

Linked Open Citation Database

Enabling Libraries to Contribute to an Open
and Interconnected Citation Graph

**Anne Lauscher, Kai Eckert, Lukas Galke, Ansgar Scherp, Szed Tahseen Raya Riyva,
Sheraz Ahmed, Andreas Dengel, Philipp Zumstein, Annette Klein**
JCDL, 2018
Fort Worth, Texas



Tiessen, Jan (2007): Die Resultate im Blick?
ner/Döhler, Marian (Hrsg.): Agencies in W
Tondorf, Karin/Bahn Müller, Reinhard/Klages,
instrument. Anwendungspraxis, Problem
sigma.
Touraine, Alain (1984): Le retour de l'acteur: e
Treiber, Hubert (1984): Warum man nicht die
Mikroskop den ganzen Elefanten zu sehen.



The origins: What were libraries cataloging?

- Everything you can put in a shelf, i.e. cataloging on the level of physical objects
- Dependent resources, e.g. journal articles, were not cataloged



Later: Resource Discovery Systems

- Combination of classical library content with large indexes of article data
- Indexes are dominantly run by commercial providers (Breeding, 2015)
- Some indexes are provided by library service centers (e.g., [K10plus-Zentral](#))



Now: Citations?

- Commercial providers often include citation data in their catalogs (I4OC)
- Fully automated approaches are still erroneous
- .. libraries?



Linked Open Citation Database

Research Question

How much would it cost, with respect to resources, if libraries catalogued everything and curated the citation graph?

Method

- Development of processes and tools based on linked data technologies to enable libraries to contribute to an open and interconnected citation graph
- Quantitative and qualitative evaluation, e.g., cost benefit analysis



Tiessen, Jan (2007): Die Resultate im Blick?
ner/Döhler, Marian (Hrsg.): Agencies in W
Tondorf, Karin/Bahnmüller, Reinhard/Klages,
instrument. Anwendungspraxis, Problem
sigma.
Touraine, Alain (1984): Le retour de l'acteur: e
Treiber, Hubert (1984): Warum man nicht die
Mikroskop den ganzen Elefanten zu sehen.
...



Agenda

1. Motivation
- 2. Data**
3. Reference Linking Workflow
4. LOC-DB Infrastructure
5. Evaluation
6. Conclusion

Data

- Social sciences collection of Mannheim University Library
- 522 print books and collections acquired by in 2011:
~271,000 references
- Articles published in 2011 in 101 (mostly electronic) journals:
~298, 000 references
- New print acquisitions of the social sciences branch library
from July 2017 on



