

# Deutsches DSpace-User-Group-Meeting 2016

DSpace im Repository-Netzwerk  
Schnittstellen, Zertifikate, Guidelines,  
Metadatenqualität

Friedrich Summann

Universitätsbibliothek Bielefeld

# **BASE** = Bielefeld Academic Search Engine [www.base-search.net](http://www.base-search.net)

- Wissenschaftliche Suchmaschine
- Wiss. Inhalte bereitgestellt von Repositorien via OAI-PMH (OAI Service Provider)
- Konzeption und Entwicklung ab 2001

## Heute:

- Mehr als 4680 Quellen
- Mehr als 99 Mill. Dokumente/Objekte

# BASE heute: OAI Service Provider und Spiegelbild der Repository Landschaft

- 4688 Repositorien (via OAI-PMH)
- Aus 111 Ländern weltweit
- Ca. 99 Mill. Dokumente/Objekte
- Ca. 70 % Open Access
- Dublin Core Format
- Ca. 14.7 Mill. Dokumente mit  
angereichertem DDC-Code (Dewey)

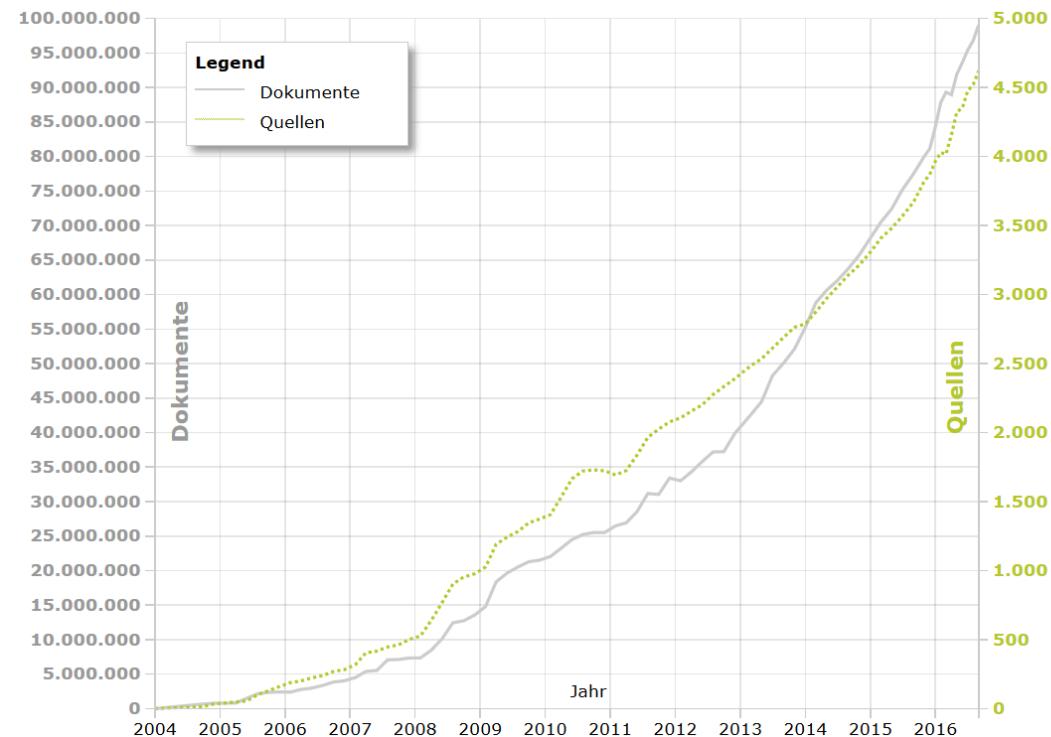
# Some BASE Milestones

- 2001 Starting point as a search engine follow-up for a metasearch system
- 2004 Official Start (FAST Data Search)
- 2006 starting participation in EU projects, HTTP Interface
- 2011 Switch to open source (Lucene/Solr, VuFind)
- 2012 OAI-PMH-Interface, data delivery of subject sections
- 2014 OA-boosting
- 2015 OA status and License information processing

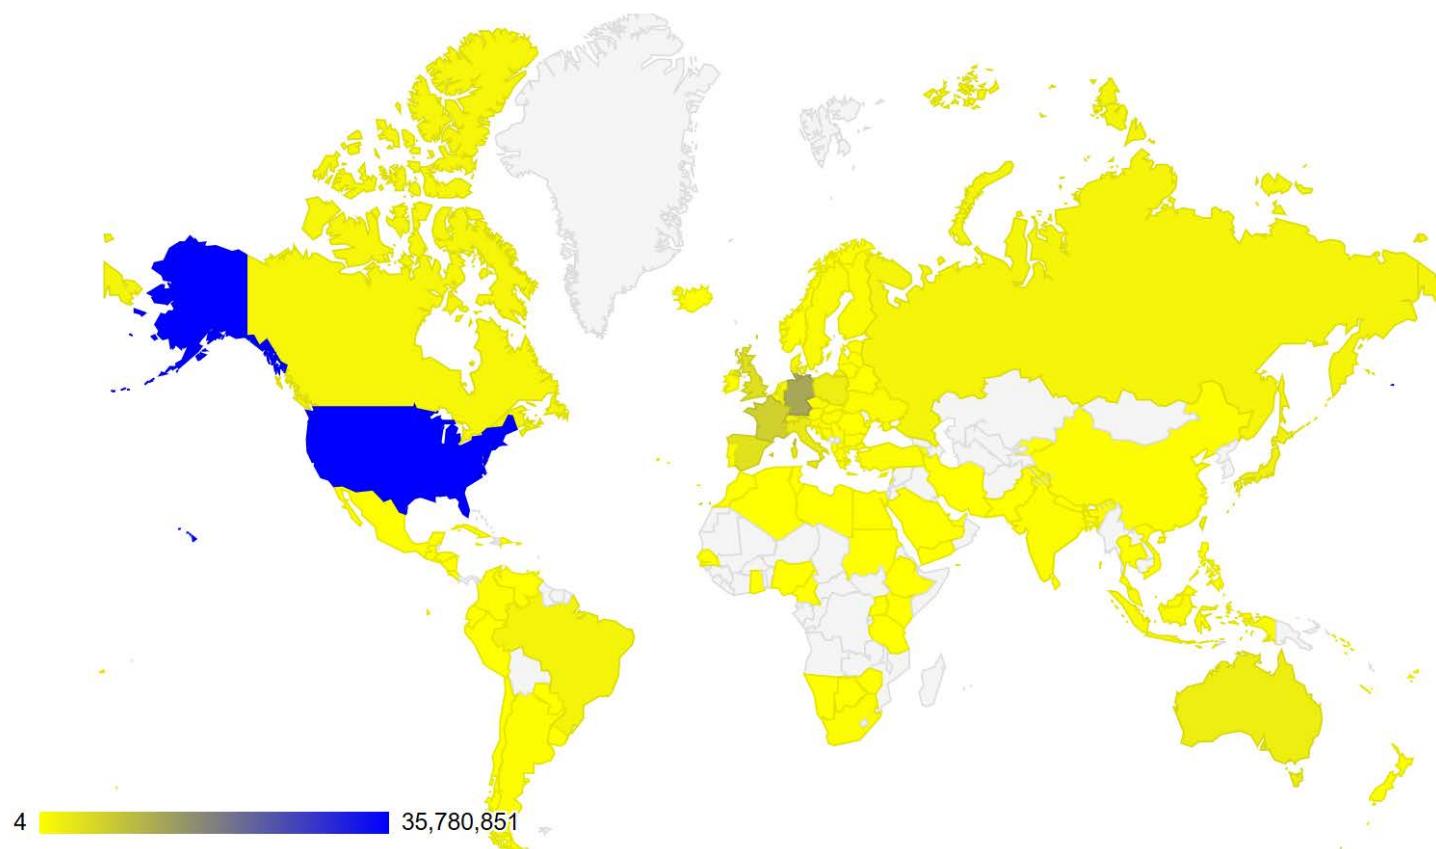
## Über BASE: Statistik

Entwicklung der Zahl der von BASE indexierten Quellen und Dokumente seit September 2004.

