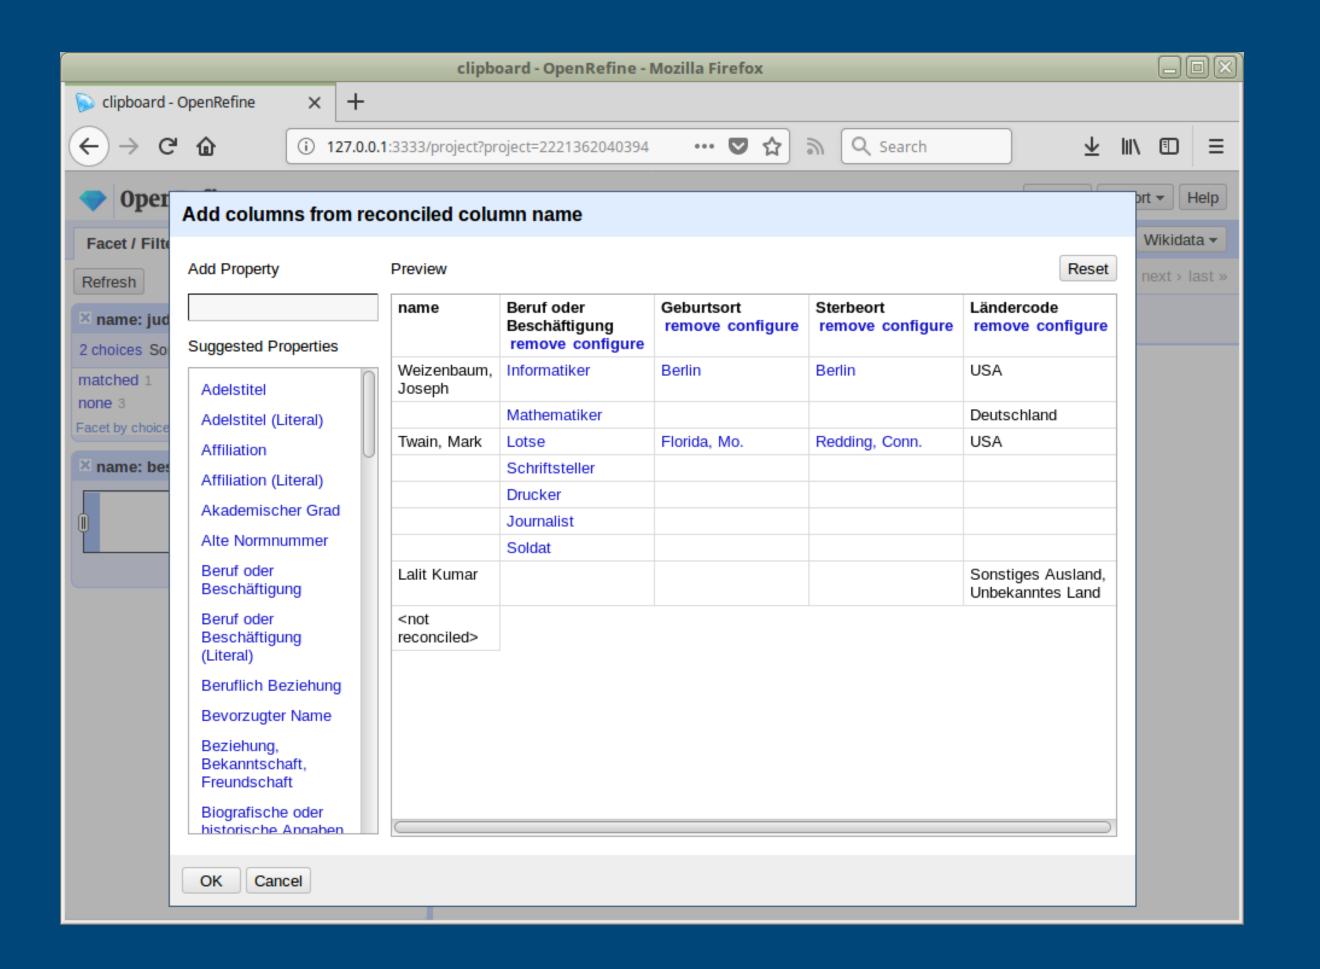
F

Namen wurden mit GND-IDs assoziiert
Felder der GND-Entitäten stehen so zur Verfügung
Mit diesen können wir unsere lokalen Daten anreichern
d.h. konkret: neue Spalten in unserer Tabelle anlegen

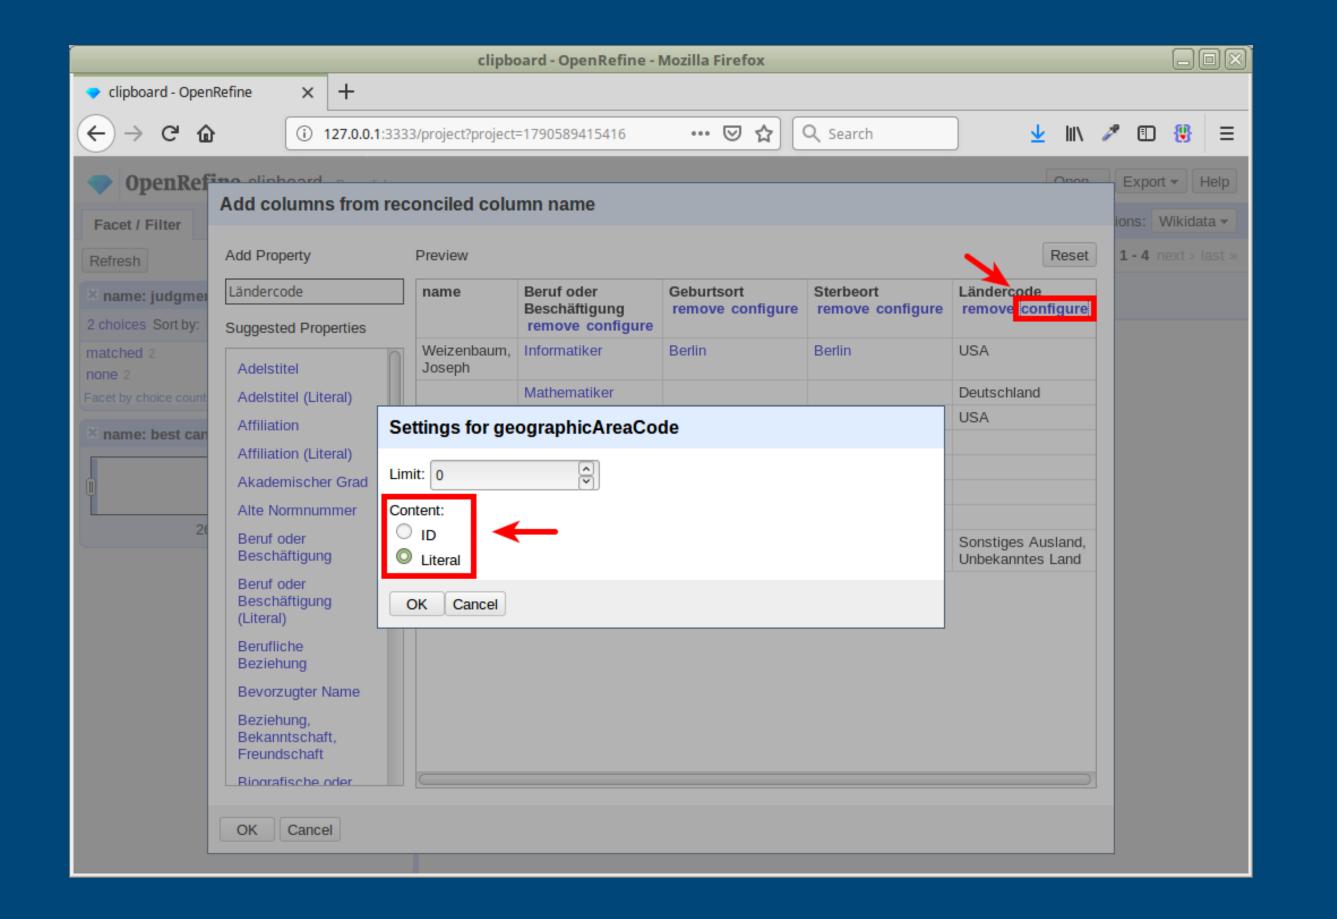


F 149





 F



- 18

Übung: Anreicherung

```
id, name
1, Haddaway
2, Johannes Geßner
3, Judith Kuckart
4, Rosa Luxemburg
5, Albert Einstein
6, Hazel Brugger
7, Anne Cuneo
8, Vitus Huonder
```

Projekt anlegen, Namen abgleichen und Berufe anreichern

Angereicherte Felder sind z.T. GND-Entitäten

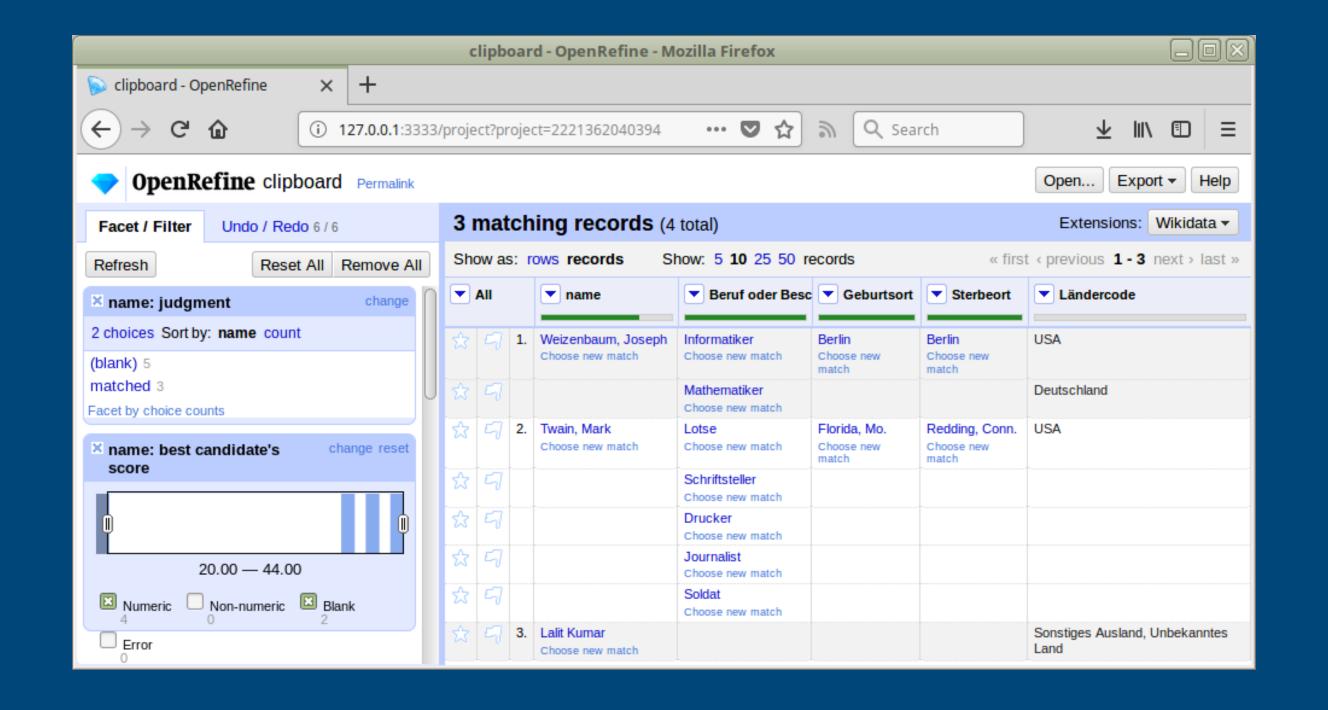
Angereicherte Felder sind z.T. GND-Entitäten

Sind automatisch abgeglichen / reconciled

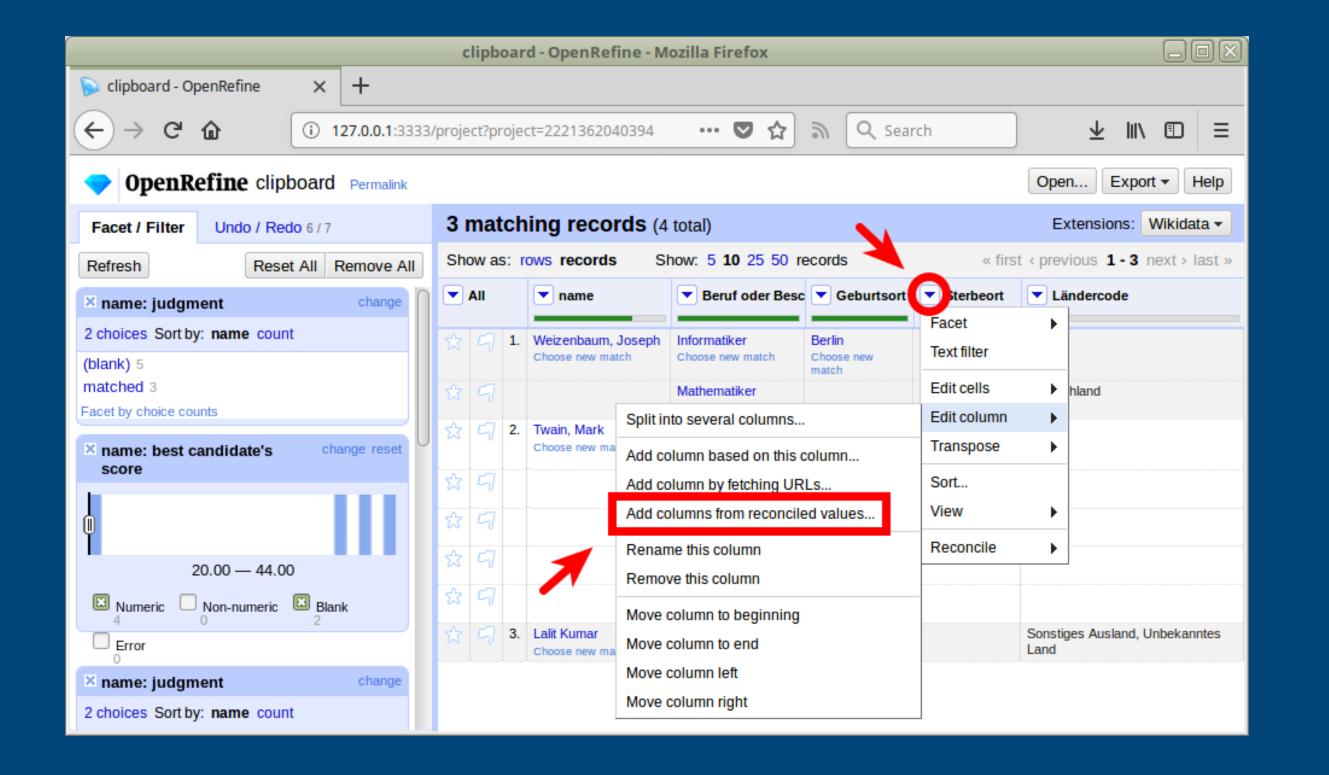
Angereicherte Felder sind z.T. GND-Entitäten

Sind automatisch abgeglichen / reconciled

Können als Grundlage für weitere Anreicherung dienen



F 155



 F

Übung: Anreicherung mit GND-Entitäten

Wirkungsort und Darstellung des Wirkungsortes anreichern

Export * Open... Help 8 records Extensions: Wikidata -Show as: rows records Show: 5 10 25 50 records « first < previous 1 - 8 next > last » ▼ AII ▼ Beruf oder Beschäl ▼ Wirkungsort ▼ Darstellung des Wirkungsortes ▼ id ▼ name 1. 1 Haddaway Komponist Köln http://commons.wikimedia.org/wiki/Special:FilePath /DEU%20Koeln%20COA.svg Choose new Choose new match Choose new match match Sänger Kitzbühel http://commons.wikimedia.org/wiki/Special:FilePath /AUT%20Kitzb%C3%BChel%20COA.svg Choose new match Choose new match Musiker Choose new match 2. 2 Geßner, Zürich http://commons.wikimedia.org/wiki/Special:FilePath Arzt /Zurich-coat%20of%20arms.svg Johannes Choose new match Choose new match Choose new match Mathematiker Choose new match Naturwissenschaftler Choose new match 3. 3 Kuckart, Judith Schriftstellerin Berlin https://commons.wikimedia.org/wiki/Special:FilePath /Cityscape_Berlin.jpg Choose new Choose new match Choose new match match Regisseurin http://commons.wikimedia.org/wiki/Special:FilePath Zürich /Zurich-coat%20of%20arms.svq Choose new match Choose new match Tänzerin Choose new match Choreografin Choose new match