Agenda

1. Motivation
2. Data
- 3. Reference Linking Workflow**
4. LOC-DB Infrastructure
5. Evaluation
6. Conclusion

Library Workflow

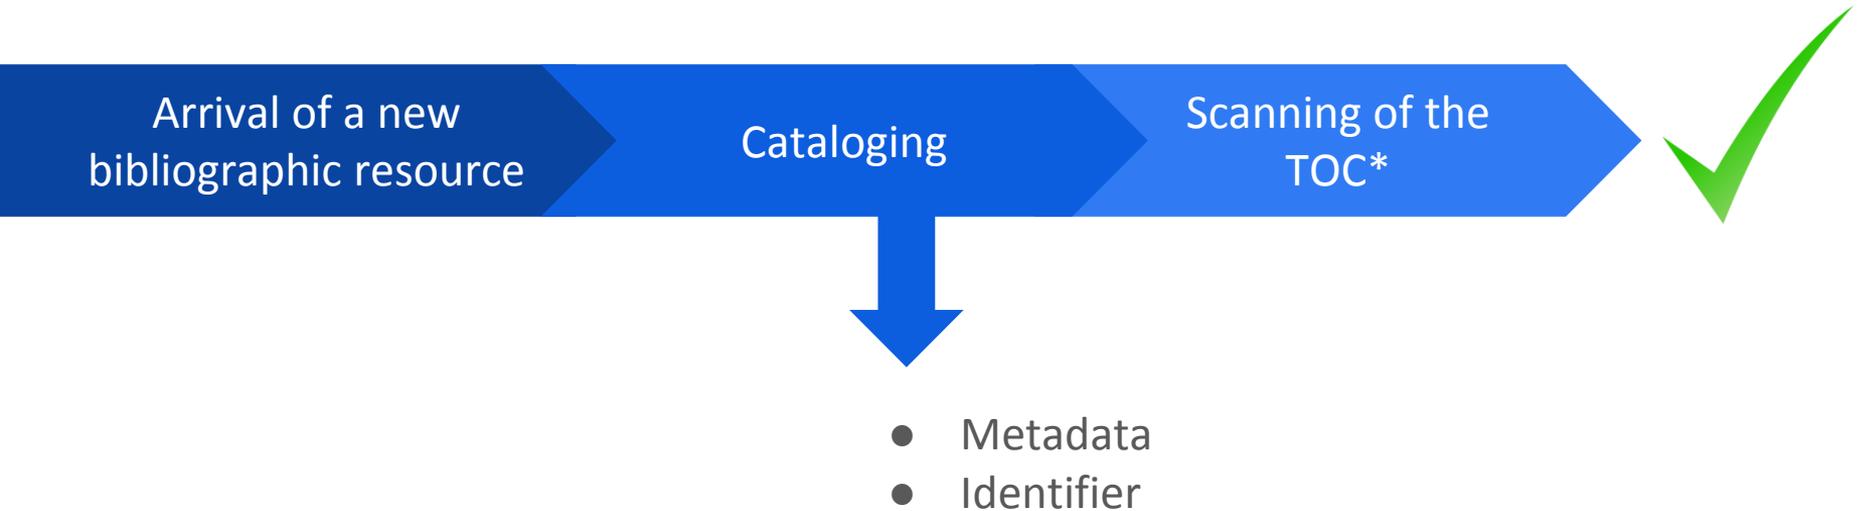
- Integrated into the standard library workflow
- Reuse of data from existing resources, e.g. from publishers, other projects, and standard library catalogs (high quality metadata)
- Automated as far as possible
 - Automatic reference extraction
 - Easy-to-use editorial system
- Distributed database
and collaborative cataloging processes

EFFICIENCY



Standard Library Workflow (UB Mannheim)