**Diagramm: Zahl der indexierten Dokumente und Quellen in BASE**



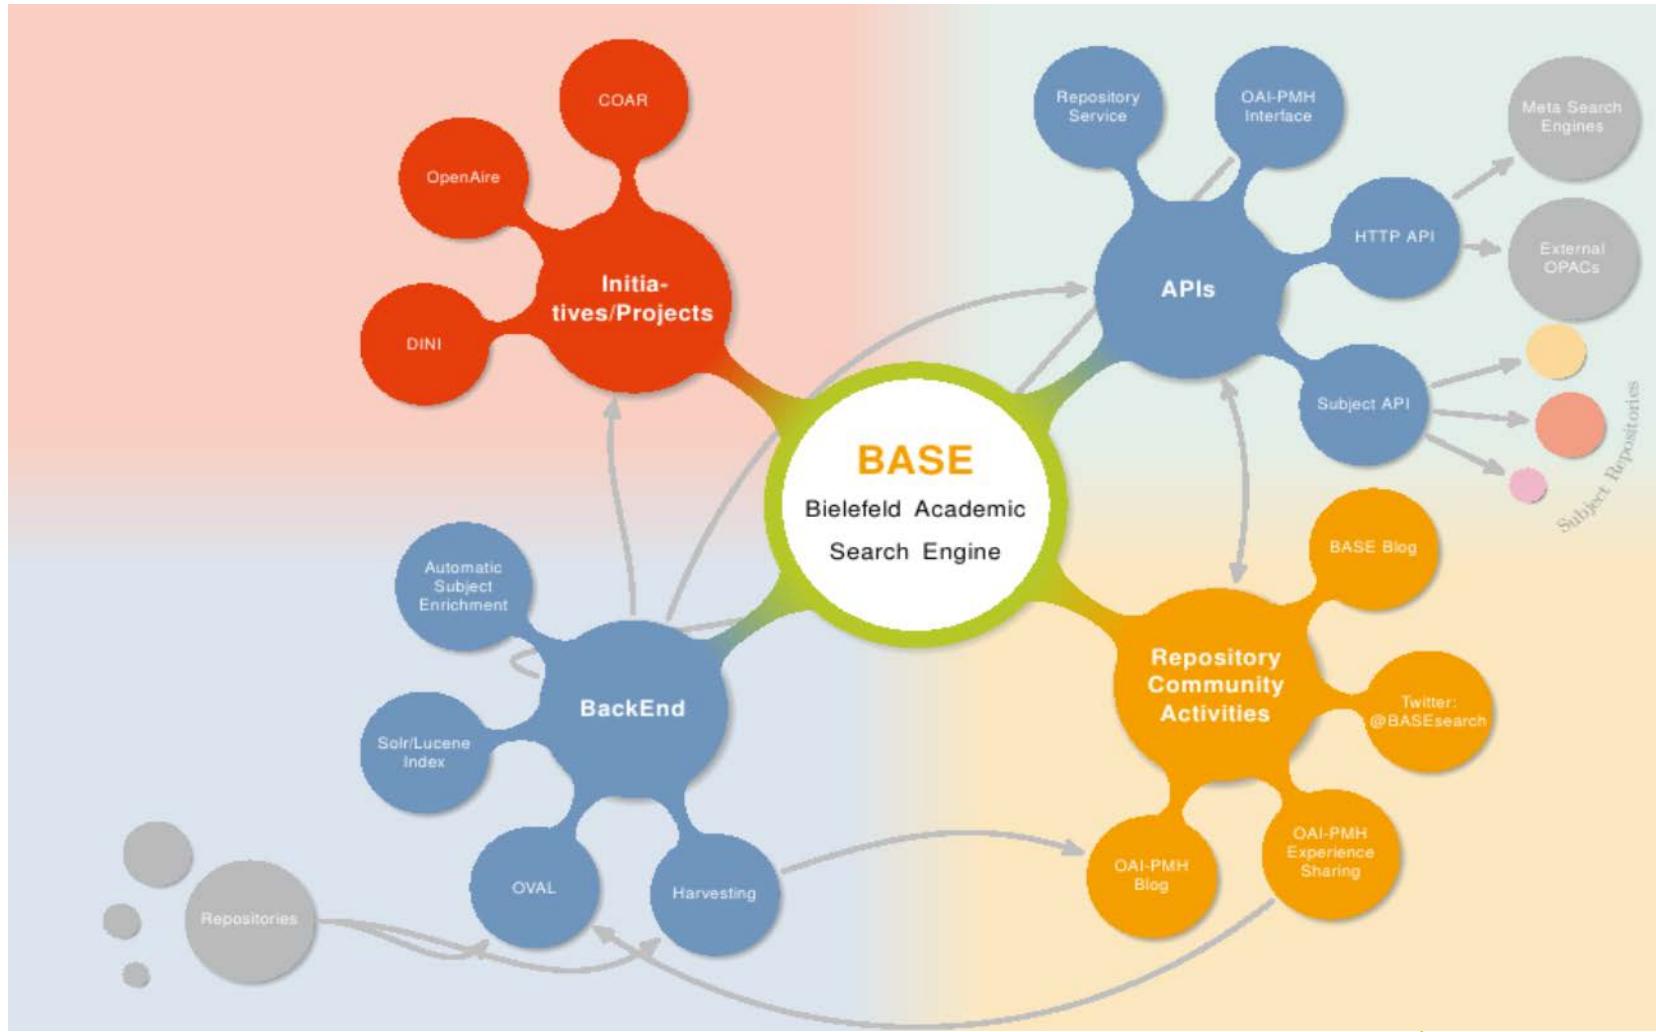
## Anzahl der Dokumente in BASE nach Ländern