 $\color{red} \textbf{158}$

Verbesserung des Matching auf GND-Einträge

Ergebnisse verbessern

Ergebnisse verbessern

Einschränkung der Typen der Zielentitäten

Ergebnisse verbessen

Einschränkung der Typen der Zielentitäten

Verwendung zusätzlicher lokaler Daten

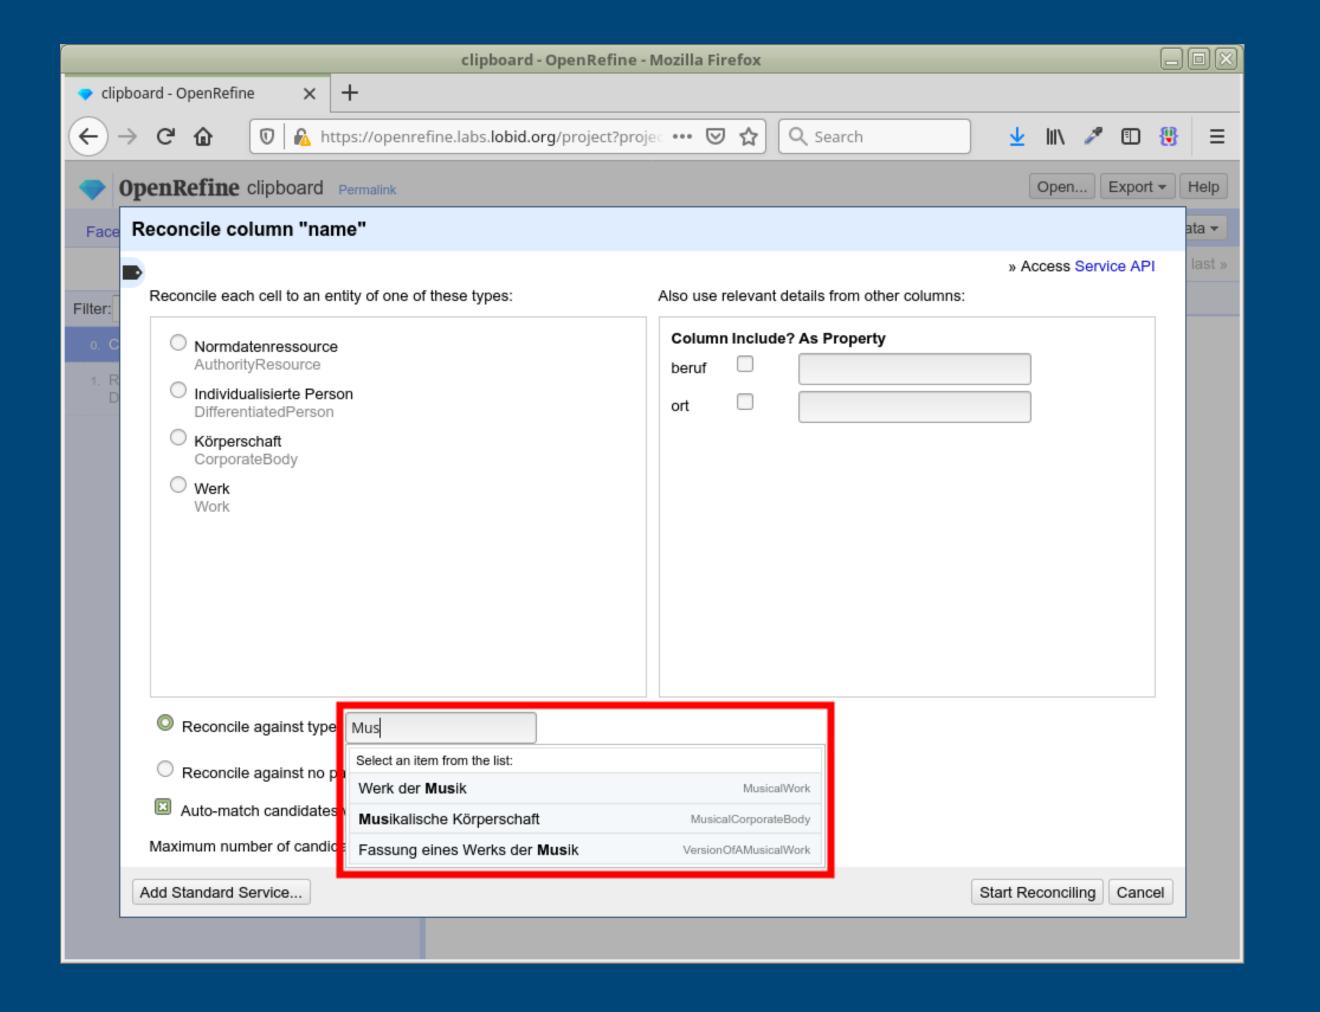
Ergebnisse verbessen

Einschränkung der Typen der Zielentitäten

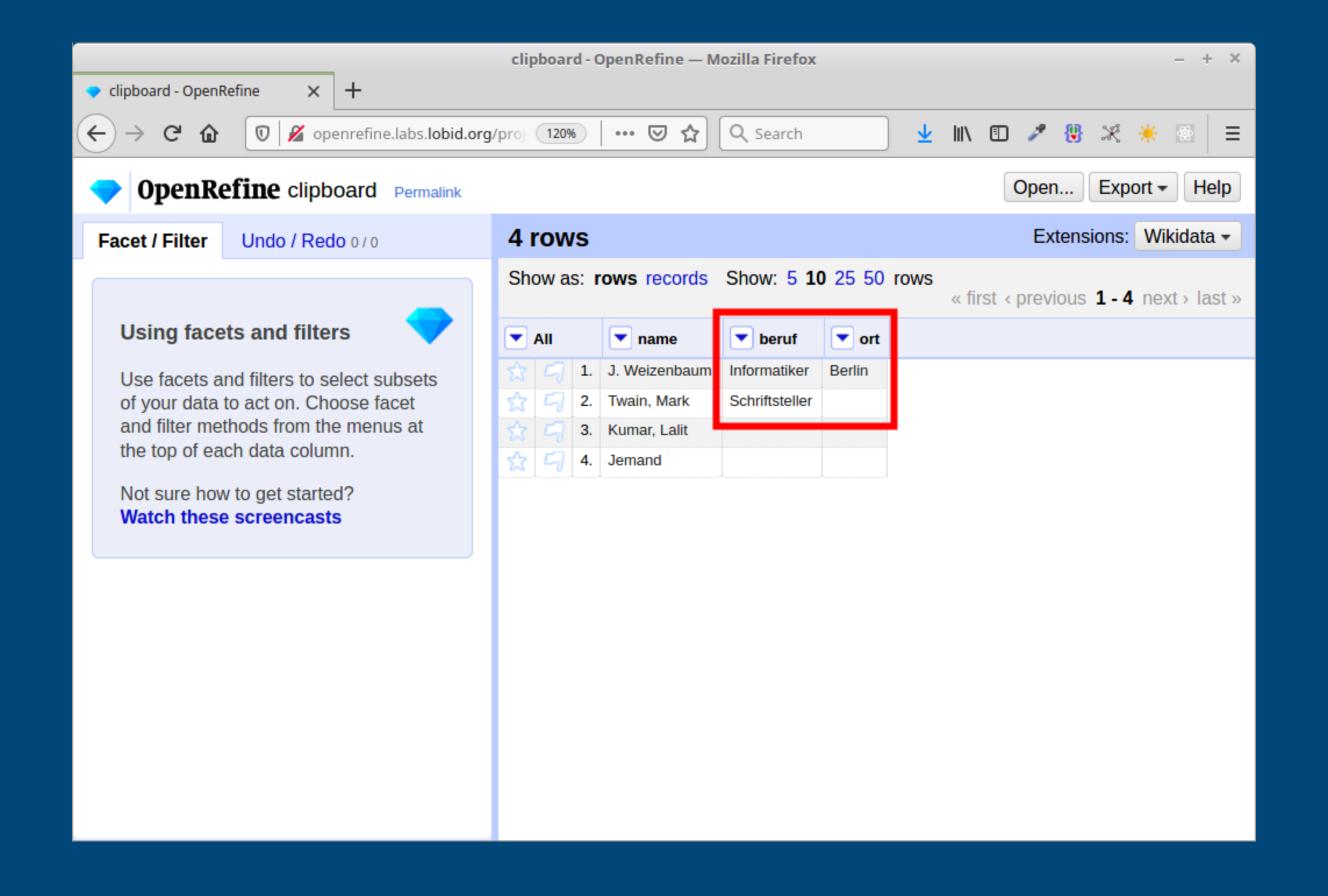
Verwendung zusätzlicher lokaler Daten

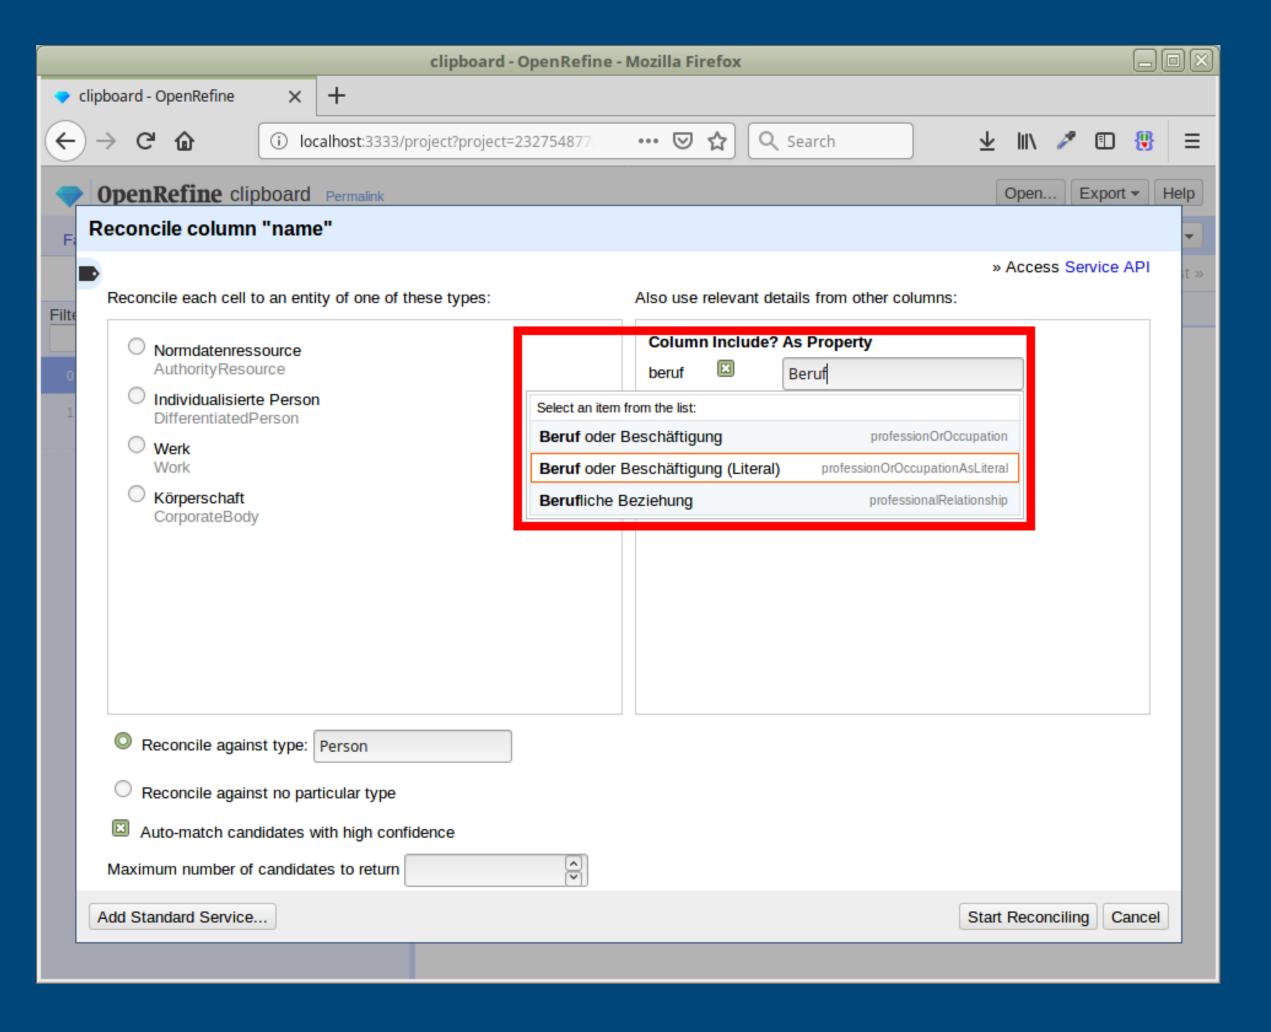
Gezielte Suche nach Treffern

Einschränkung der Entitätstypen

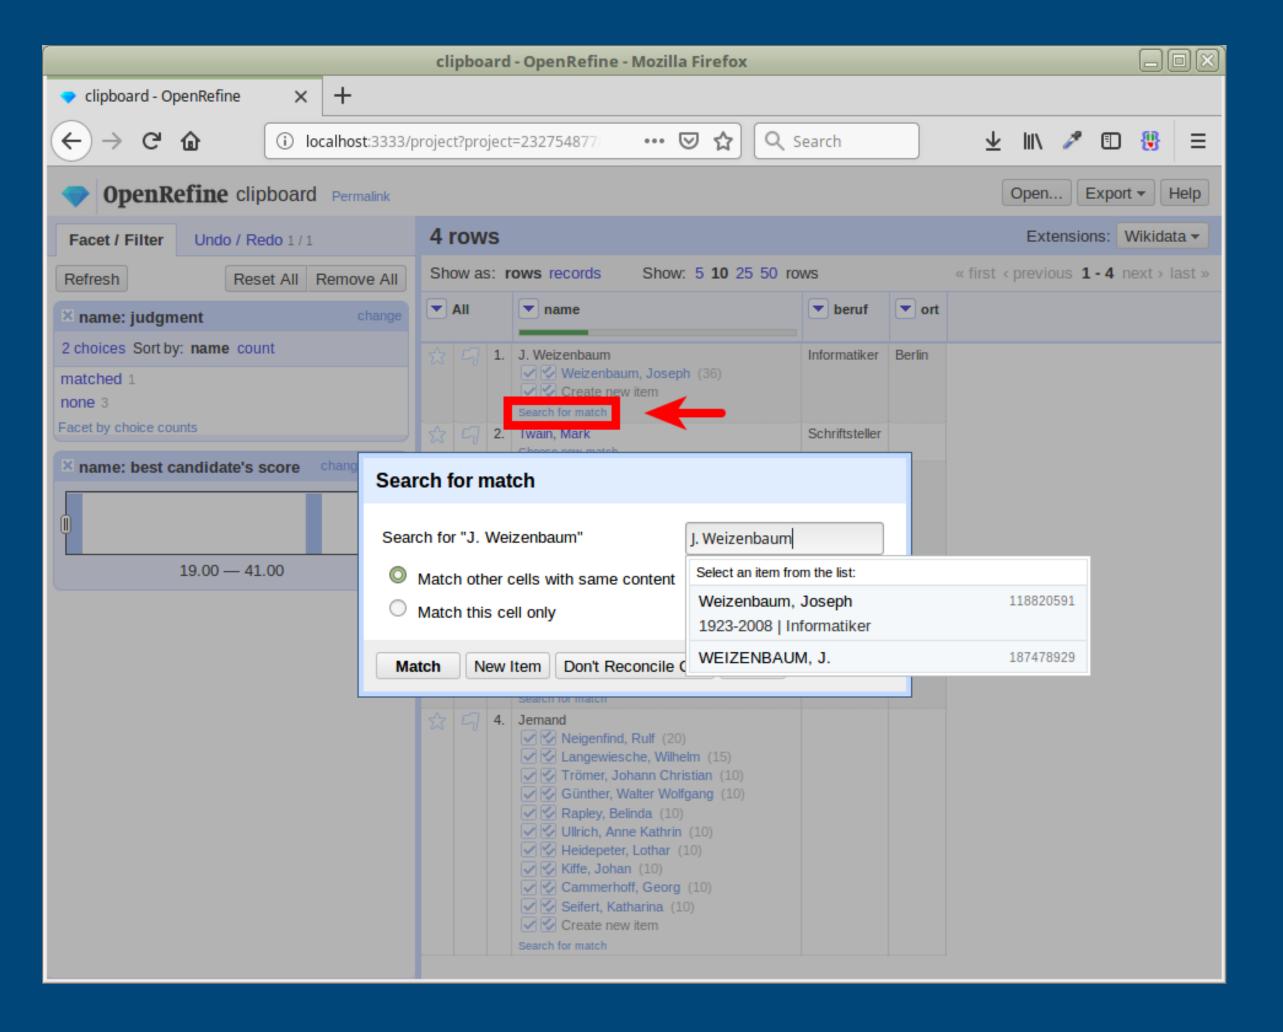


Verwendung zusätzlicher lokaler Daten





Gezielte Suche nach Treffern



Verwendung zusätzlicher lokaler Daten

Verwendung zusätzlicher lokaler Daten

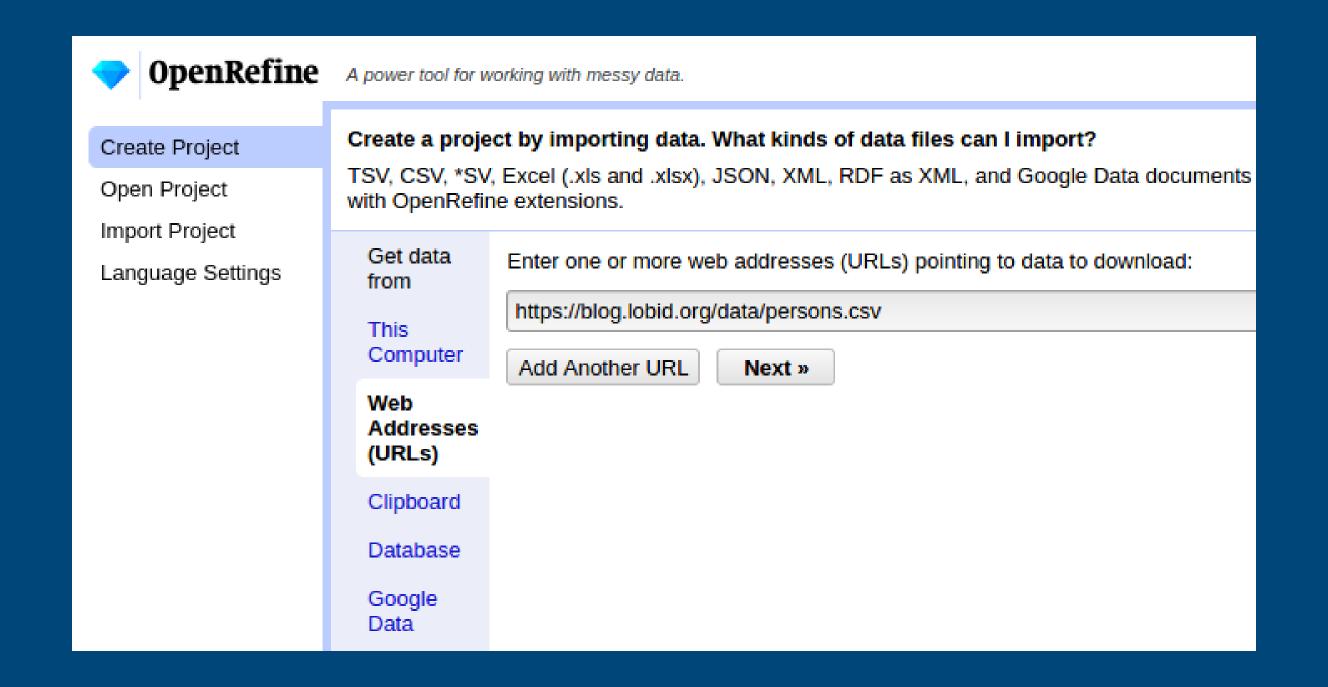