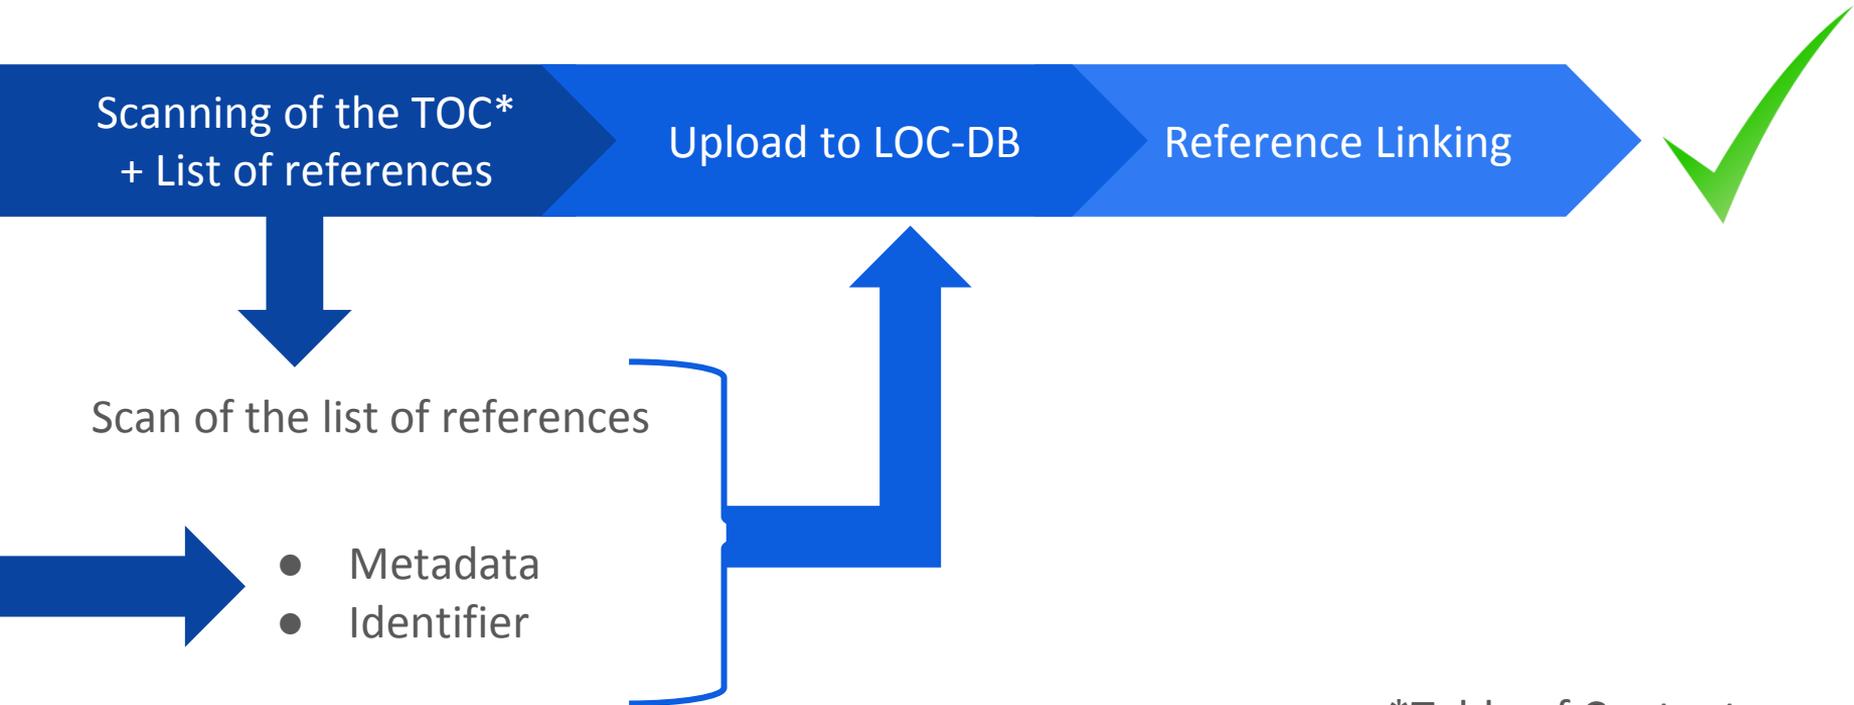
For Print Resources



*Table of Contents

Reference Linking

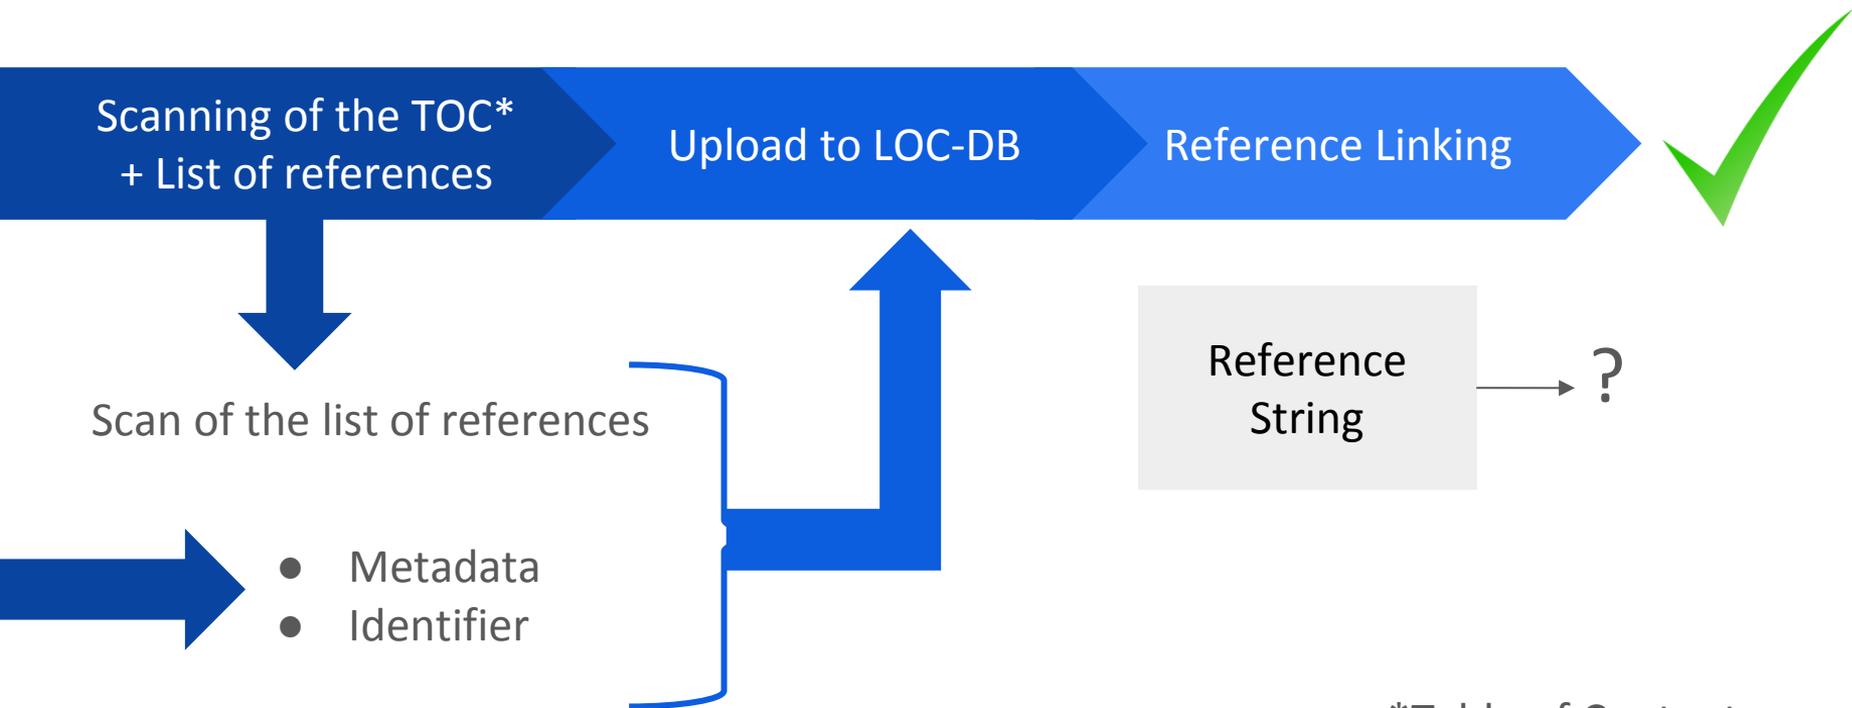
Extending the Standard Library Workflow



*Table of Contents

Reference Linking

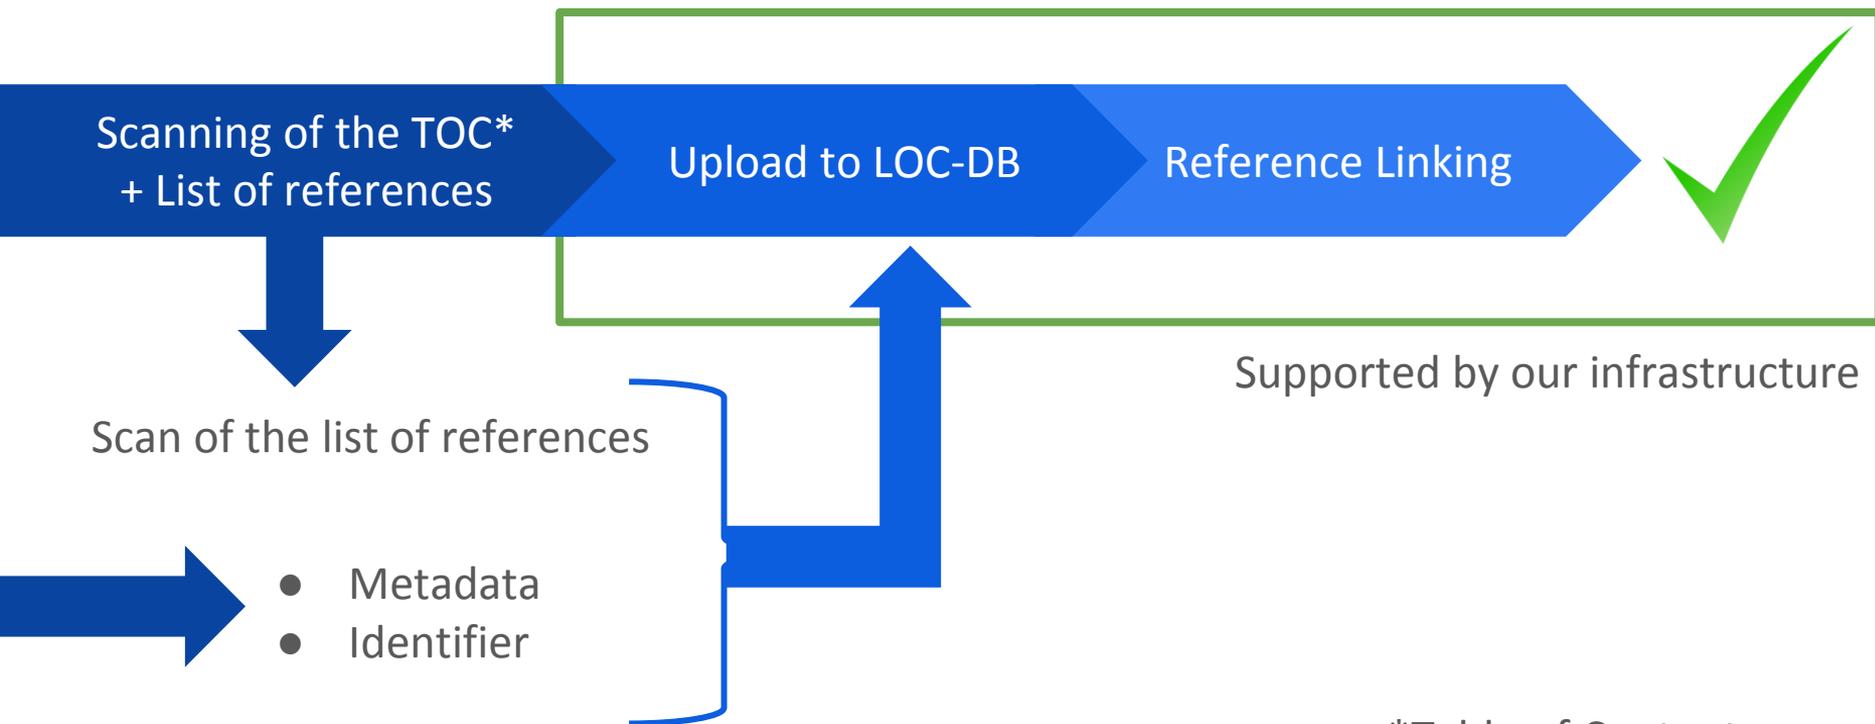
Extending the Standard Library Workflow



*Table of Contents

Reference Linking

Extending the Standard Library Workflow

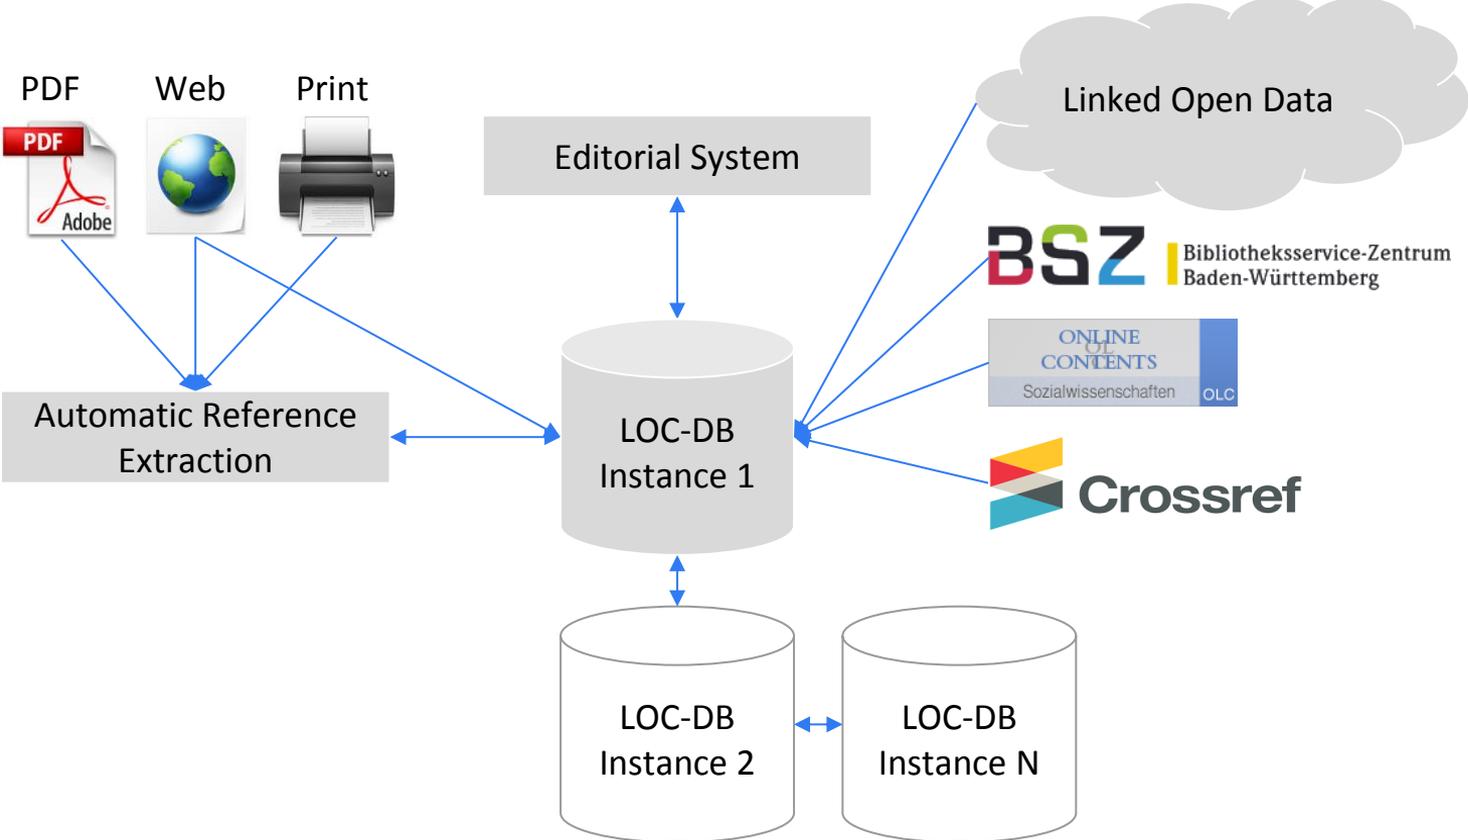


*Table of Contents