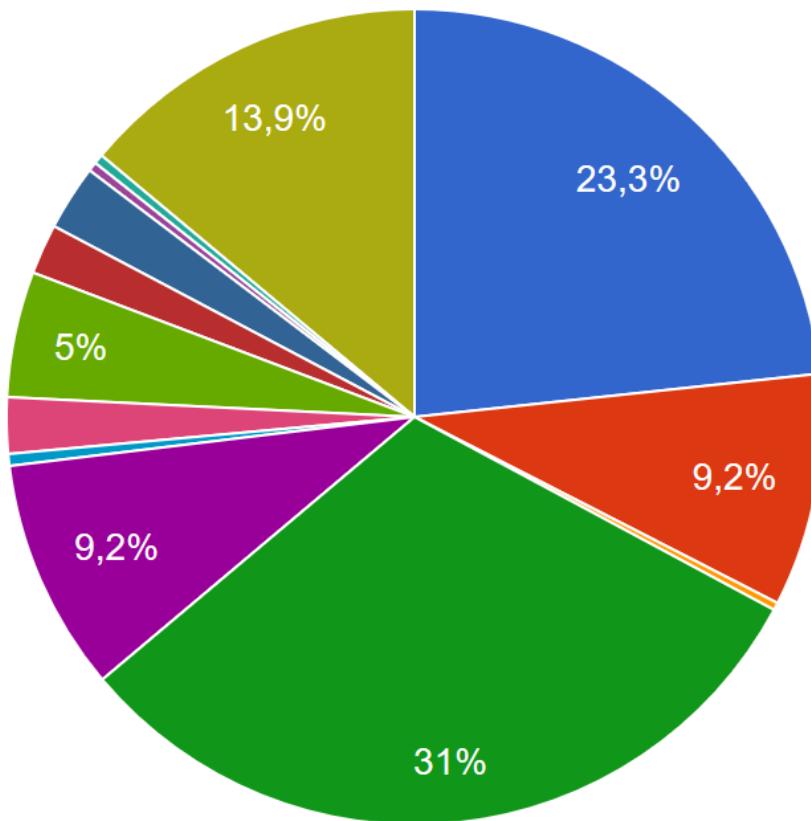
## Der BASE Focus

- OA Repositorien (global)
- Wissenschaftliche Inhalte
- Schwerpunkt Institutionelle Repositorien
- Aggregatoren (RePEc etc)
- Subject Repositories (arXiv, CiteSeerX etc)
- Electronic Journals (DOAJ, OJS-Installationen)
- Digitale Sammlungen
- Forschungsdaten-Repositorien

# BASE im Wissenschaftlichen Netzwerk



## Verteilung DSpace weltweit - Anzahl der Installationen



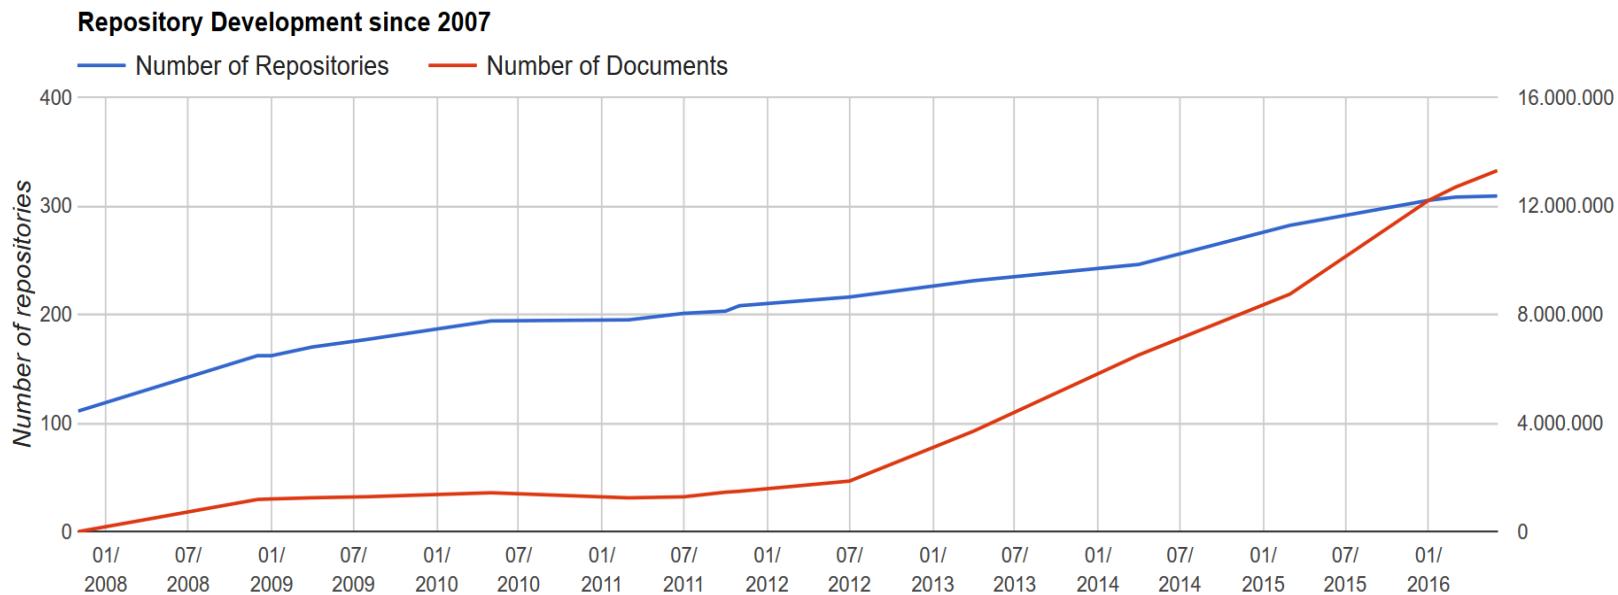
Eprints 432  
Dspace 1090  
DigitalCommons 431  
ContentDM 121  
Fedora 22  
Opus 104  
Digitool 11  
WEKO 233  
HAL 93  
OJS 1451  
Pure 18  
Invenio 14  
Greenstone 17  
Andere 651