1. Beispiel: Lebensdaten

Verwendung zusätzlicher lokaler Daten

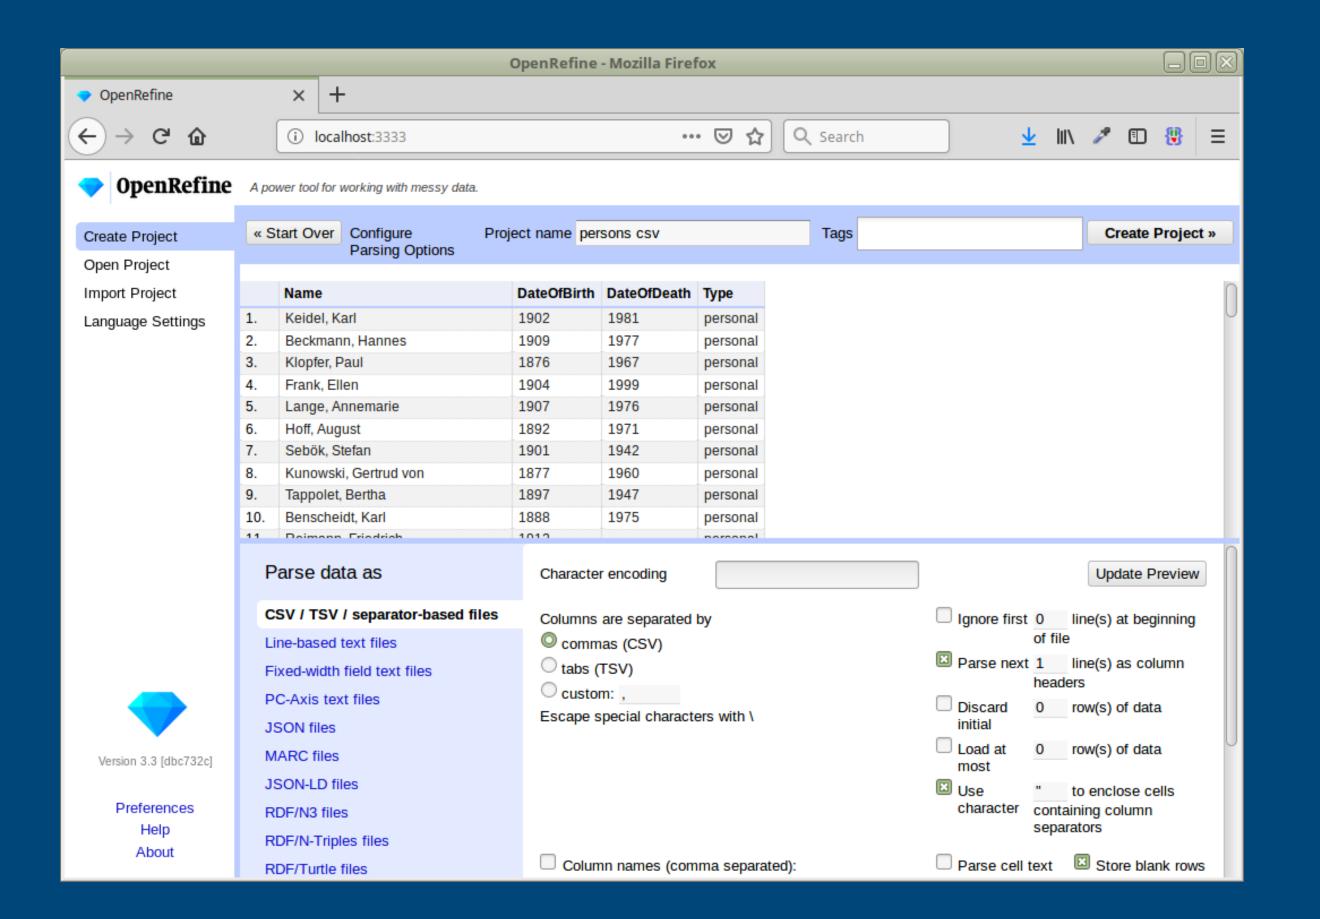
1. Beispiel: Lebensdaten

2. Beispiel: Beruf & Parteizugehörigkeit

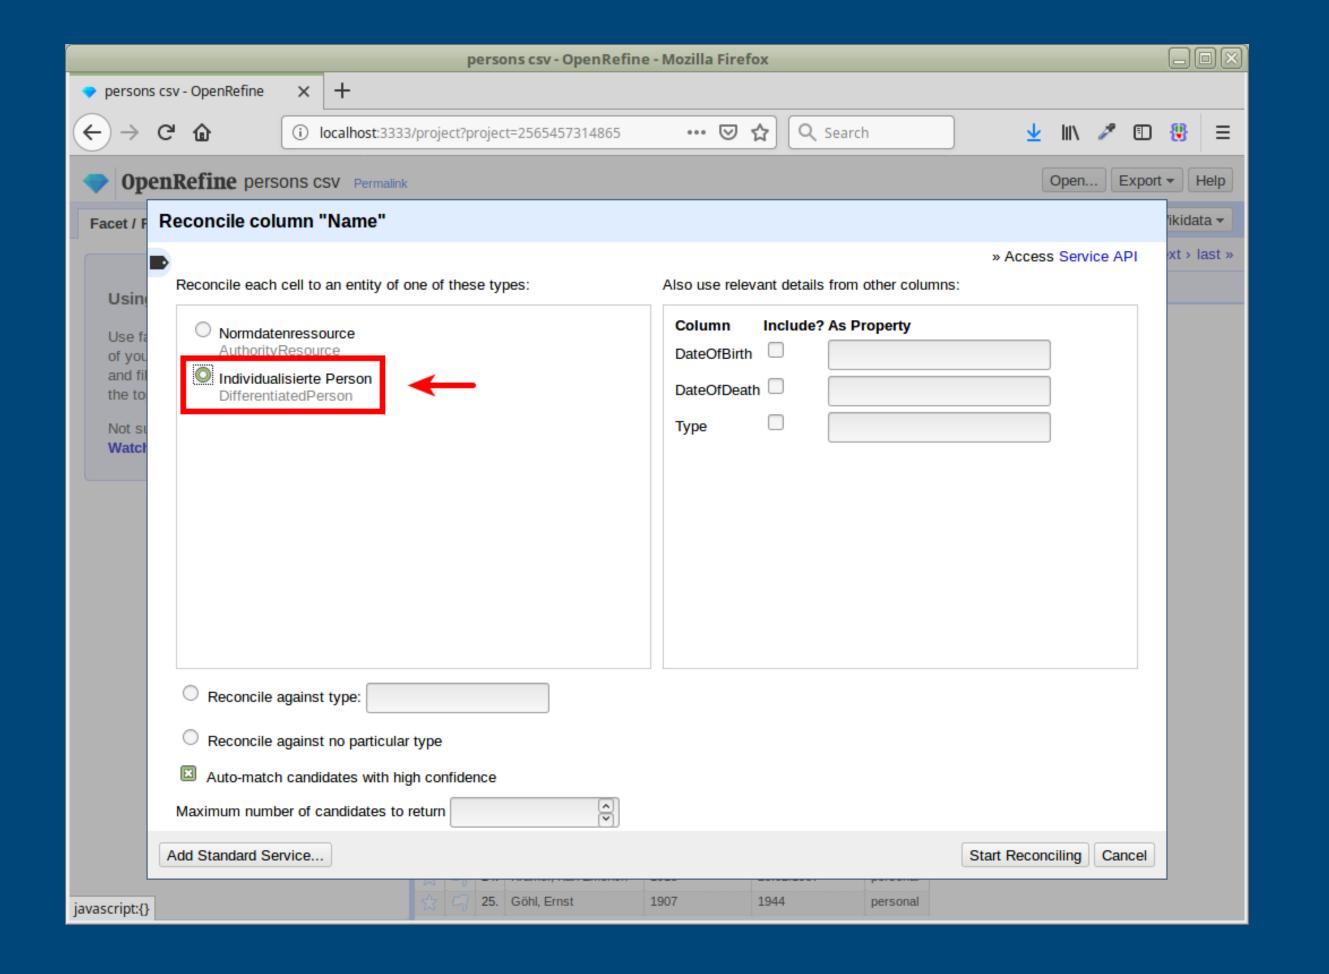
1. Beispiel: Lebensdaten



CSV lokal speichern oder direkt per URL: https://blog.lobid.org/data/persons.csv



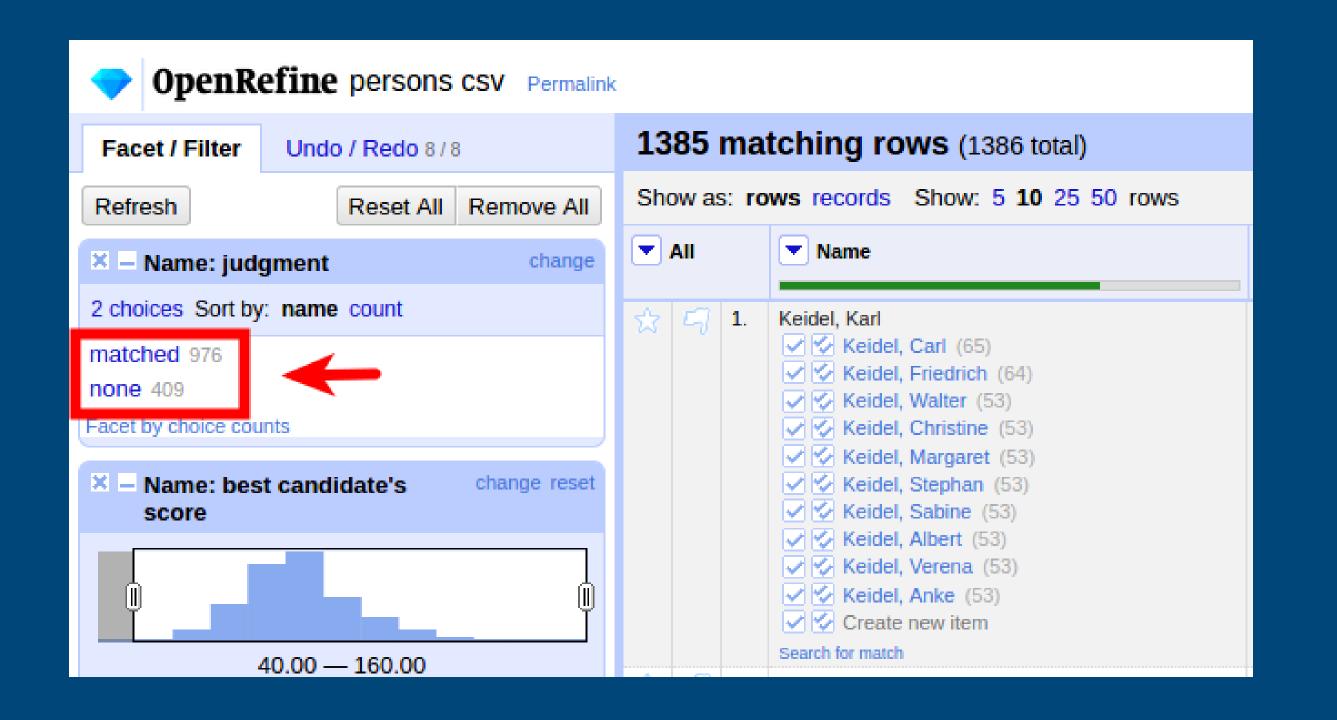
 $^{-171}$



Project anlegen und Namen abgleichen

openrefine.labs.lobid.org | localhost:3333

persons.csv



Ein erstes Ergebnis:

ca. 70% automatisch abgeglichen

Wir wollen die Lebensdaten zur Disambiguierung nutzen

Wir wollen die Lebensdaten zur Disambiguierung nutzen

In unseren abzugleichenden Daten z.B. "1904"

Wir wollen die Lebensdaten zur Disambiguierung nutzen

In unseren abzugleichenden Daten z.B. "1904"