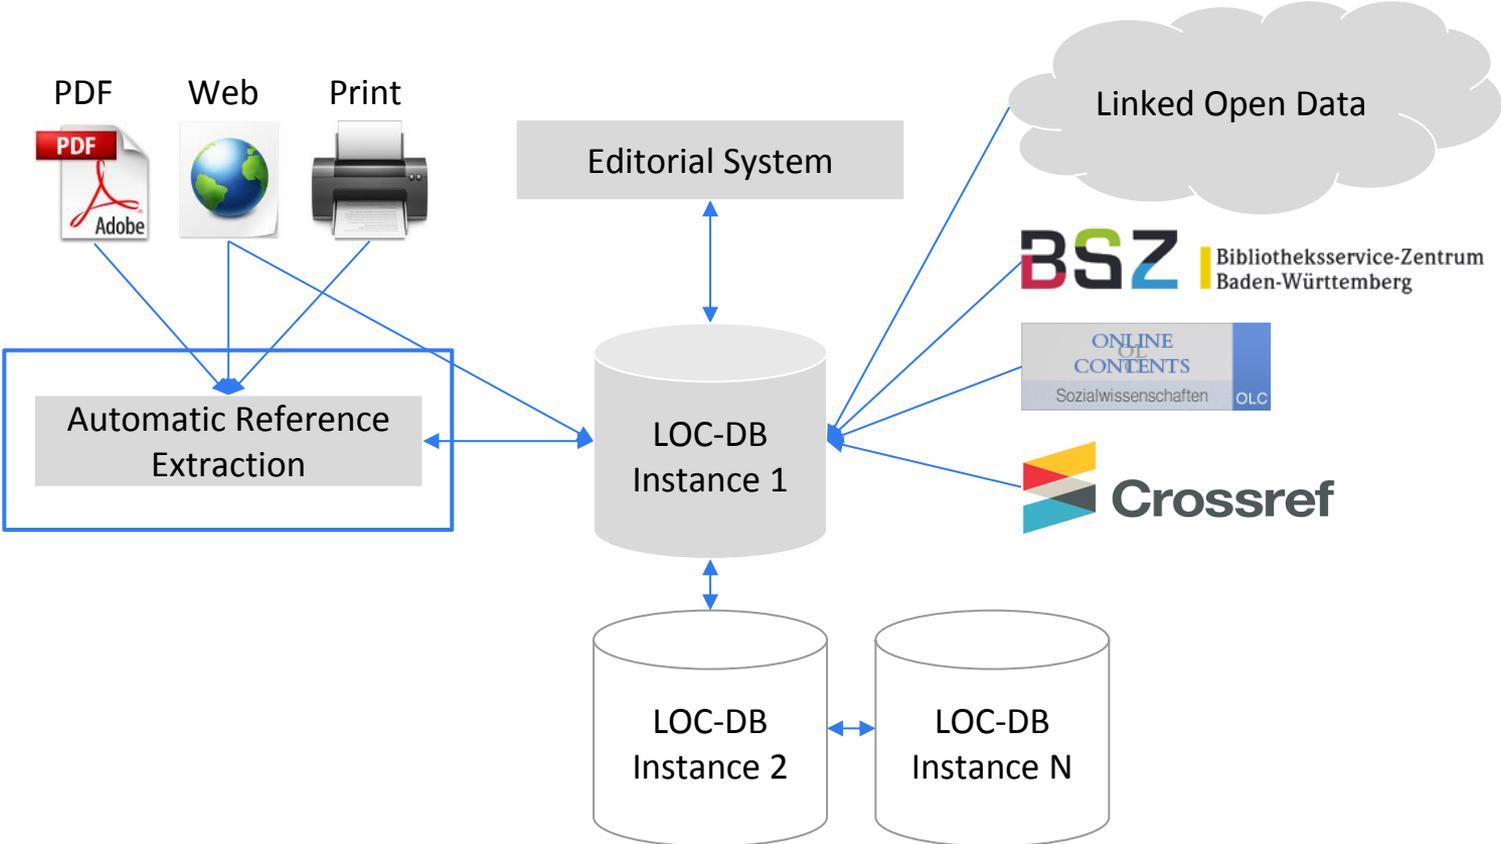
Agenda

1. Motivation
2. Data
3. Reference Linking Workflow
- 4. LOC-DB Infrastructure**
5. Evaluation
6. Conclusion

LOC-DB Infrastructure



LOC-DB Infrastructure



Automatic Reference Extraction

Combination of text-driven
and layout-driven extraction
using deep learning techniques
(“DeepBIBX”; Bhardwaj et al., 2017)

Ackermann, Josef, »Null Toleranz für Grauzonen. Josef Ackermann, Vorstandsvorsitzender der Deutschen Bank, über