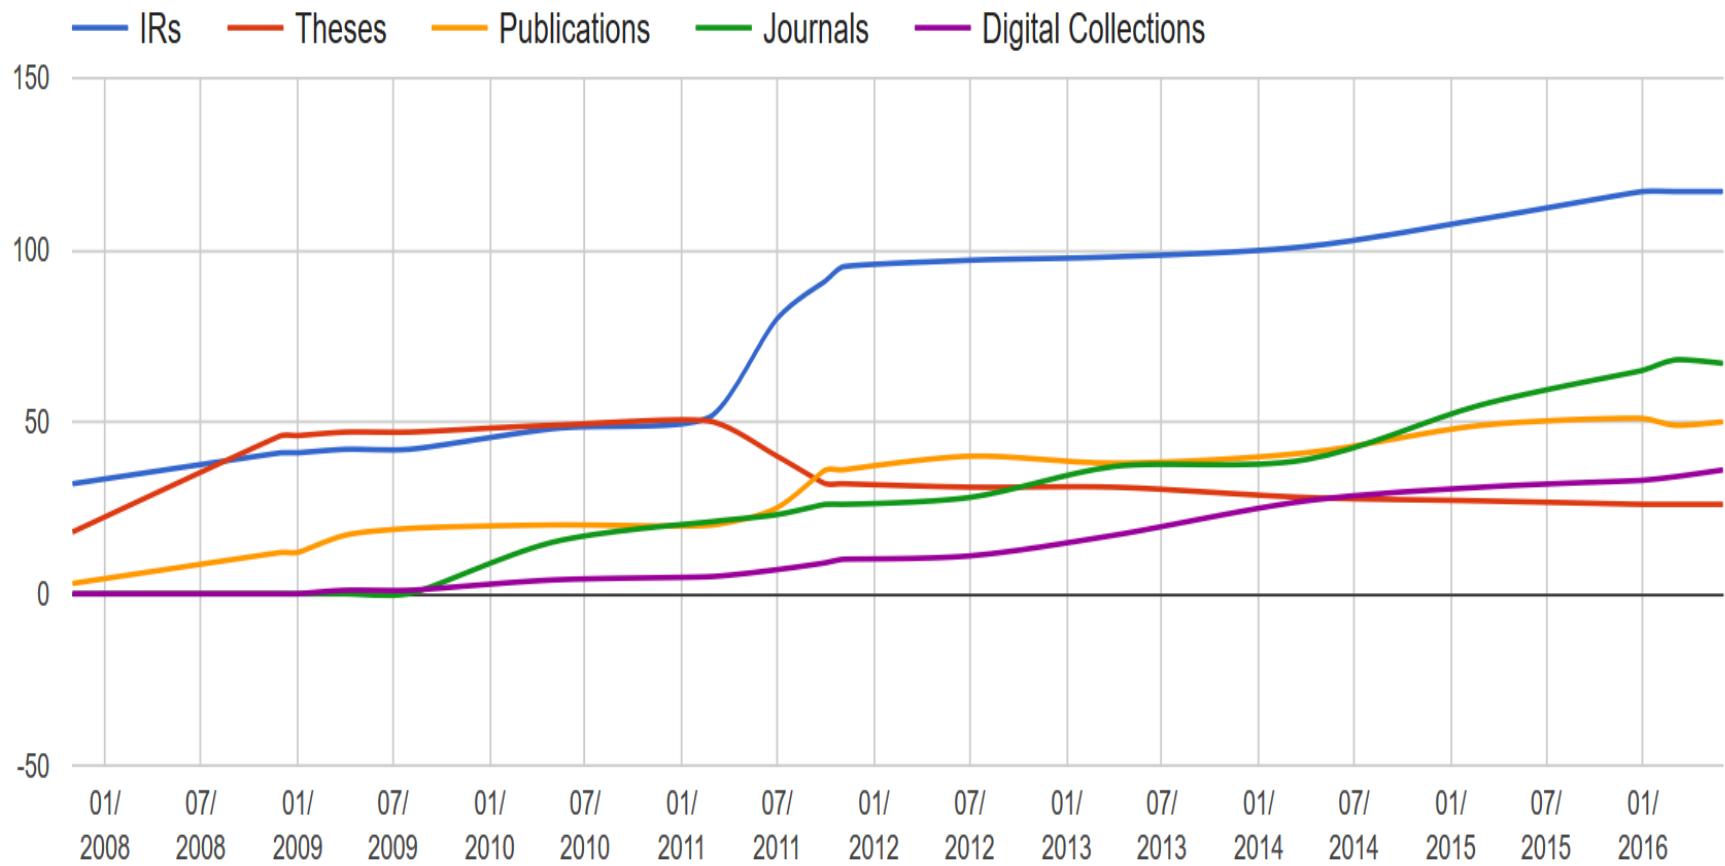
# Germany

**11853051 Documents from 309 Repositories**

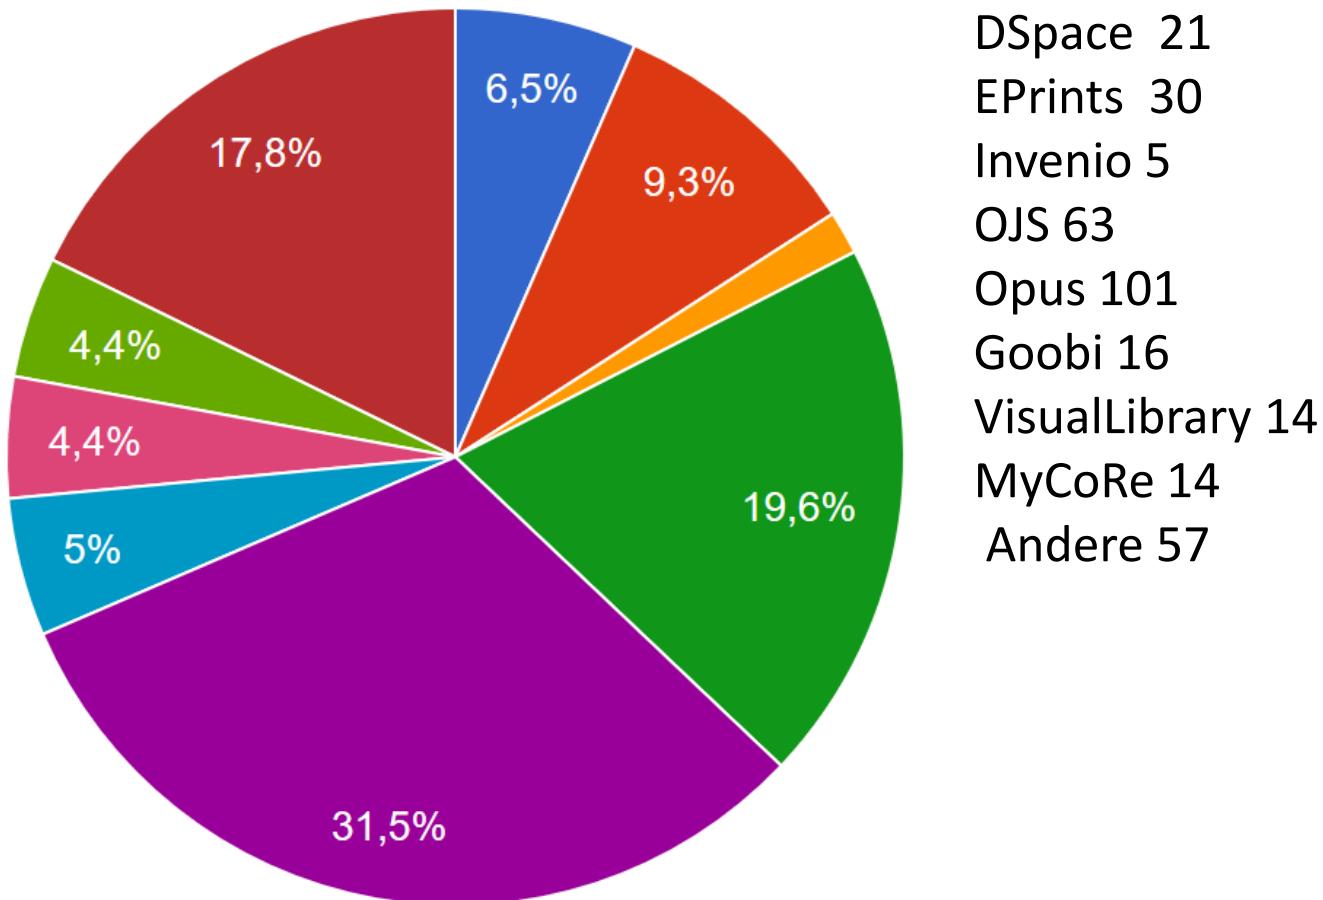
This means: **12.59 %** of Documents world-wide, **7.10 %** of Repositories world-wide