Womit gleichen wir ab? z.B. Ellen Frank

Wir wollen die Lebensdaten zur Disambiguierung nutzen

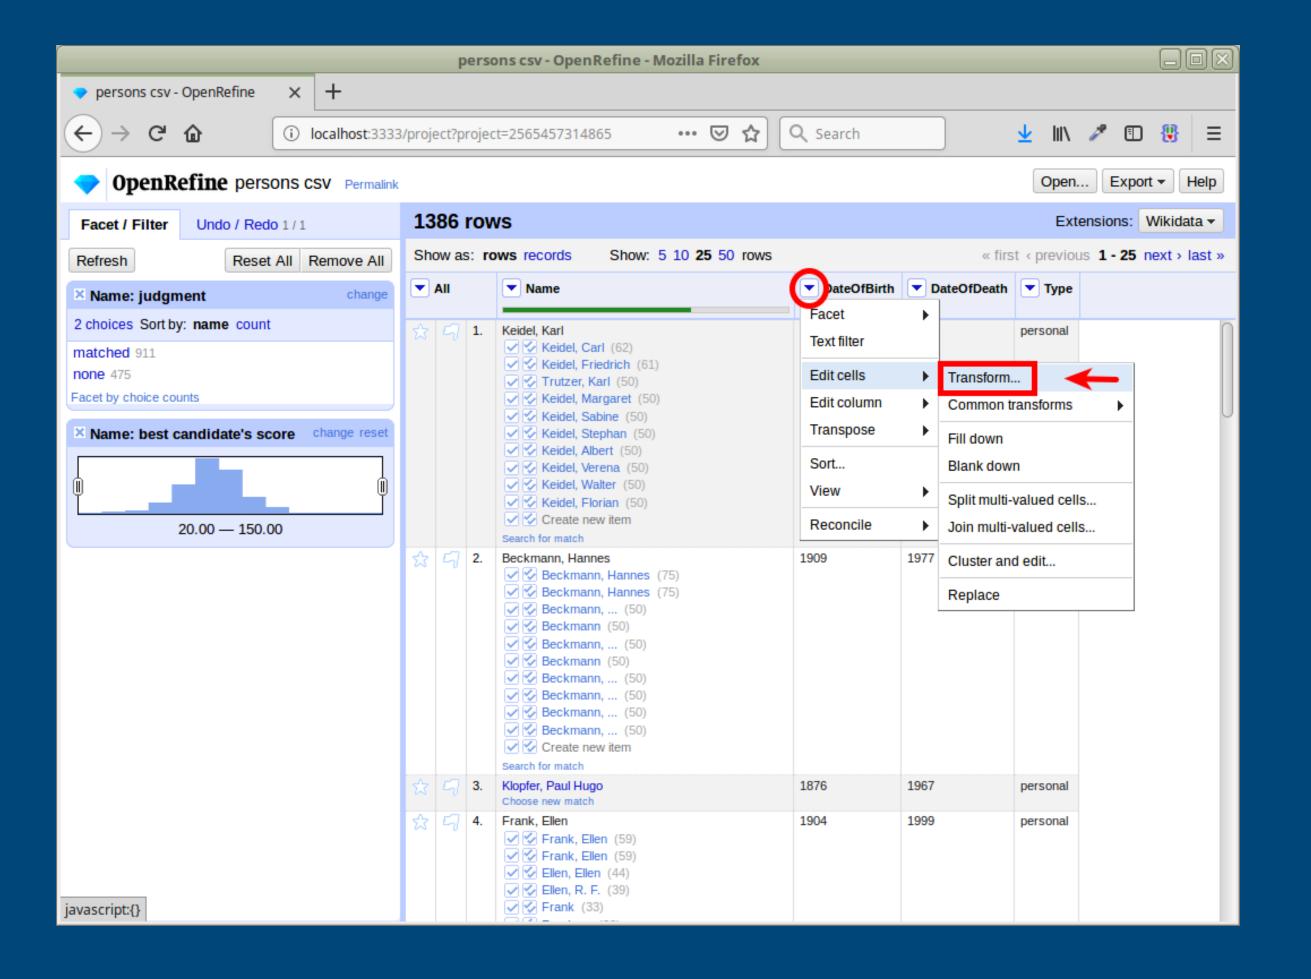
In unseren abzugleichenden Daten z.B. "1904"

Womit gleichen wir ab? z.B. Ellen Frank

```
"dateOfDeath": [
    "1999-09-17"
],

"dateOfBirth": [
    "1904-03-09"
]
```

F



For the state of the

Für die Transformation verschiedene Sprachen

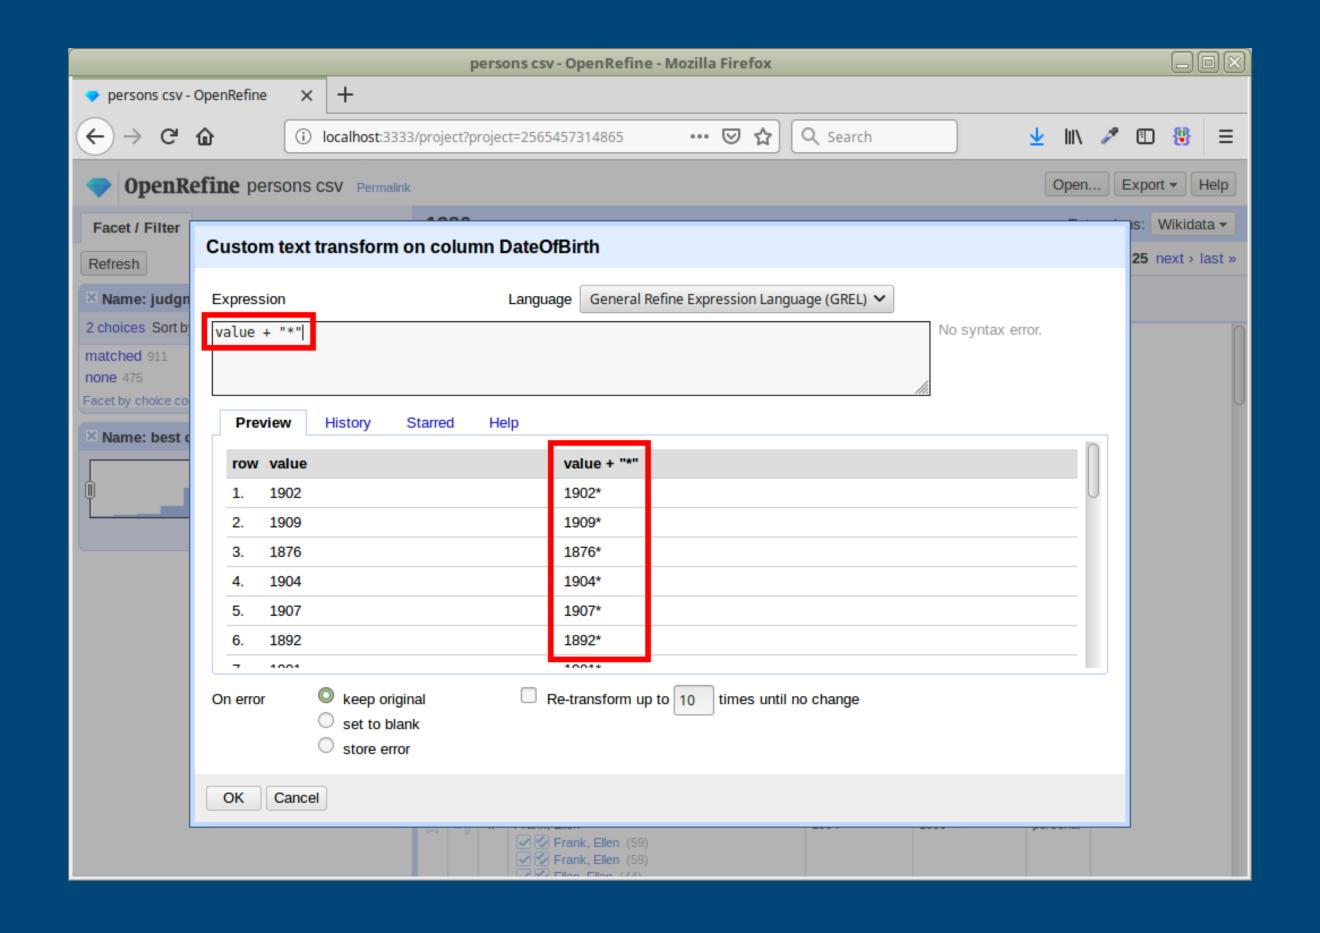
Für die Transformation verschiedene Sprachen

General Refine Expression Language (GREL)

Für die Transformation verschiedene Sprachen

General Refine Expression Language (GREL)

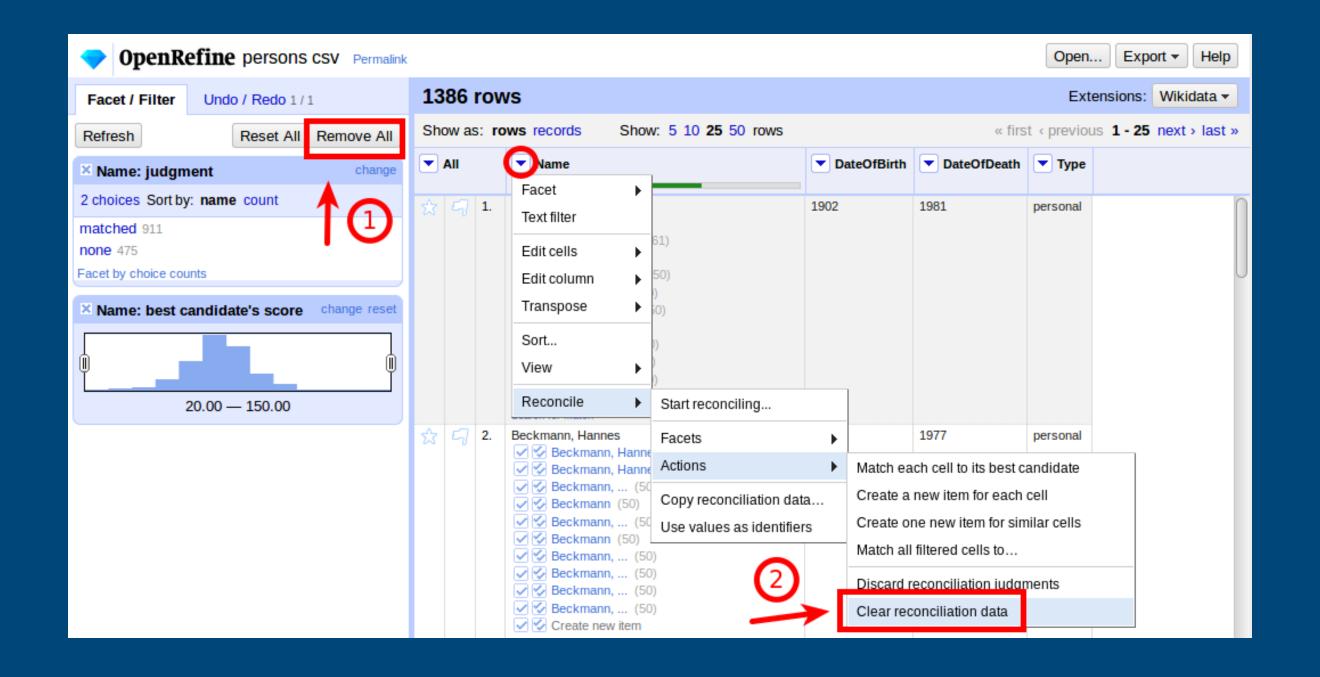
Python/Jython & Clojure



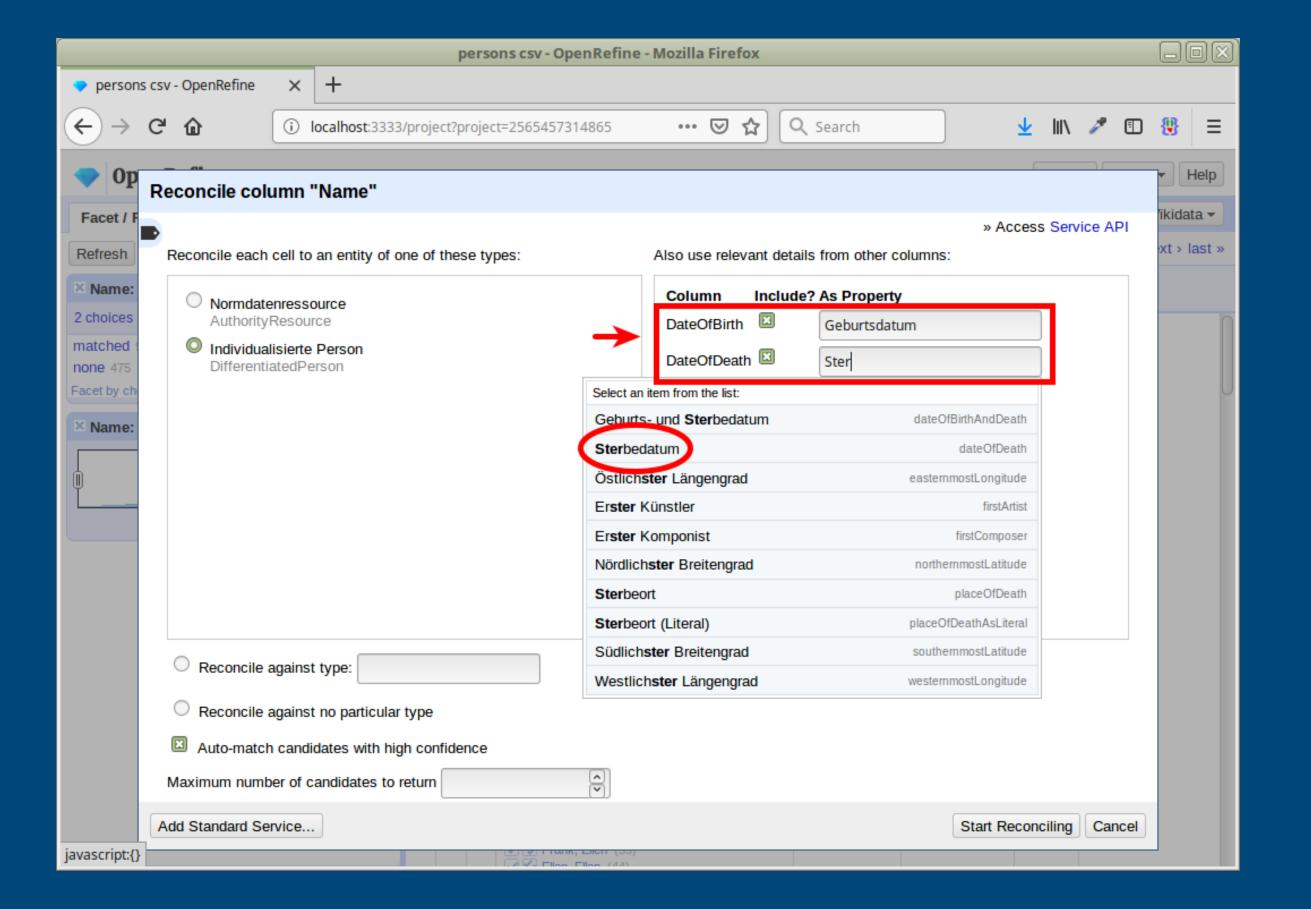
Wildcards: ? für ein Zeichen, * für beliebig viele Zeichen

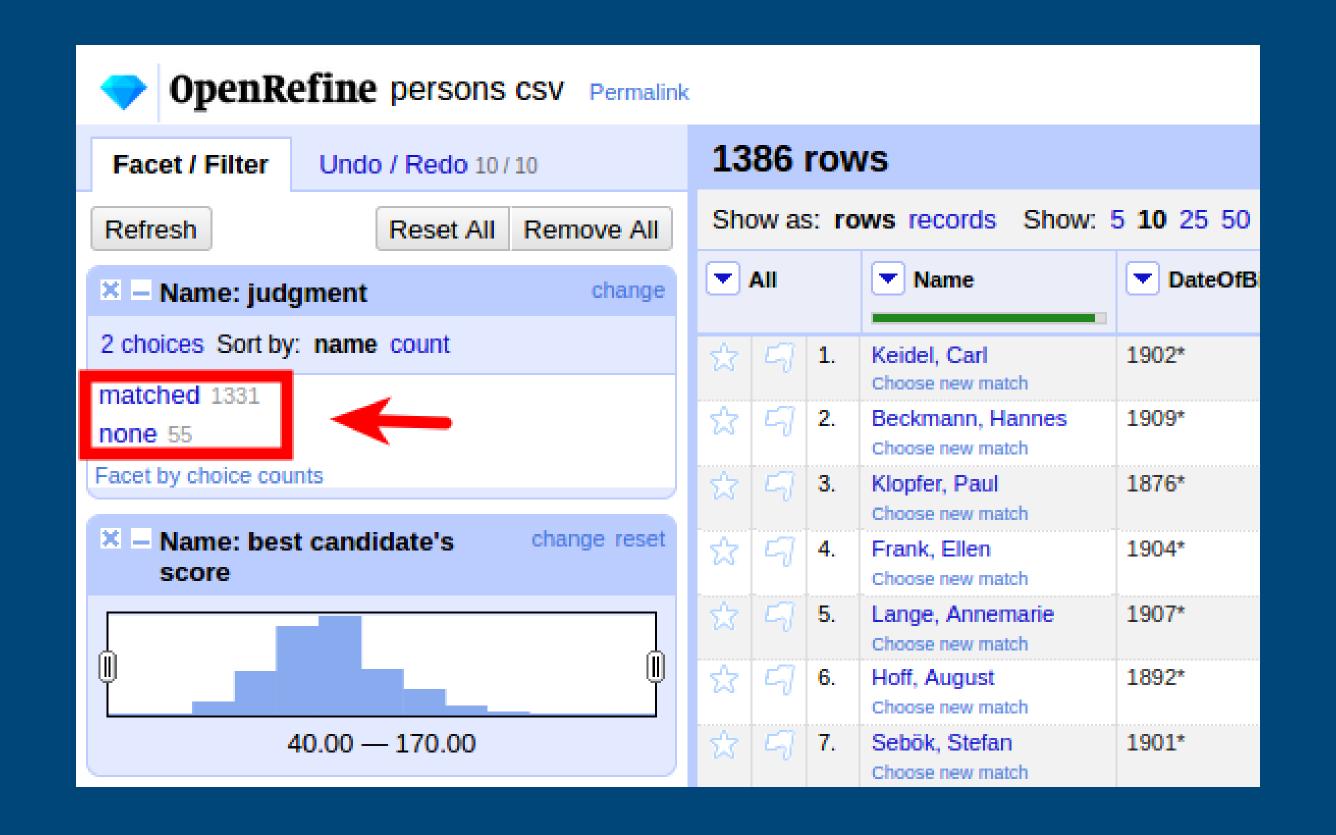
178

Daten bereit für neuen, verbesserten Abgleich



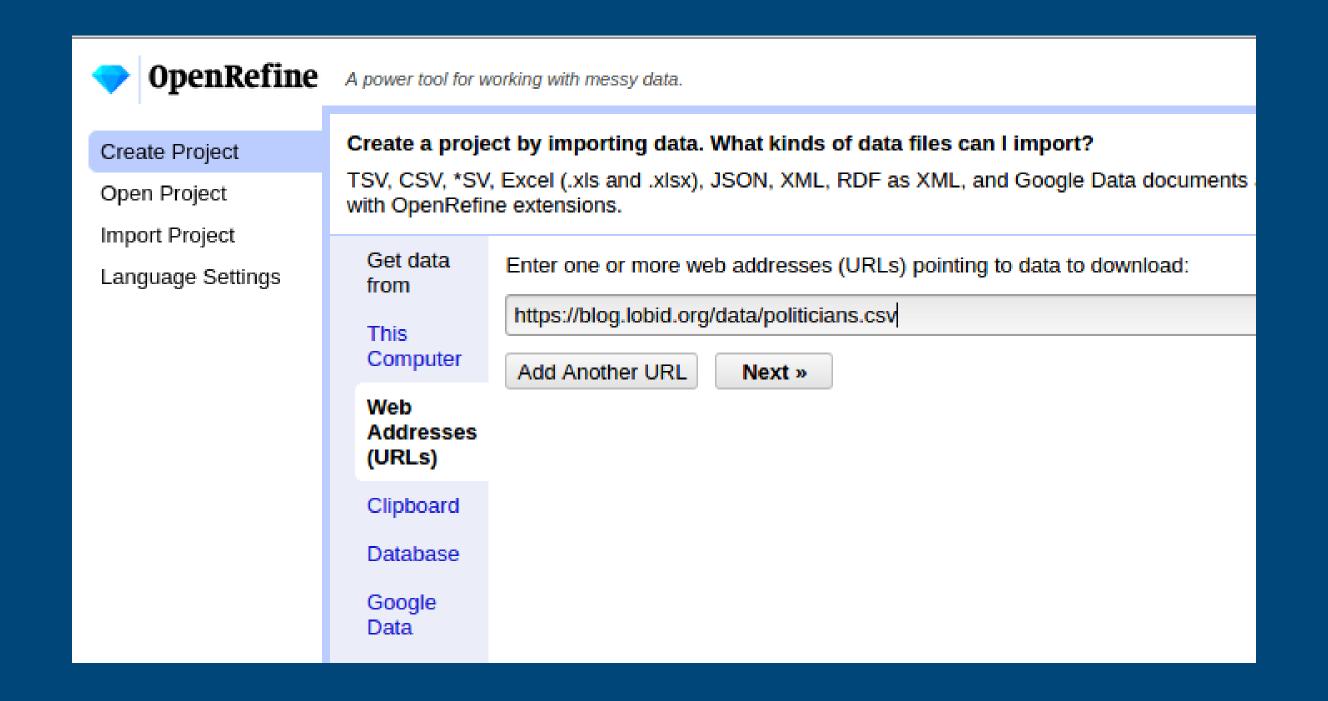
Vorherigen Abgleich zurücksetzen



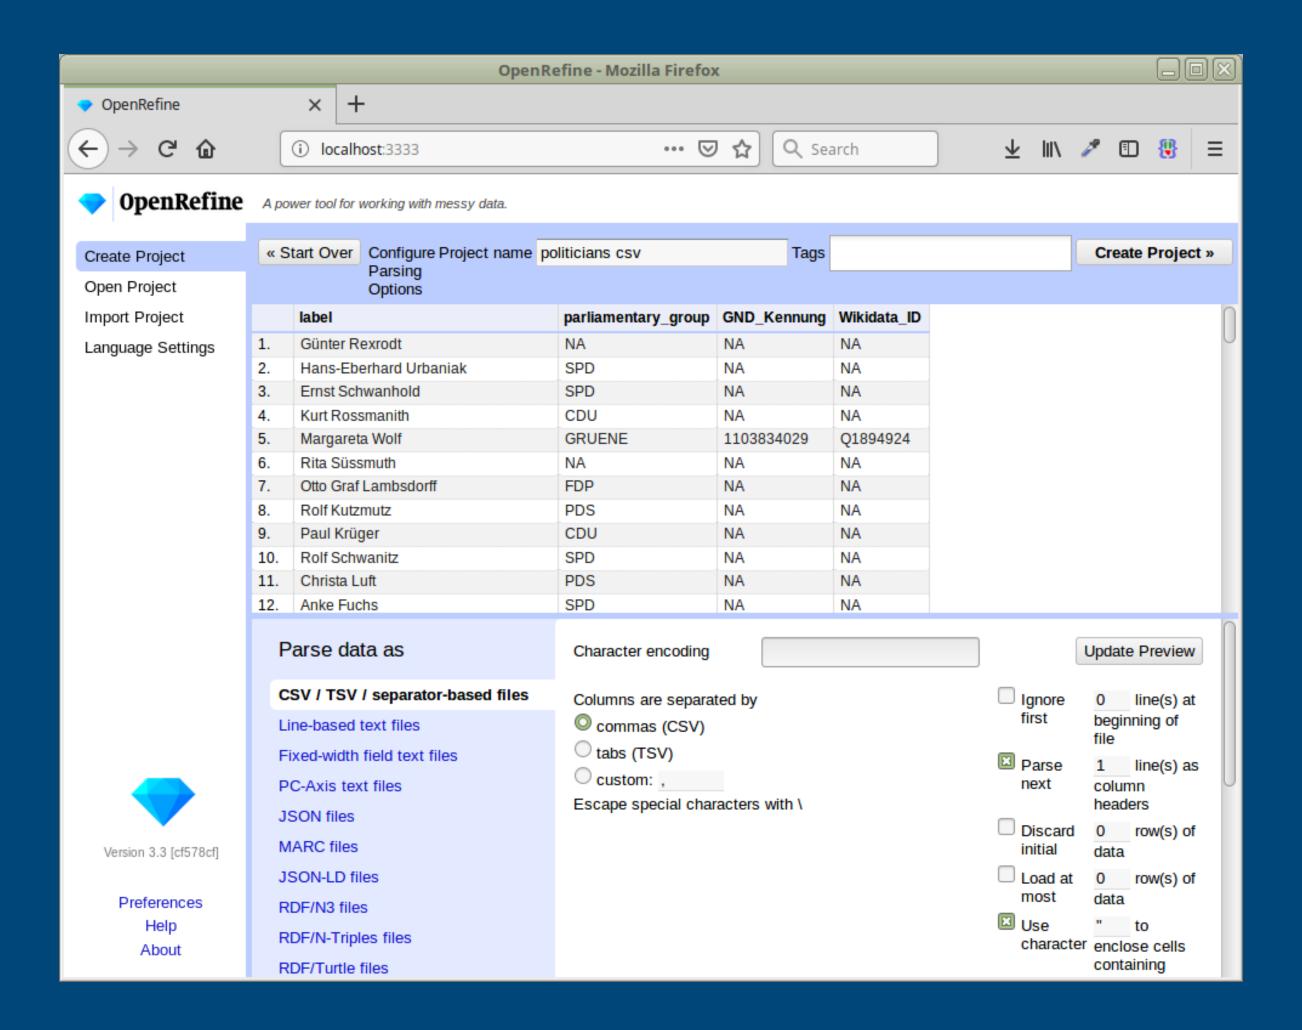


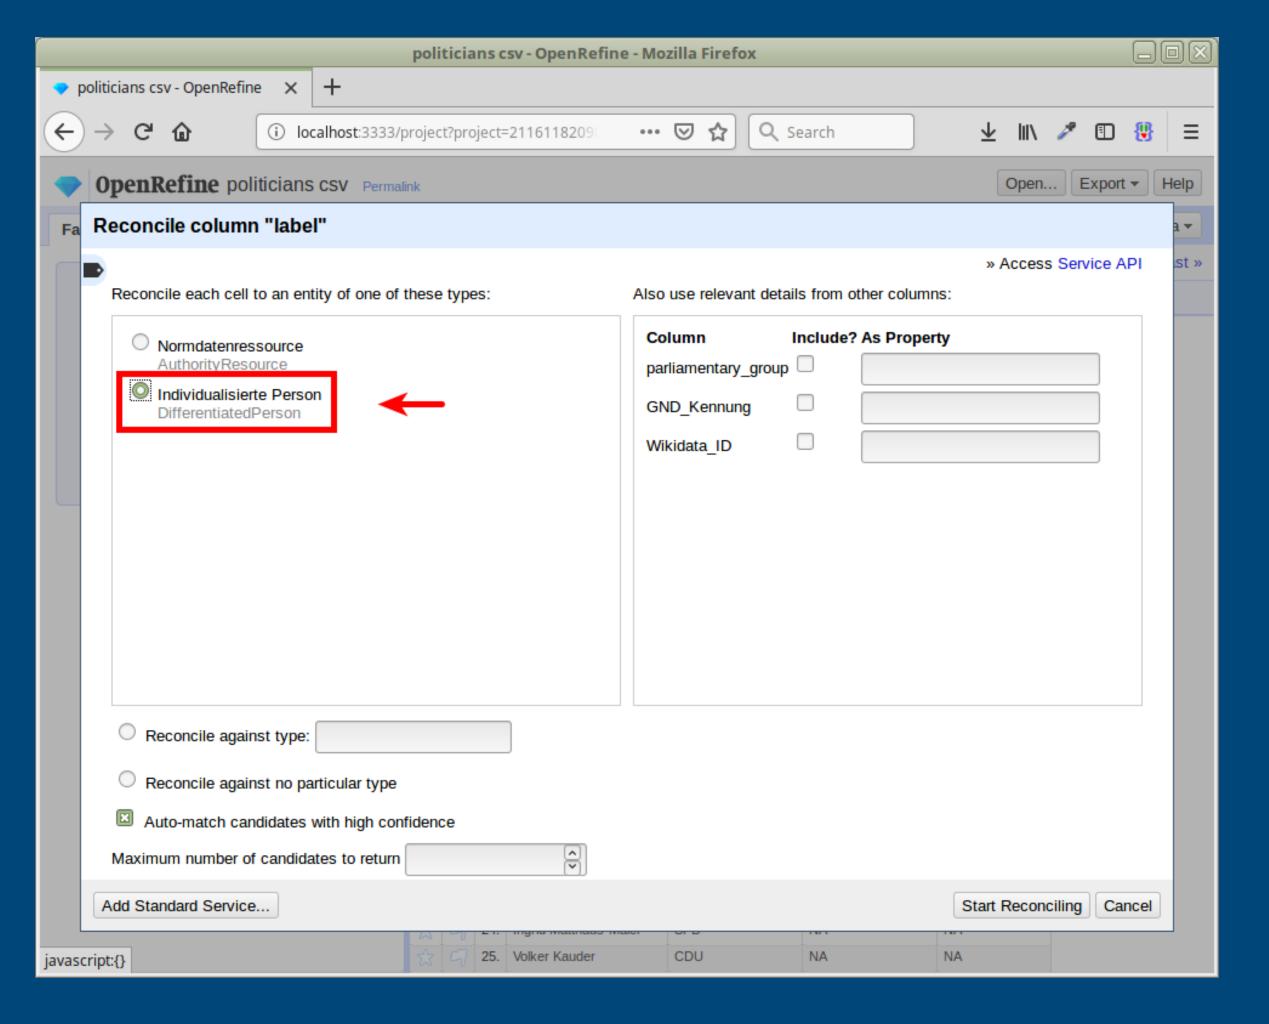
ca. 95% automatisch abgeglichen

2. Beispiel: Beruf & Parteizugehörigkeit



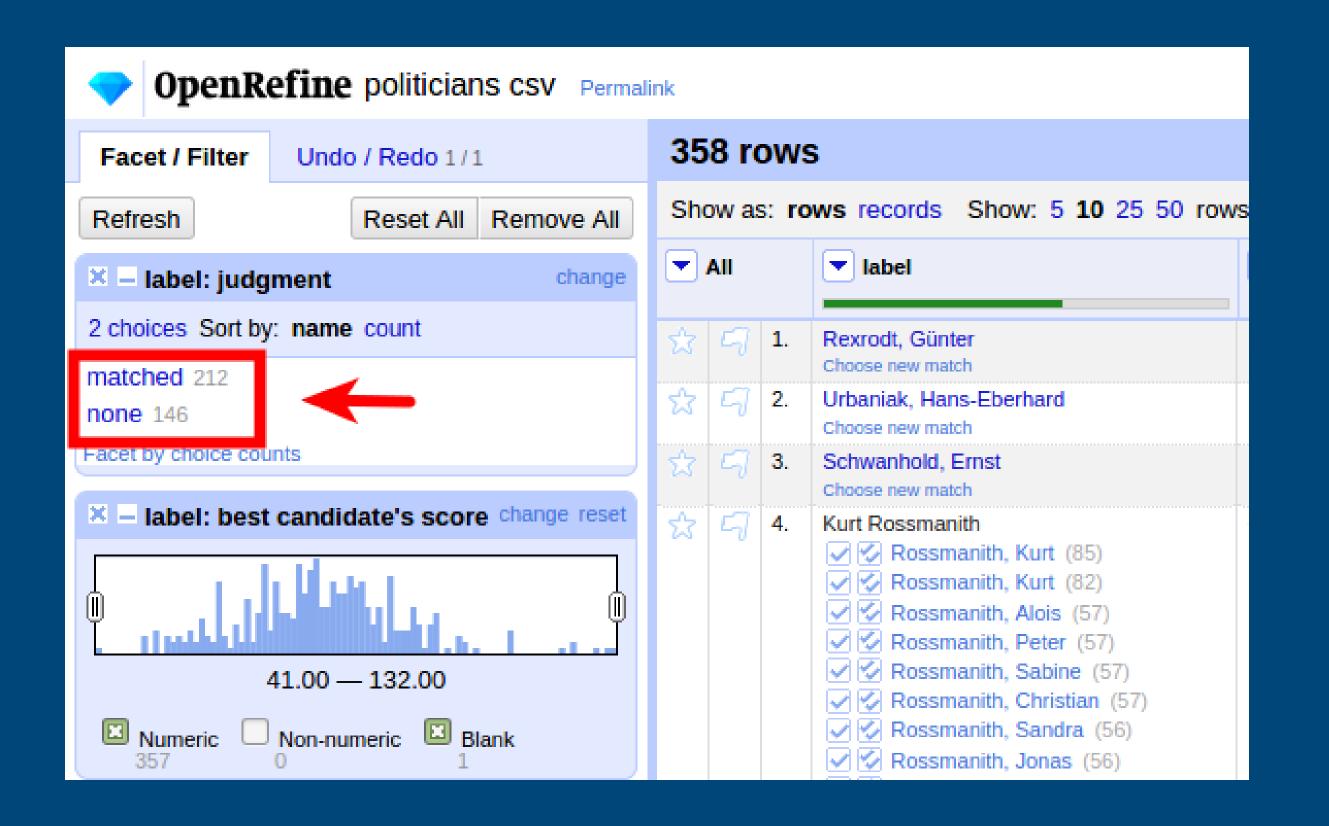
CSV lokal speichern oder direkt per URL: https://blog.lobid.org/data/politicians.csv