## Repository Type Development since 2007 (Number of Repositories)



## Verteilung DSpace in DE - Anzahl der Installationen



# DSP

About D

## DSpace

Check out  
repository

Search th



### Filter By Country:

- [united states \(294\)](#)
- [india \(157\)](#)
- [spain \(105\)](#)
- [japan \(101\)](#)
- [brazil \(91\)](#)
- [turkey \(86\)](#)
- [ukraine \(67\)](#)
- [united kingdom \(65\)](#)
- [taiwan \(63\)](#)
- [italy \(62\)](#)
- [norway \(54\)](#)
- [portugal \(50\)](#)
- [colombia \(49\)](#)
- [canada \(47\)](#)
- [germany \(32\)](#)
- [peru \(29\)](#)
- [australia \(28\)](#)
- [mexico \(28\)](#)



### Filter By Dspace Version:

- [Unknown \(334\)](#)
- [5.x \(145\)](#)
- [4.x \(328\)](#)
- [3.x \(251\)](#)
- [1.8.x \(181\)](#)
- [1.7.x \(214\)](#)
- [1.6.x \(153\)](#)
- [1.5.x \(117\)](#)
- [1.4.x \(89\)](#)
- [1.3.x and earlier \(40\)](#)

# The 10 Biggest Misunderstandings around OAI-PMH

- OAI-PMH means ‚Everything is Open Access‘
- Persistent Identifiers are persistent
- Link to the Document page is not necessary
- Configuration is not needed
- Checking the Service is needless
- DublinCore is simple but sufficient
- OpenAccess Status Information is needless
- End-User Interface is not necessary
- Personal Sys Admin Email Address is not needed
- Incremental Harvesting is sufficient

# Main Issues to Avoid

- Wrong Document URLs  
(a specific Dspace problem with non-configured links as  
`<dc:identifier>http://hdl.handle.net/123456789/87639</dc:identifier>`)
- Empty Records
- Invalid XML delivered
- Crashing Harvest Processes
- Changing OAI-PMH basicurls without  
dissemination/redirect

# Main Issues Preferred

- OA Status delivered (on repository or document level)
- Metadata Guidelines compatible
  - Vocabularies used (for type, language, date, classification etc.)
- English end-user interface (in parallel)
- Citation/Abstract information delivered
- Available repository contact information
- Visible in Registries (OpenDOAR, openarchives ...)

# DSpace aus BASE-Sicht

## Positives

- Stabil, robust, valide, weit verbreitet
- Hohe Metadatenqualität
- CRIS-Erweiterung

## Verbesserungsoptionen

- Kontakt zur Entwickler-Community
- OAI-PMH (korrekt) konfigurieren
- ORCID-Unterstützung
- Vokabular OA-Status
- Vokabular für Lizenzen
- Internationale Sichtbarkeit
- Volltextlink

# DSpace OAI-PMH issues (1)

- \* In many cases the persistent identifiers are not configured at all.

```
<dc:identifier>http://hdl.handle.net/123456789  
/3</dc:identifier>
```

- \* a certain local identifier is configured but it is not registered at the handle system

- \* Identifier links are mixed (some wrong, some ok)

# DSpace OAI-PMH issues (2)

- \* **local url format is not correct** (containing some additional strings as xmlui for example)
- \* **Admin email address often unconfigured.**
- \* **No response from the feedback form**
- \* **Harvesting crashes**
- \* **A really often occurring problem is that the basicurl has lost the port number (mostly 8080) in the OAI basicurl**
- \* **Instead of UTF-8 characters the OAI-PMH interface delivers question marks**

# Lyncode XOA problems

- \* *No records* message while the repository has contents
- \* Links in the Lyncode navigational bar are different with the starting basicurl and do not work!
- \* Incremental harvesting fails when using the day granularity in from parameter

## Aktuelle BASE-Umsetzungen

Verbesserung Normalisierung OA-Status

Verbesserung Normalisierung Lizenzbedingungen

Verbesserung Normalisierung Publikationstypen

# Issue: OA Status, Rights and Licences

## Normalization

SUBGoettinger		ceu	181	Scan	<a href="#">5x http://creativecommons.org/licenses/by-sa/3.0</a> <a href="#">5x http://creativecommons.org/licenses/by-nc/2.5/</a> <a href="#">5x http://creativecommons.org/licenses/by-nc/2.0/</a> <a href="#">4x http://goedoc.uni-goettingen.de</a> <a href="#">4x info:eu-repo/semantics/http://creativecommons.org/licenses/by-nd/3.0/de/</a> <a href="#">4x https://creativecommons.org/licenses/by/4.0</a> <a href="#">4x http://creativecommons.org/licenses/by/2.0/uk/legalcode</a> <a href="#">4x http://creativecommons.org/licenses/by-nc-nd/3.0/deed.de</a>
---------------	---	-----	-----	------	--