Project anlegen und Namen abgleichen

openrefine.labs.lobid.org | localhost:3333 politicians.csv



Ein erstes Ergebnis:

ca. 60% automatisch abgeglichen

•

Wir wollen die Parteizugehörigkeit nutzen

Wir wollen die Parteizugehörigkeit nutzen

In unseren abzugleichenden Daten z.B. SPD

Wir wollen die Parteizugehörigkeit nutzen

In unseren abzugleichenden Daten z.B. SPD

Womit gleichen wir ab? z.B. Willy Brandt

Wir wollen die Parteizugehörigkeit nutzen

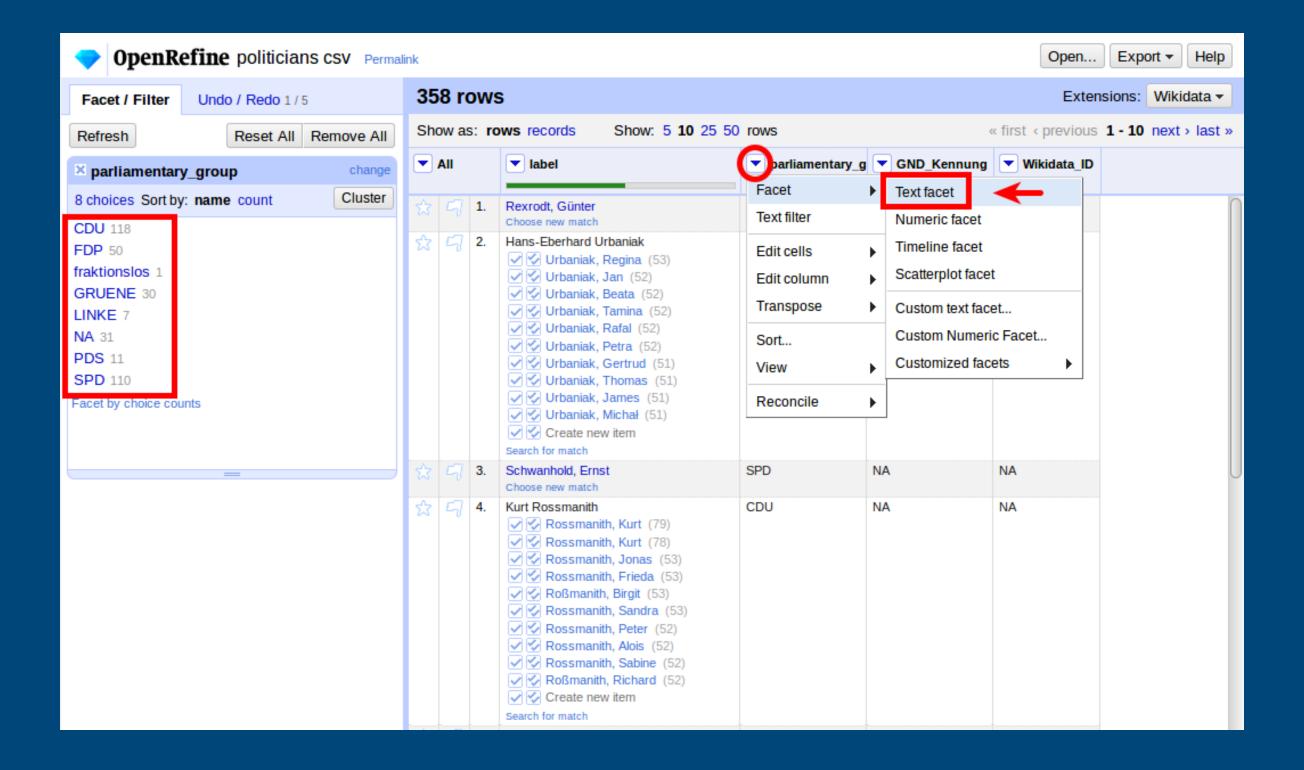
In unseren abzugleichenden Daten z.B. SPD

Womit gleichen wir ab? z.B. Willy Brandt

```
"affiliation": [
    {
        "id": "https://d-nb.info/gnd/2022139-3",
        "label": "Sozialdemokratische Partei Deutschlands"
    }
]
```

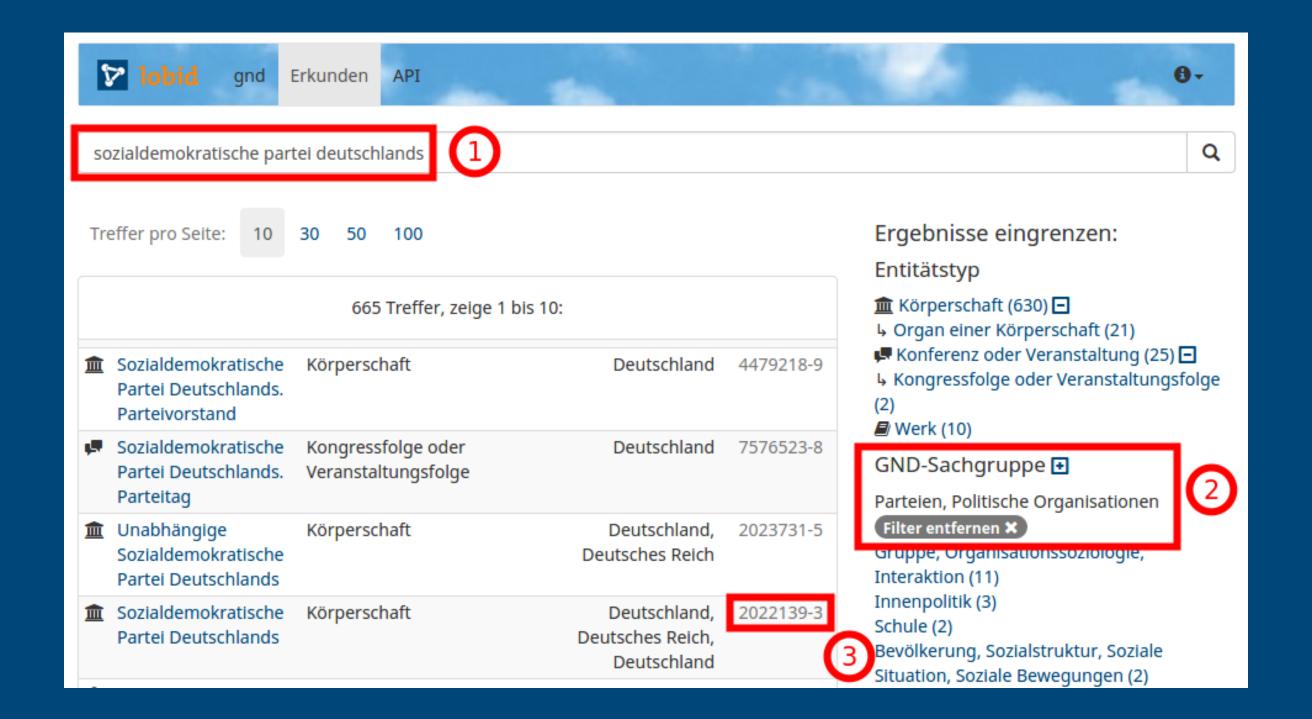
Abkürzungen auf eindeutige Identifier mappen

Welche Abkürzungen kommen in den Daten vor?



Ü

Wie finden wir die GND-Nummern? z.B. SPD:



192

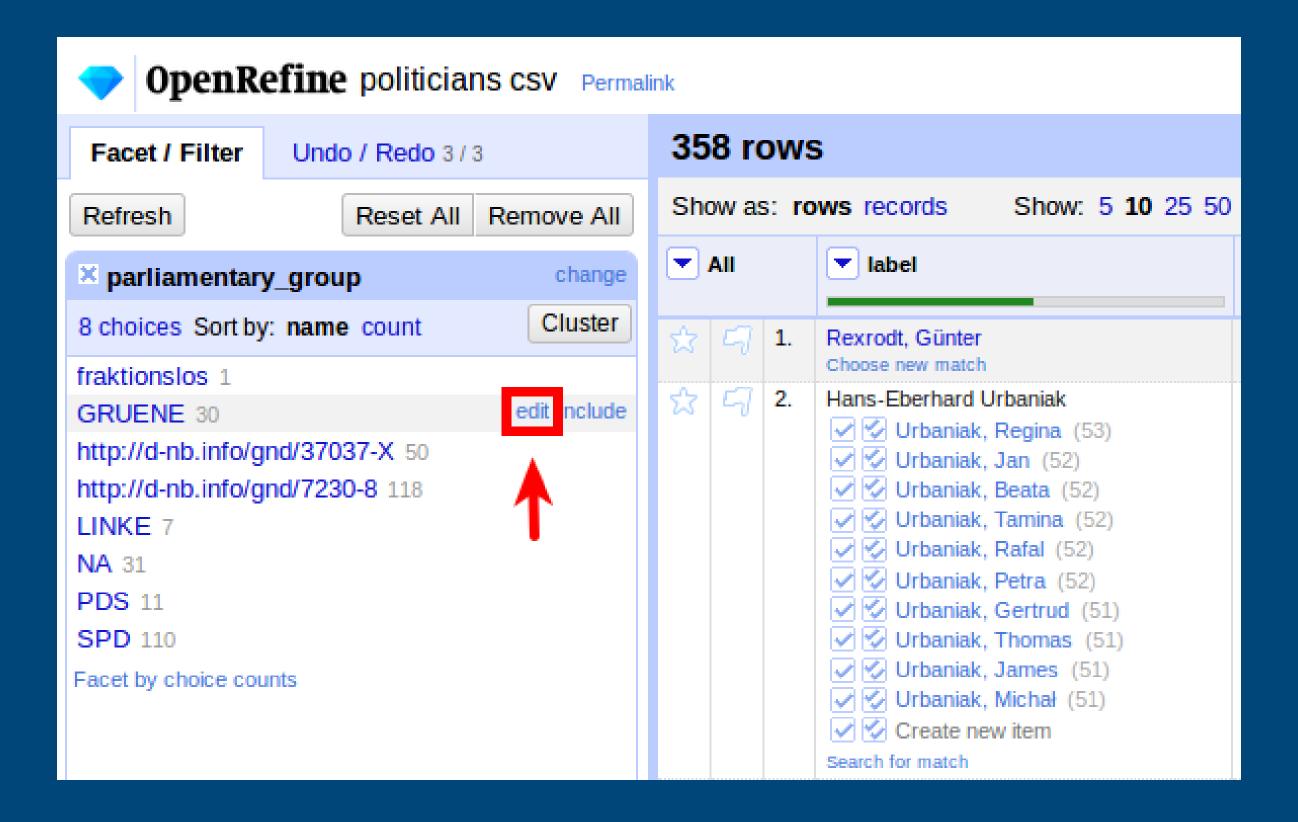
Übung: Abkürzungen auf eindeutige Identifier mappen

- SPD → https://d-nb.info/gnd/???
- CDU → https://d-nb.info/gnd/???
- GRUENE → https://d-nb.info/gnd/???
- FDP → https://d-nb.info/gnd/???
- LINKE → https://d-nb.info/gnd/???
- PDS → https://d-nb.info/gnd/???

Mappings

- SPD \rightarrow https://d-nb.info/gnd/2022139-3
- CDU → https://d-nb.info/gnd/7230-8
- GRUENE \rightarrow https://d-nb.info/gnd/2124337-2
- FDP → https://d-nb.info/gnd/37037-X
- LINKE → https://d-nb.info/gnd/10173685-X
- PDS → https://d-nb.info/gnd/5010217-5

In der Text-Facette können wir alle Vorkommen der Werte entsprechend unseres Mappings editieren:



 U

Diese manuelle Schritte können in der Undo/Redo-History extrahiert werden:



U

Wir bekommen die Editierhistorie als JSON:

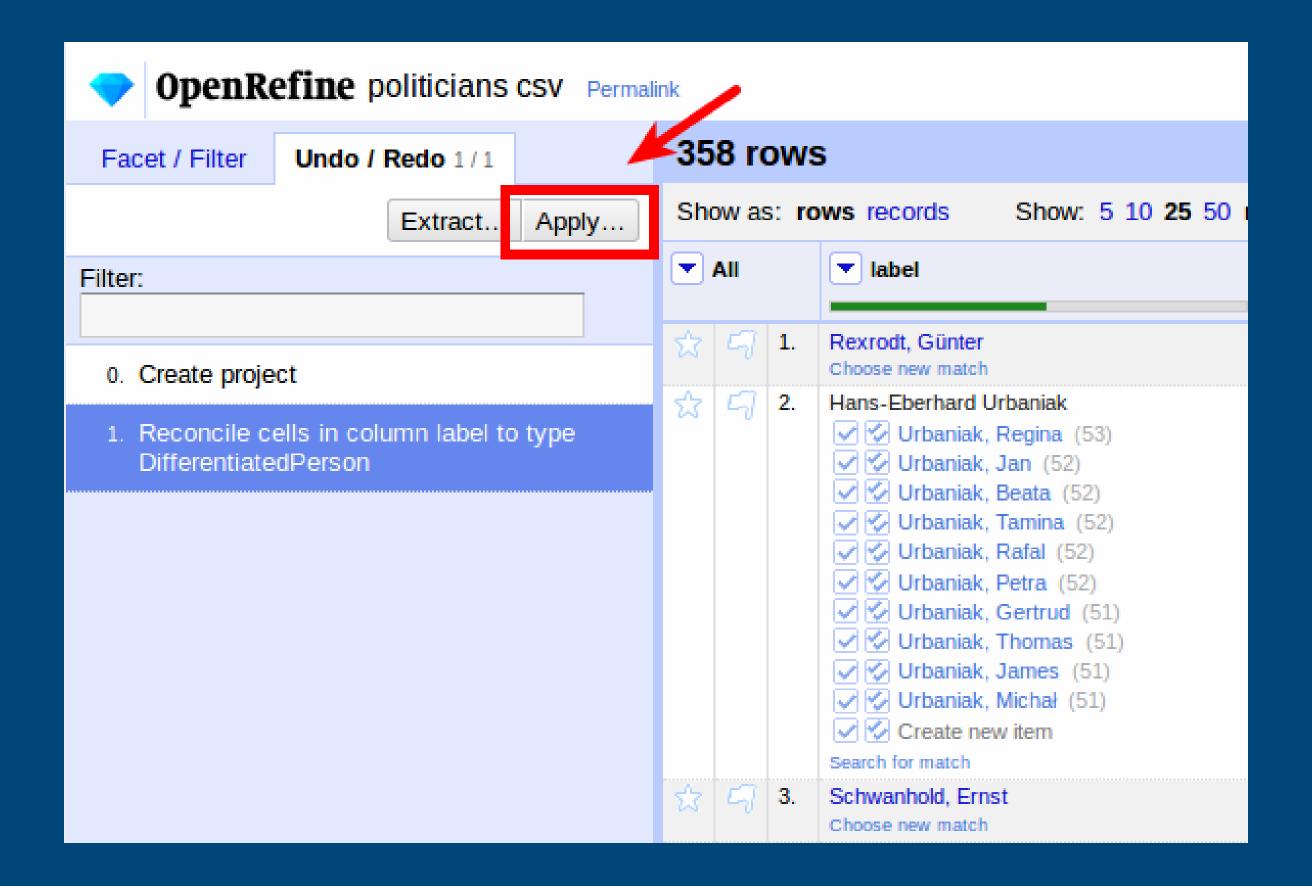
```
"op": "core/column-addition",
    "engineConfig": {
      "facets": [],
      "mode": "row-based"
    "baseColumnName": "parliamentary group",
    "expression": "grel:value",
    "onError": "set-to-blank",
    "newColumnName": "affiliation",
    "columnInsertIndex": 2,
    "description": "Create column affiliation at index 2 based
on column parliamentary group using expression grel:value"
```