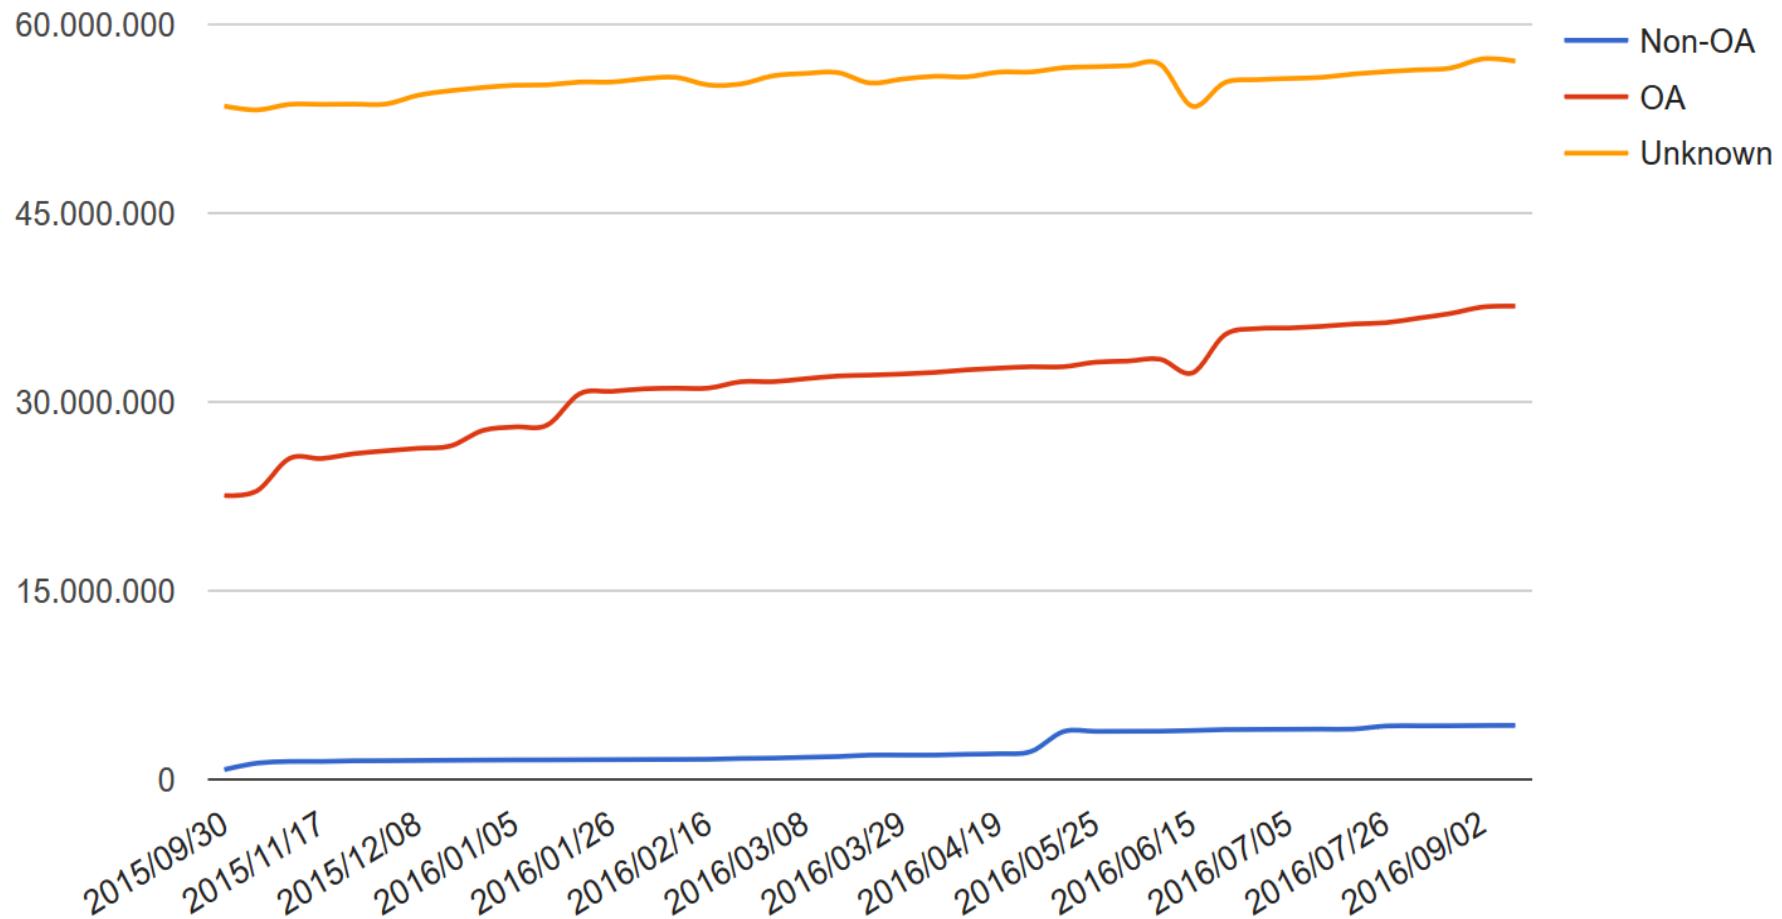
### Nachnutzung/Lizenzen

 Alle Creative Commons CC-BY  
 CC-BY-SA CC-BY-ND  
 CC-BY-NC CC-BY-NC-SA  
 CC-BY-NC-ND Public Domain CC0 Public Domain Mark (PDM)

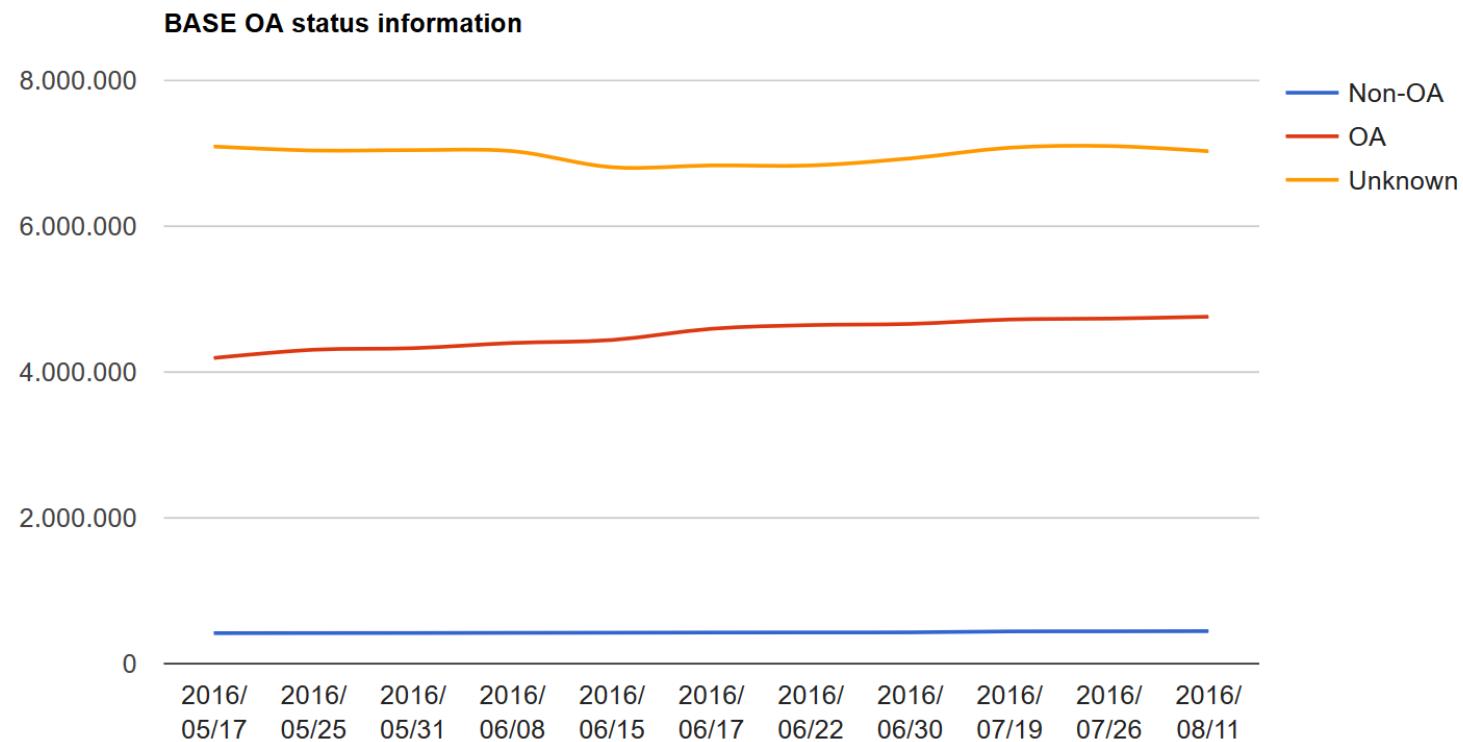
### Zugang

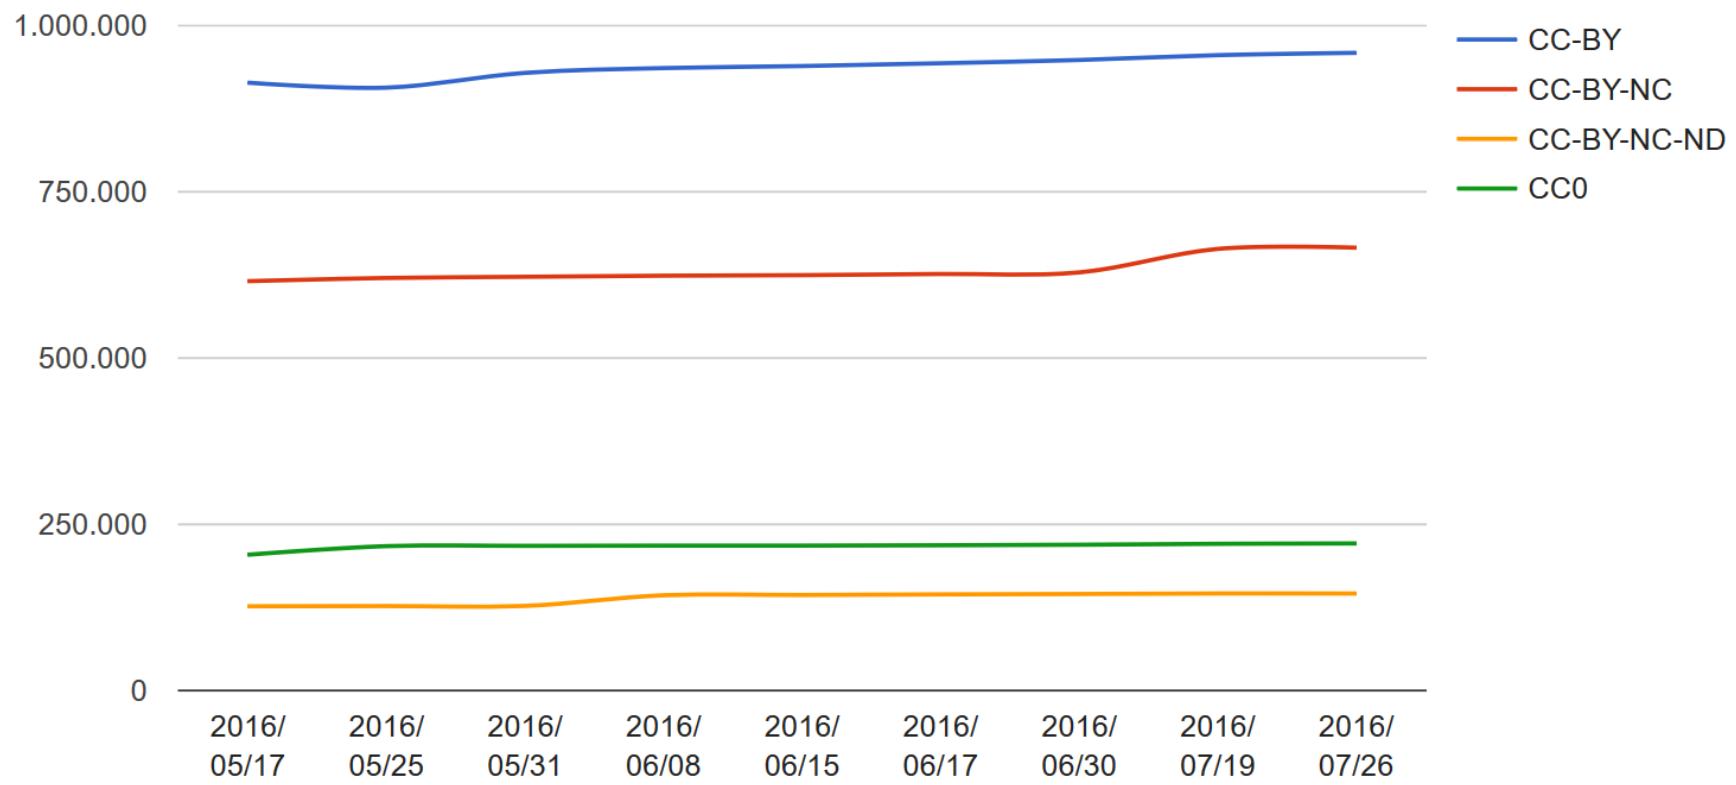
 Open Access Kein Open Access Unbekannt

2x [http://creativecommons.org/licenses/by-nc-nd/3.0/at/](#)  
2x [http://creativecommons.org/licenses/by/2.0](#)  
2x [http://creativecommons.org/licenses/by-sa/3.0/de/](#)

**BASE OA status information**

## OA status and licence Information Germany



**BASE License information Part 1**

## Dokumentart

### Alle Dokumentarten

#### Text

- Buch
- Teil eines Buches
- Zeitschrift/Zeitung
- Artikel in einer Zeitschrift/Zeitung
- Anderer Beitrag in einer Zeitschrift/Zeitung

- Konferenzveröffentlichung
- Bericht
- Review
- Lehrmaterial
- Vortrag
- Manuskript
- Patent