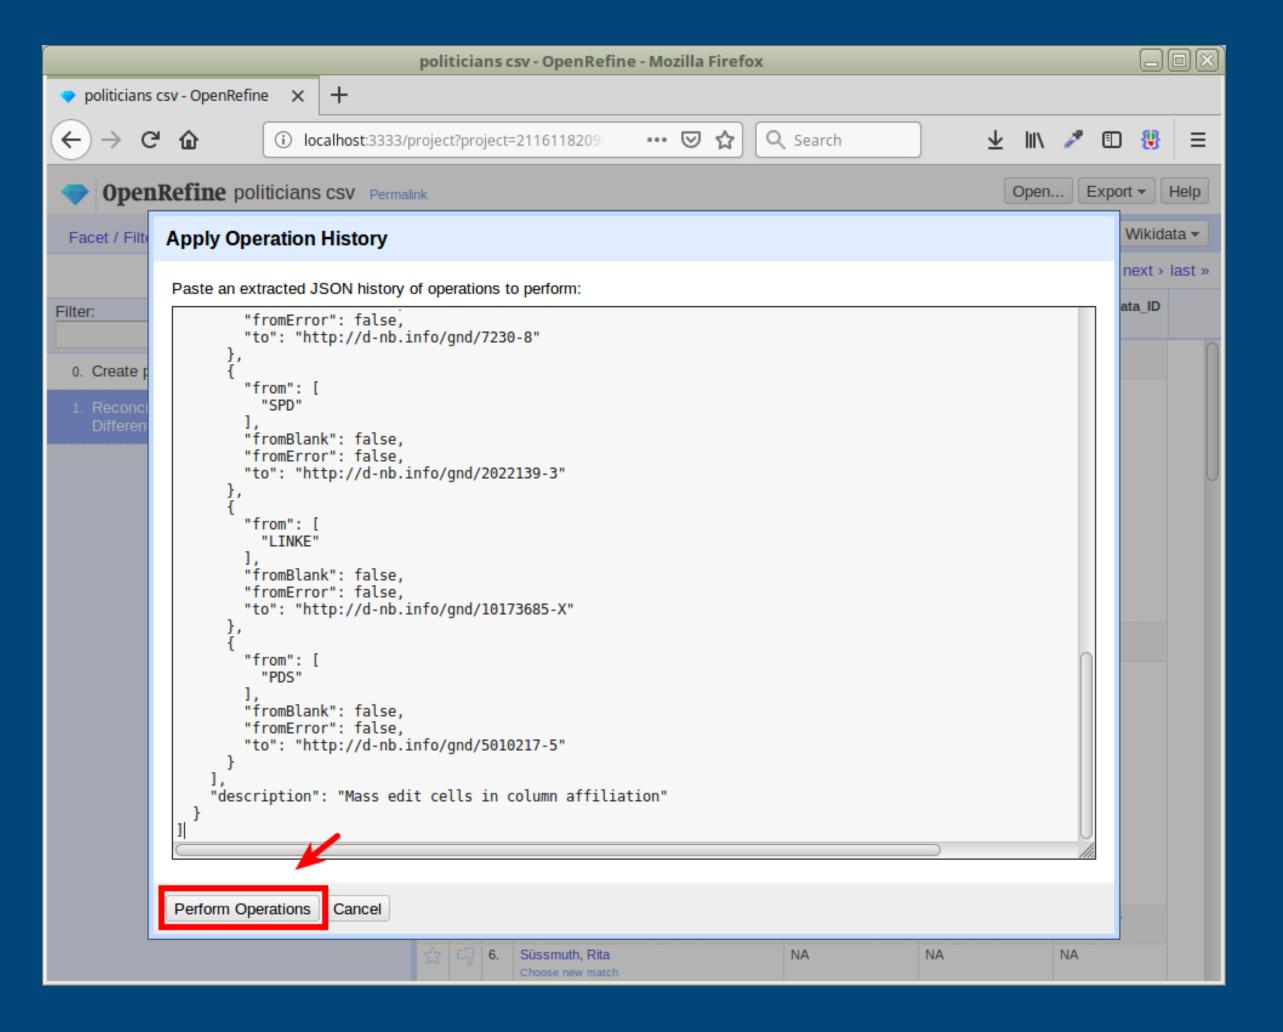
Wir bekommen die Editierhistorie als JSON:

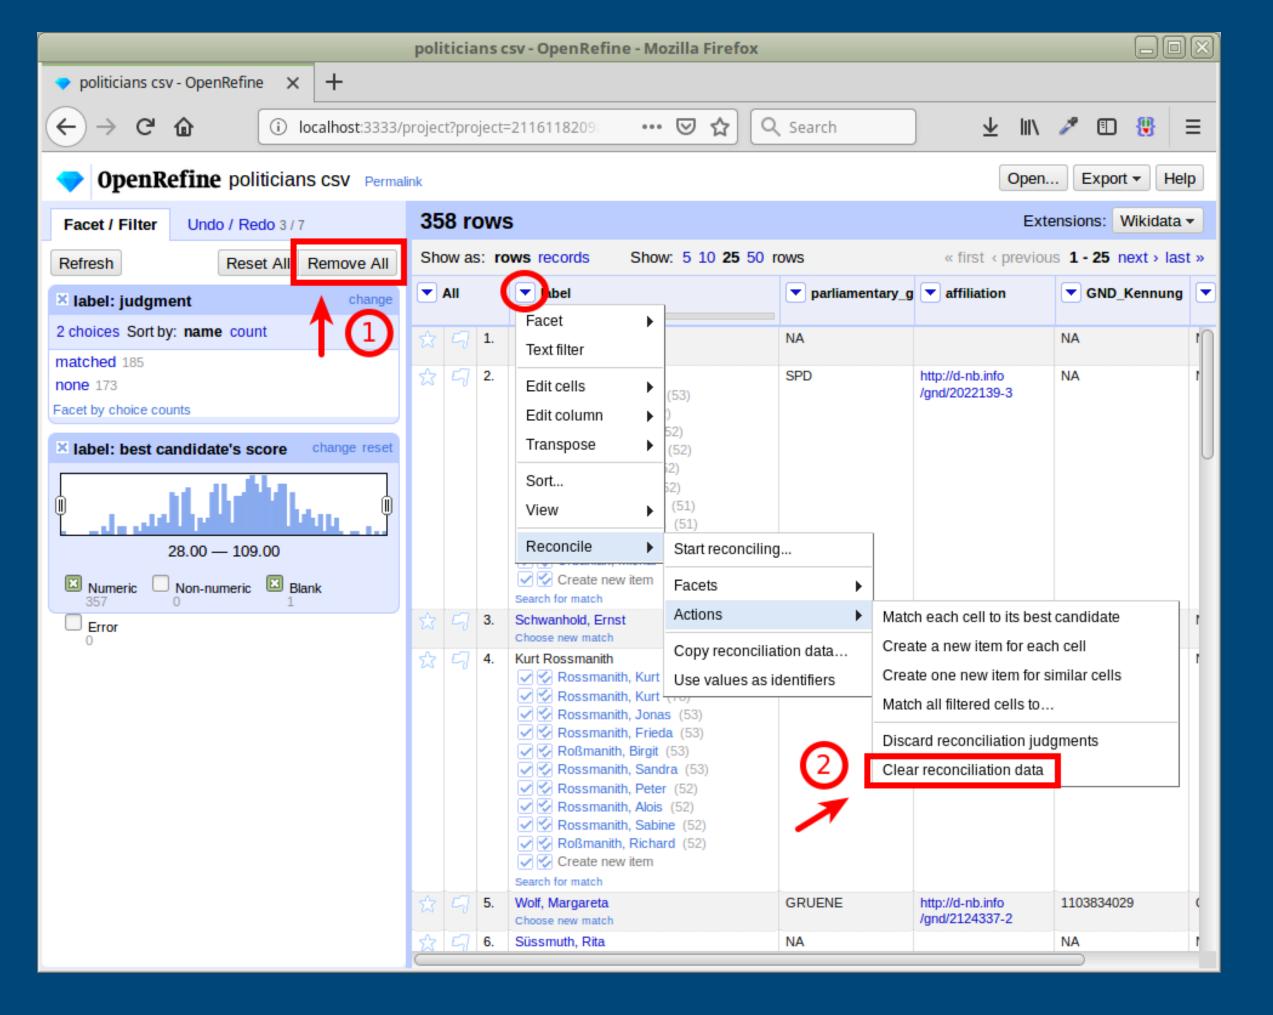
```
"op": "core/column-addition",
    "engineConfig": {
      "facets": [],
      "mode": "row-based"
    "baseColumnName": "parliamentary group",
    "expression": "grel:value",
    "onError": "set-to-blank",
    "newColumnName": "affiliation",
    "columnInsertIndex": 2,
    "description": "Create column affiliation at index 2 based
on column parliamentary group using expression grel:value"
```

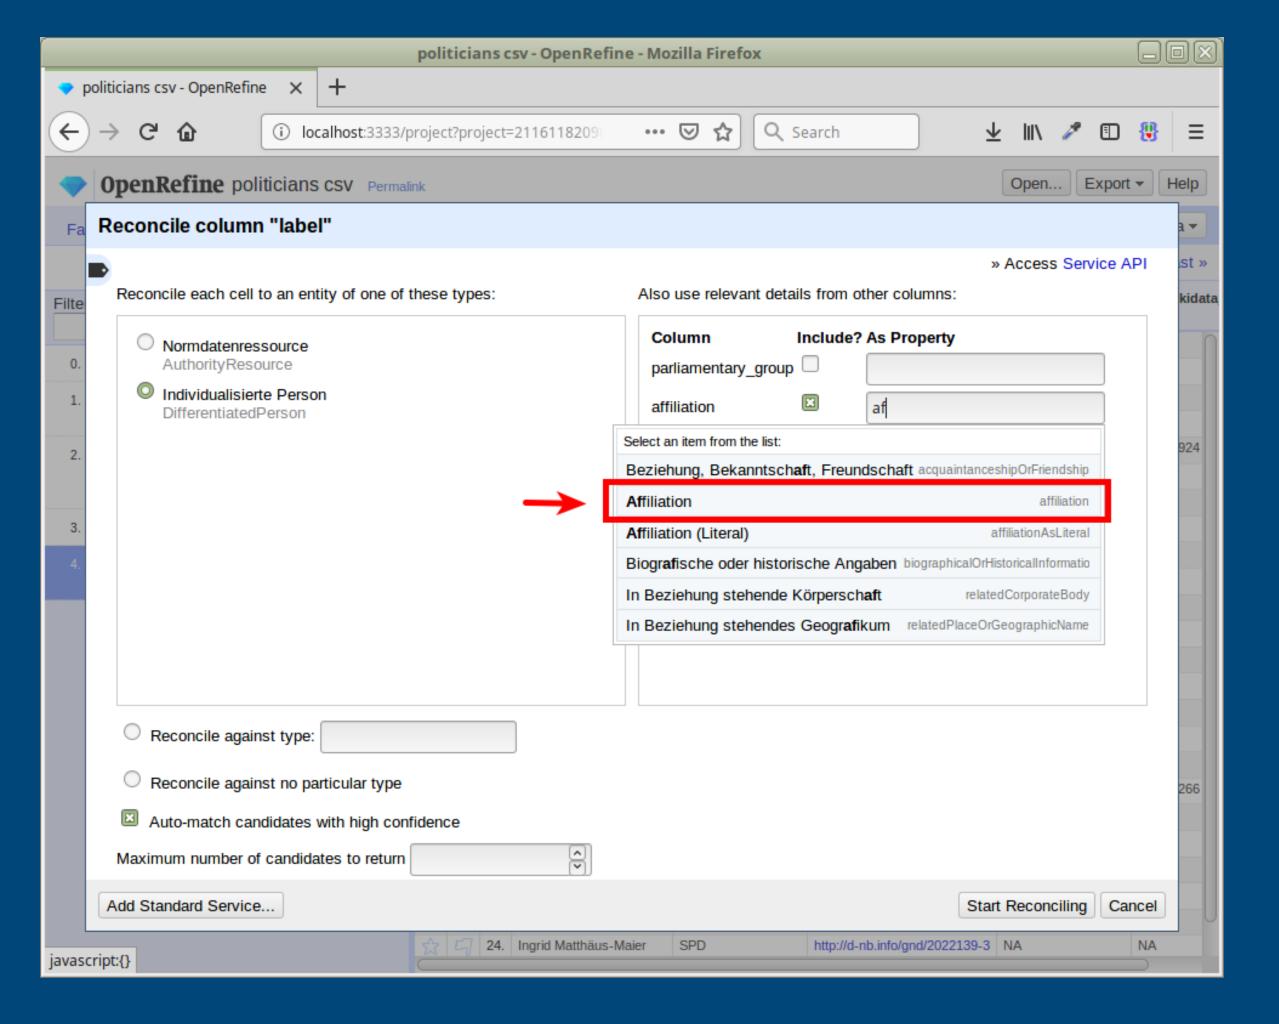
(Hier setzt auch die erwähnte Möglichkeit zur Automatisierung an: die manuell von der Fachebene in der Oberfläche erstellten Schritte können so ohne Oberfläche automatisiert werden)

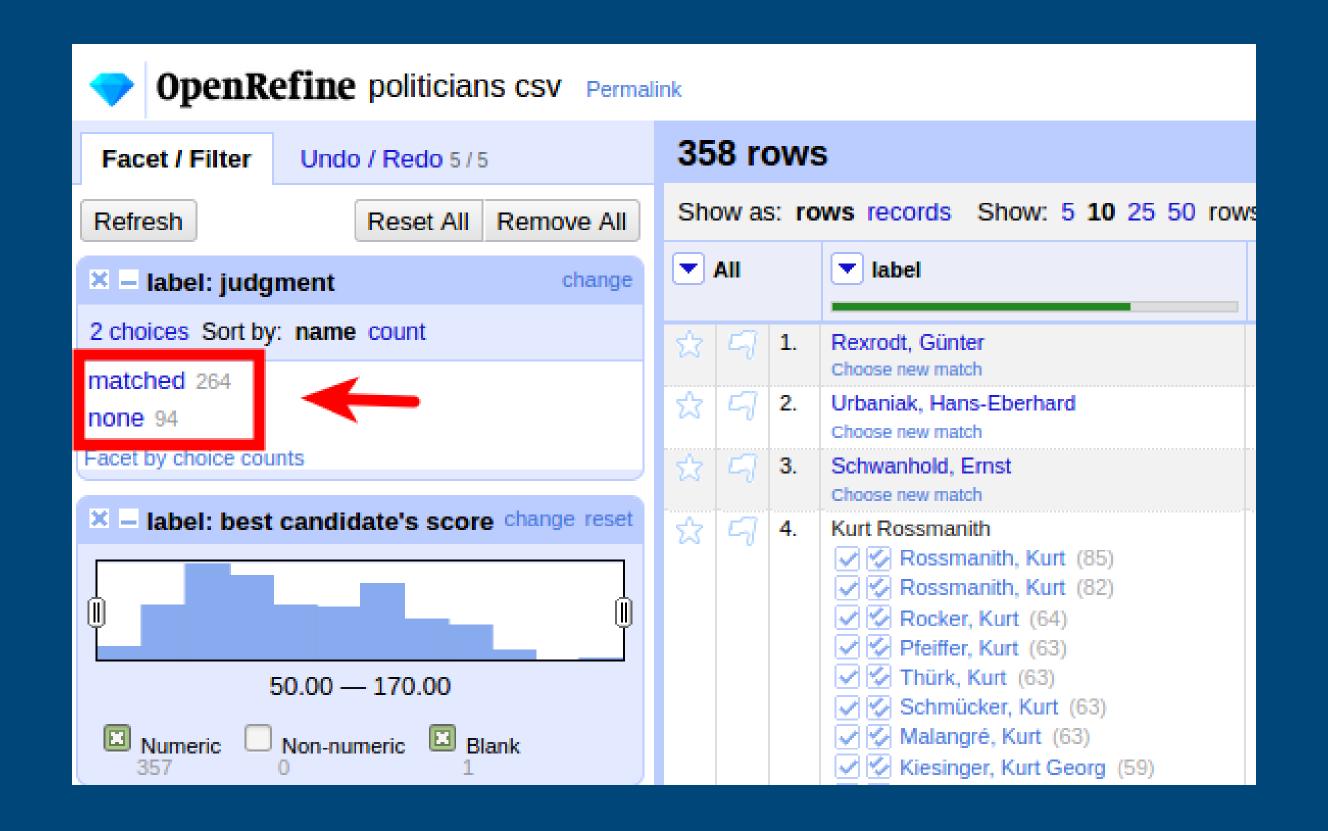
Operationen können angepasst und reproduziert werden:











Zwischenergebnis: ca. 70% automatisch abgeglichen

203

Implizites Wissen nutzen

Implizites Wissen nutzen

Hintergrundwissen, das so gar nicht in den Daten ist

Implizites Wissen nutzen

Hintergrundwissen, das so gar nicht in den Daten ist

Formal ergänzen für die Disambiguierung

Implizites Wissen nutzen

Hintergrundwissen, das so gar nicht in den Daten ist

Formal ergänzen für die Disambiguierung

Hier z.B. wissen wir, dass es sich um Politiker:innen handelt

D.h. wir ergänzen eine neue Spalte mit dem Beruf

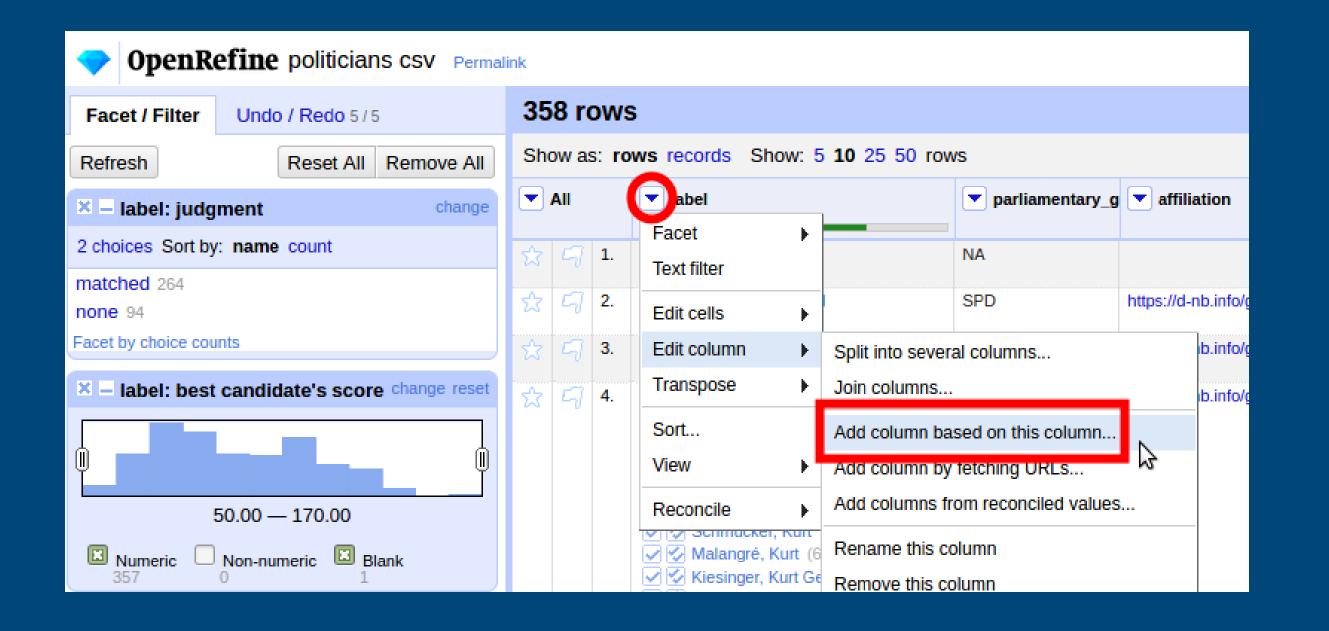
D.h. wir ergänzen eine neue Spalte mit dem Beruf

Mit dem Wert Politik*

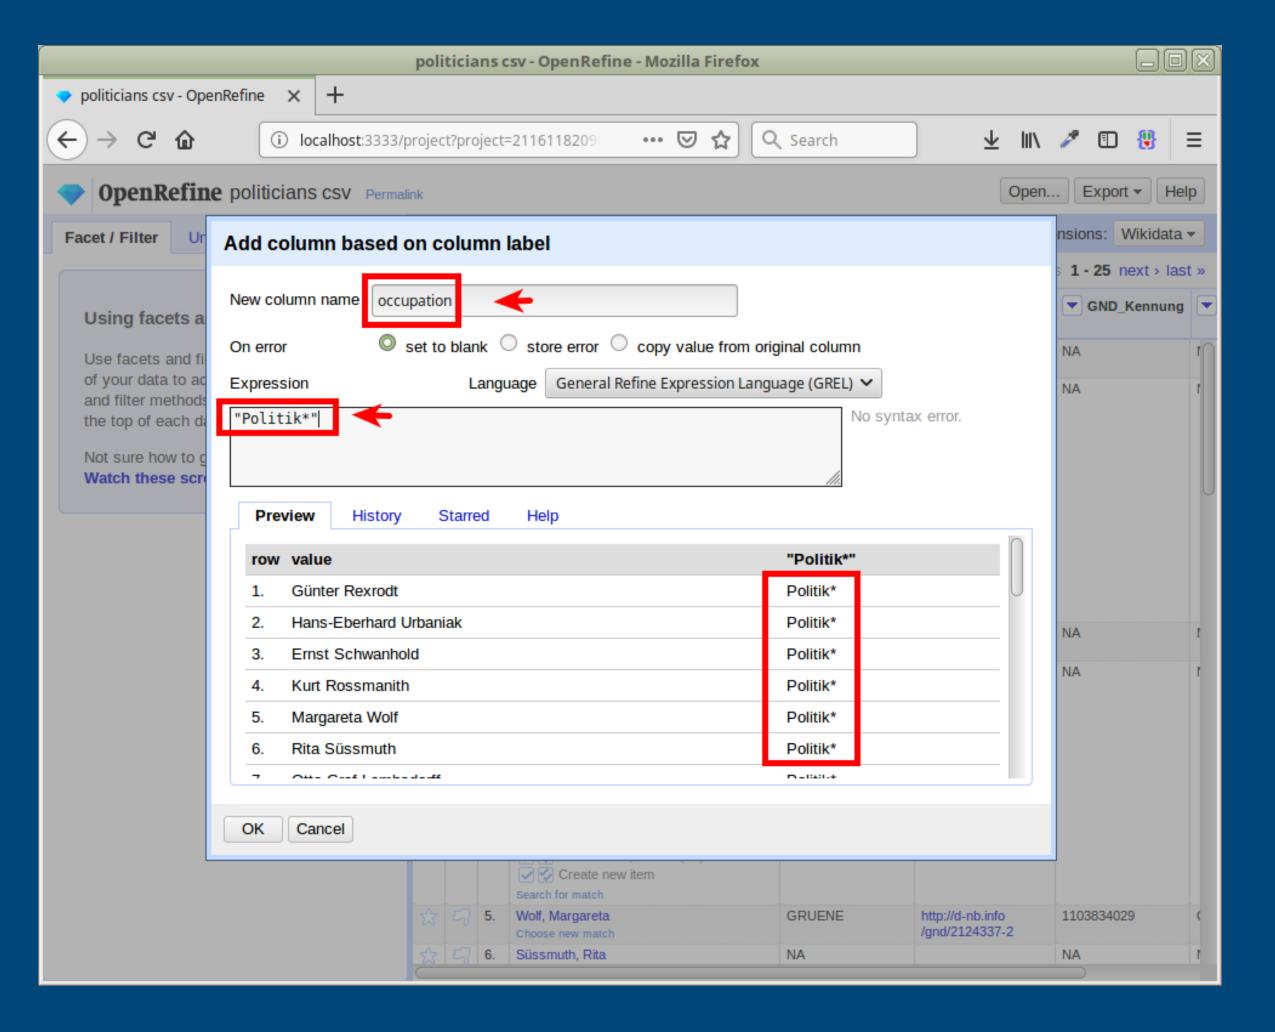
D.h. wir ergänzen eine neue Spalte mit dem Beruf

Mit dem Wert Politik*

Über die Wildcard decken wir mehrere Formen ab: Politiker, Politikerin, Politikwissenschaftler, Politikwissenschaftlerin



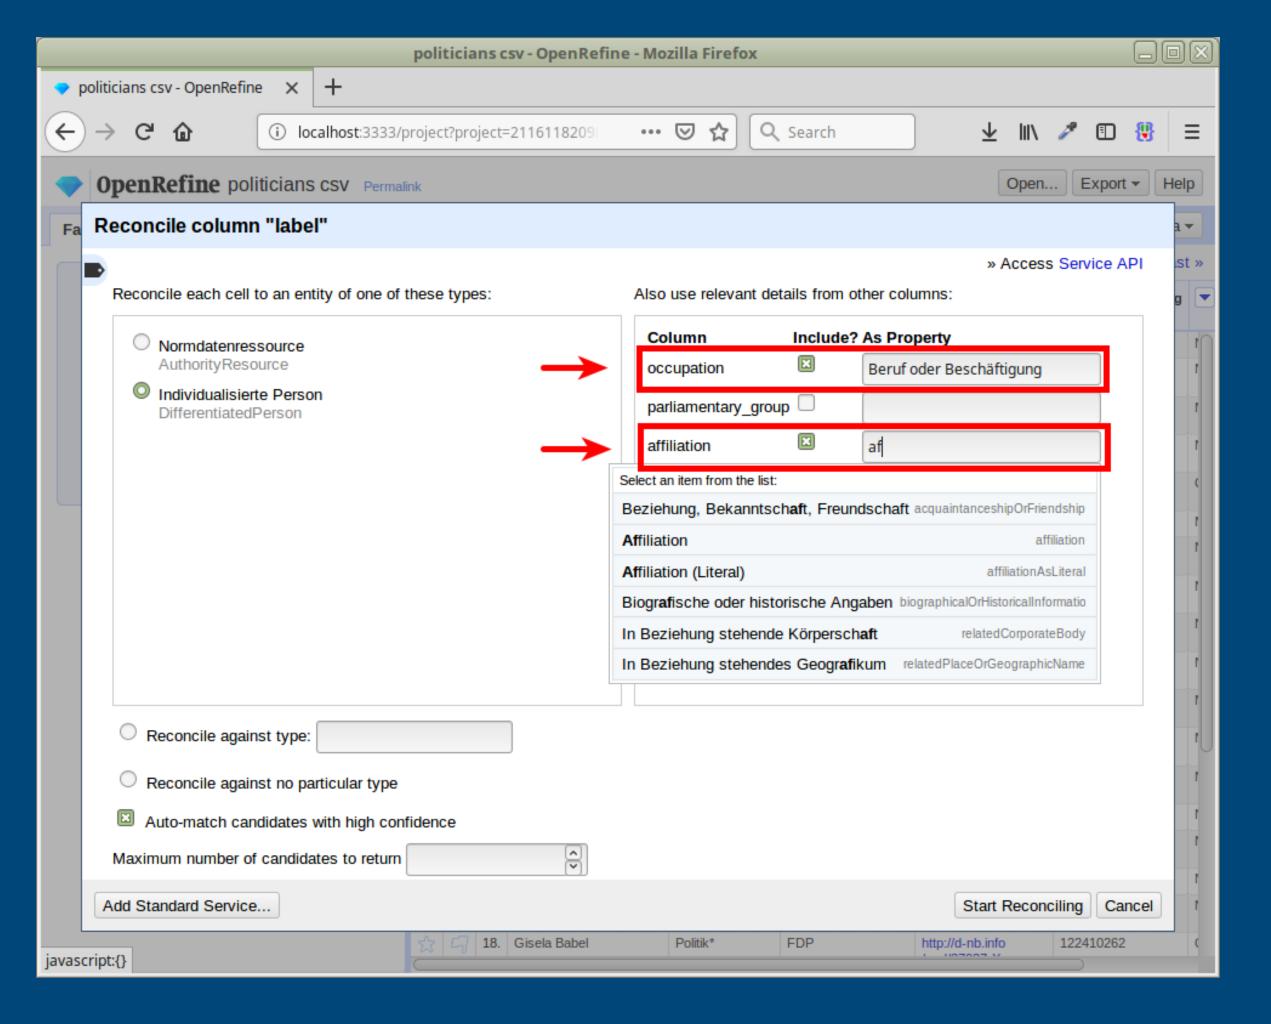
For the control of th

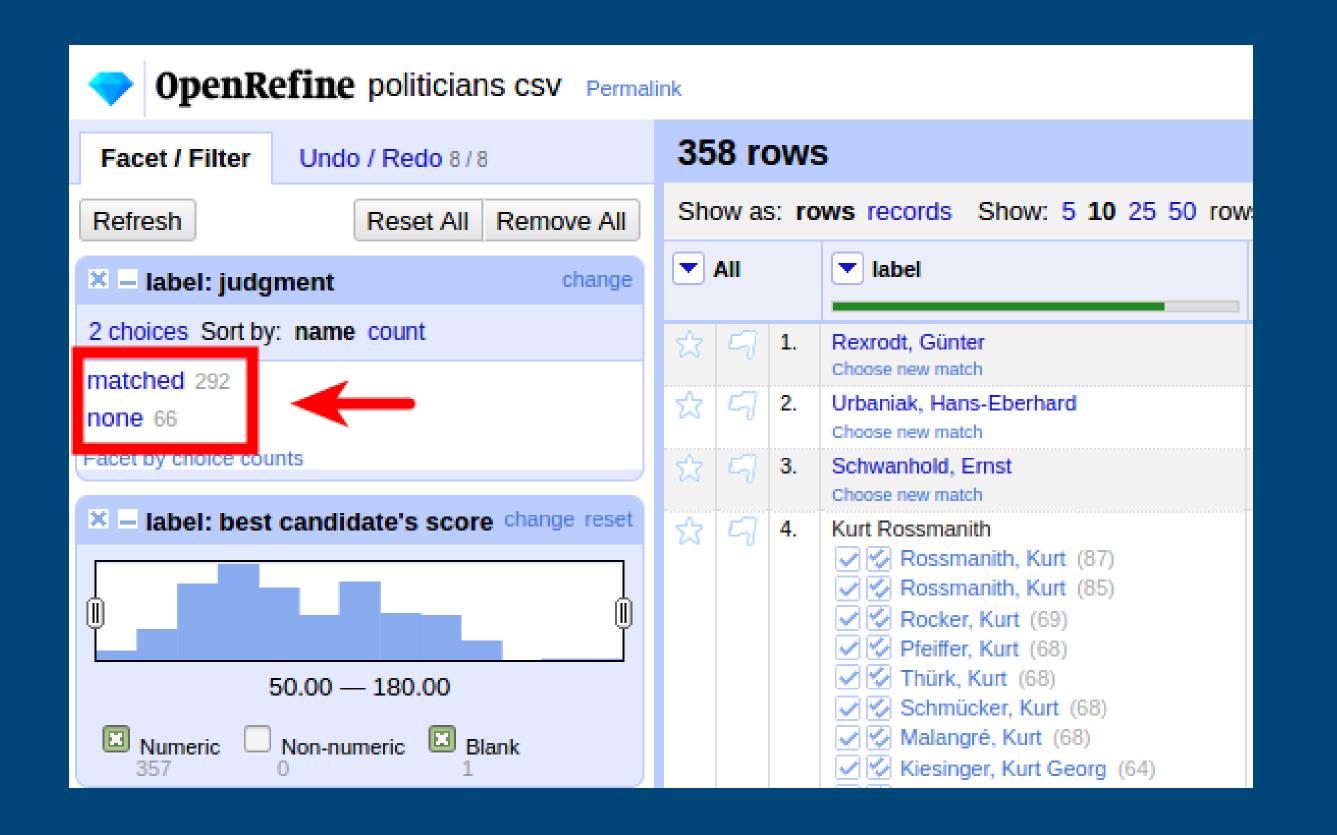


Vorherigen Abgleich zurücksetzen

Vorherigen Abgleich zurücksetzen

Beruf & Affiliation mitschicken





ca. 80% automatisch abgeglichen

210

Export und mehr

Export und mehr

Fertige Daten können flexibel exportiert werden

Export und mehr

Fertige Daten können flexibel exportiert werden

https://lobid.org/gnd/reconcile

Weiterführende Informationen – Rund um lobid und Linked Data

- lobid-Blog, Präsentationsfolien, lobid auf Twitter und Mastodon
- Kreutzer, Till (2011): Open Data Freigabe von Daten aus Bibliothekskatalogen. Hg. v. Hochschulbibliothekszentrum des Landes Nordrhein-Westfalen (PDF)
- Pohl, Adrian / Steeg, Fabian / Christoph, Pascal (2018): lobid –
 Dateninfrastruktur für Bibliotheken. In: Informationspraxis 4(1).
 https://doi.org/10.11588/ip.2018.1.52445
- Steeg, Fabian / Pohl, Adrian / Christoph, Pascal (2019): lobid-gnd Eine Schnittstelle zur Gemeinsamen Normdatei für Mensch und Maschine. In: Informationspraxis 5(1). https://doi.org/10.11588/ip.2019.1.52673
- Steeg, Fabian / Pohl, Adrian (2021): Ein Protokoll für den Datenabgleich im Web am Beispiel von OpenRefine und der Gemeinsamen Normdatei (GND). In: Qualität in der Inhaltserschließung. https://doi.org/10.1515/9783110691597-013

Weiterführende Informationen – Nutzung von lobid-gnd

- Stefan Dumont (2018): correspSearch: Neue Tools, neue Daten und eine Auszeichnung https://dhd-blog.org/?p=10632
- Harald Lordick (2019): Die Öffnung der GND und die historische Forschung https://djqd.hypotheses.org/1511
- Pascal Becker (2021): Integration der gemeinsamen Normdatei in DSpace auf Basis von lobid (Vortragsfolien)
- Blogbeiträge mit lobid-gnd-Bezug des FDMLab am Landesarchiv Baden-Württemberg (2021 ff) https://fdmlab.landesarchiv-bw.de/tag/lobid/
- Michael Markert (2023): Abgleich 'unsauberer' Ortsnamen mit der GND in OpenRefine (Videotutorial), inklusive Clustering und unscharfer Suche mit alten Schreibweisen https://www.youtube.com/watch?v=tCdluPq5GkA