#### Abschlussarbeit

- Bachelorarbeit
- Masterarbeit
- Dissertation und postgraduale Arbeiten

#### Noten (Musik)

- Karte
- Audio

#### Bild/Video

- Einzelbild
- Animation/Video

#### Software

- Forschungsdaten
- Unbekannt

## Aktuelle Entwicklungen

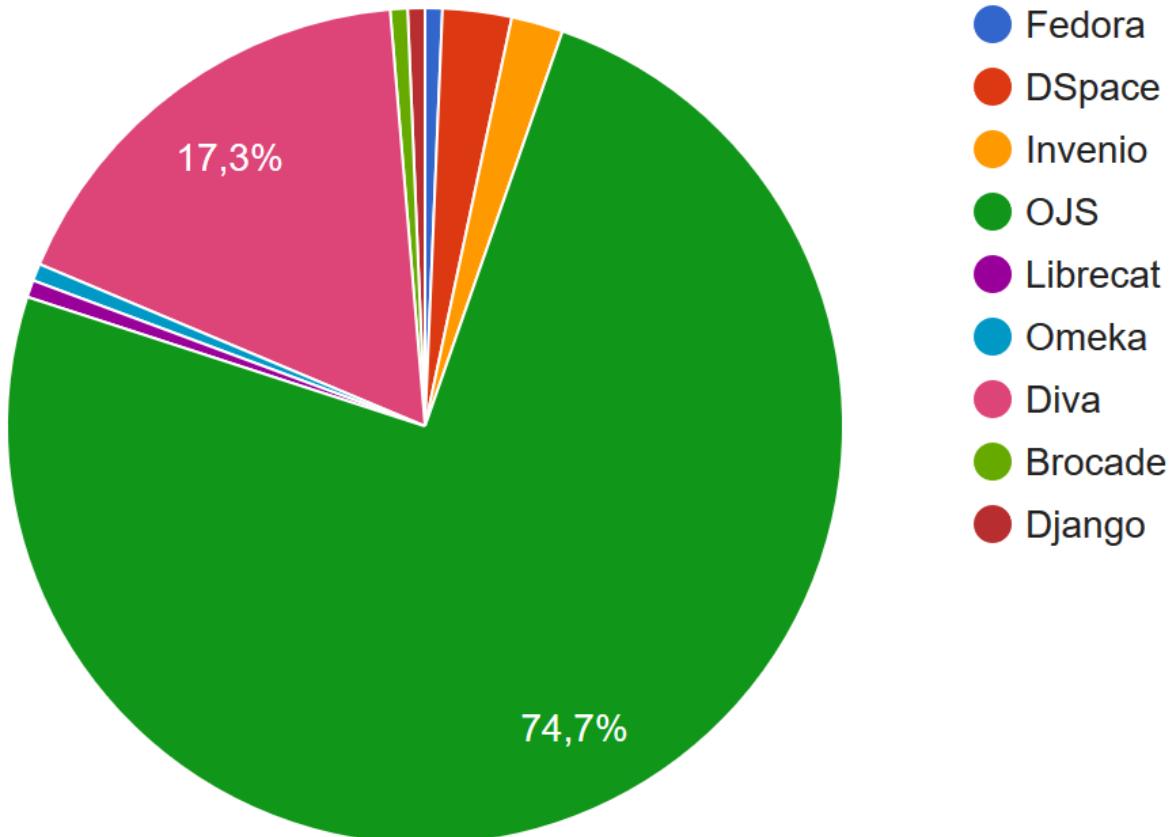
Implementierung eines ORCID-Claiming-Services im Rahmen von ORCID.DE

Auswertung und Analyse von alternativen Metadaten-Formaten jenseits von oai\_dc

Integration von (Open-Access-)Inhalten aus CrossRef

Verbesserung der Registry-Informationen  
(Auswertungen zu Repositories und Ländern)

## Autorenidentifikatoren - Verteilung Repository-Systeme mit ORCID-IDs

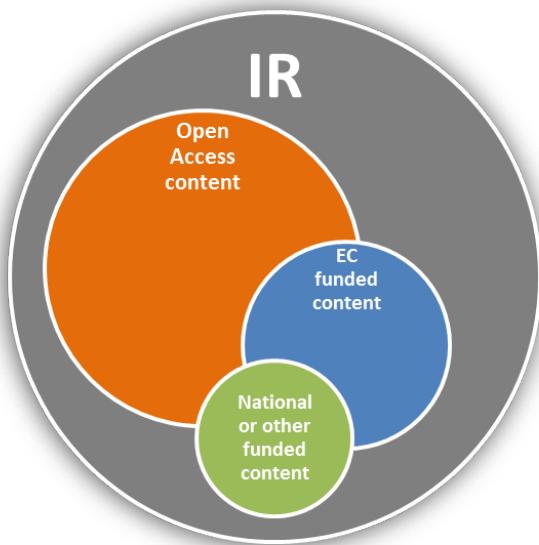


# Es geht um Metadatenqualität!

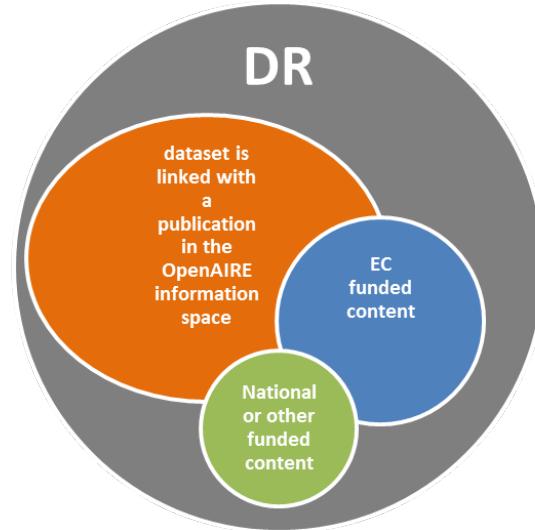
- DRIVER Guidelines
- DINI Zertifikat
- OpenAire Guidelines
- COAR Vocabularies

# OpenAIRE Content Acquisition

## Publications



## Research Data



- Repository registriert in OpenDOAR
- OpenAIRE Literature Guidelines v3
- Repository registriert in re3data
- OpenAIRE Data Archive Guidelines v2



# Schnittstellen in OpenAIRE

- Repository-Validierung und Registrierung über
  - <https://www.openaire.eu/validator/welcome>
- Aggregation und Indexierung i.d.R. wöchentlich
- Auffindbarkeit der aggregierten Quelle über
  - <https://www.openaire.eu/search/data-providers>
- OpenAIRE exponiert (ggf. angereicherte) Metadaten über
  - <http://api.openaire.eu/>
  - Unter Verwendung von OAI-PMH bzw. REST-API
  - EU-Projektinformation bereitgestellt für u.a. DSpace
    - [http://api.openaire.eu/#cha\\_projects\\_http](http://api.openaire.eu/#cha_projects_http)

# Unterstützung für DSpace Publikationen

- Allg. OpenAIRE Literature Guidelines v3
  - <https://guidelines.openaire.eu/en/latest/literature/index.html>
  - Metadata-Format “oai\_dc”
  - Empfohlenes OAI-Set “openaire”
- Implementiert / unterstützt in DSpace 5.x
  - Wichtig: separater XOAI-Context für OpenAIRE:
    - <http://www.example.com/oai/openaire>
    - Exponiert OA + funded Records
- Allg. OpenAIRE Data Archive Manager Guidelines v2
  - Metadata-Format “oai\_datacite”
  - Empfohlenes OAI-Set “openaire\_data”

# Unterstützung für DSpace Forschungsdaten

- Allg. OpenAIRE Data Archive Manager Guidelines v2
  - <https://guidelines.openaire.eu/en/latest/data/index.html>
  - Metadata-Format “oai\_datacite”
  - Empfohlenes OAI-Set “openaire\_data”
- Implementierungsbeispiel Lindat-CLARIN DSpace Repository
  - <https://github.com/ufal/lindat-dspace/wiki/OpenAIRE>



# Deutsche Dspace Repositories in OpenAIRE

- OPARU (Universität Ulm)
- GoeScholar (Georg-August-Universität Göttingen)
- TOBIAS-lib (Universität Tübingen)
- Social Science Open Access Repository (SSOAR)
- RepOSitorium (Universität Osnabrück)
- KOPS (Konstanzer Online-Publikations-System)
- Open Access Repository der TUHH (TUBdok)
- res doctae (Akademie der Wissenschaften zu Göttingen)
- DSpace an der Universität Kassel (KOBRA)
- EconStor (ZBW)
- Eldorado (Dortmund)
- Helmholtz Zentrum für Infektionsforschung Repository
- DepositOnce (TU-Berlin)

# Vielen Dank für Ihre Aufmerksamkeit!

[friedrich.summann@uni-bielefeld.de](mailto:friedrich.summann@uni-bielefeld.de)

**base-search.net**

follow us: **@BASEsearch**