seine Moral, Luxusprobleme und Belcanto im Badezimmer«, in: *Zeitmagazin* 22/2007, S. 46–51.

Adorno, Theodor W., *Ästhetische Theorie*, Frankfurt/M. 1973.

Alemann, Ulrich von/Eckert, Florian, »Lobbyismus als Schattenpolitik«, in: *Aus Politik und Zeitgeschichte (APuZ)* 15–16 (2006), S. 3–10.

Anheier, Helmut K./Appel, Anja, »Stiftungen in der Bürgergesellschaft: Möglichkeiten und Grenzen«, in: *Aus Politik und Zeitgeschichte (APuZ)* 14 (2004), S. 8–15.

Arbeitsstab Forum Bildung in der Geschäftsstelle der Bund-Länder-Kommission für Bildungsplanung und Forschungsförderung, *Förderung von Chancengleichheit. Vorläufige Empfehlungen und Expertenbericht*, Bonn 2000.

Aristoteles, *Politik*, übers. u. hrsg. v. Olof Gigon, Zürich/Stuttgart 1971.

Aristoteles, *Nikomachische Ethik*, übers. u. hrsg. v. Ursula Wolf, Reinbek b. Hamburg 2006.

Aristoteles, *Rhetorik*, übers. u. hrsg. von Gernot Krapinger, bibliogr. erg. Ausg., Stuttgart 2007.

Aron, Raymond, *Hauptströmungen des modernen soziologischen Denkens*, Reinbek b. Hamburg 1979.

Aron, Raymond, »Zur politischen Theorie« (1962), in: ders.: *Zwischen Macht und Ideologie. Politische Kräfte der Gegenwart*, Wien 1974.

Aron, Raymond, »Regierende und Regierte«, in: ders.: *Fortschritt ohne Ende? Güterlohn*, 1970, S. 50–70.

Bachrach, Peter, *Die Theorie demokratischer Elitenherrschaft. Eine kritische Analyse*, Frankfurt/M. 1970.

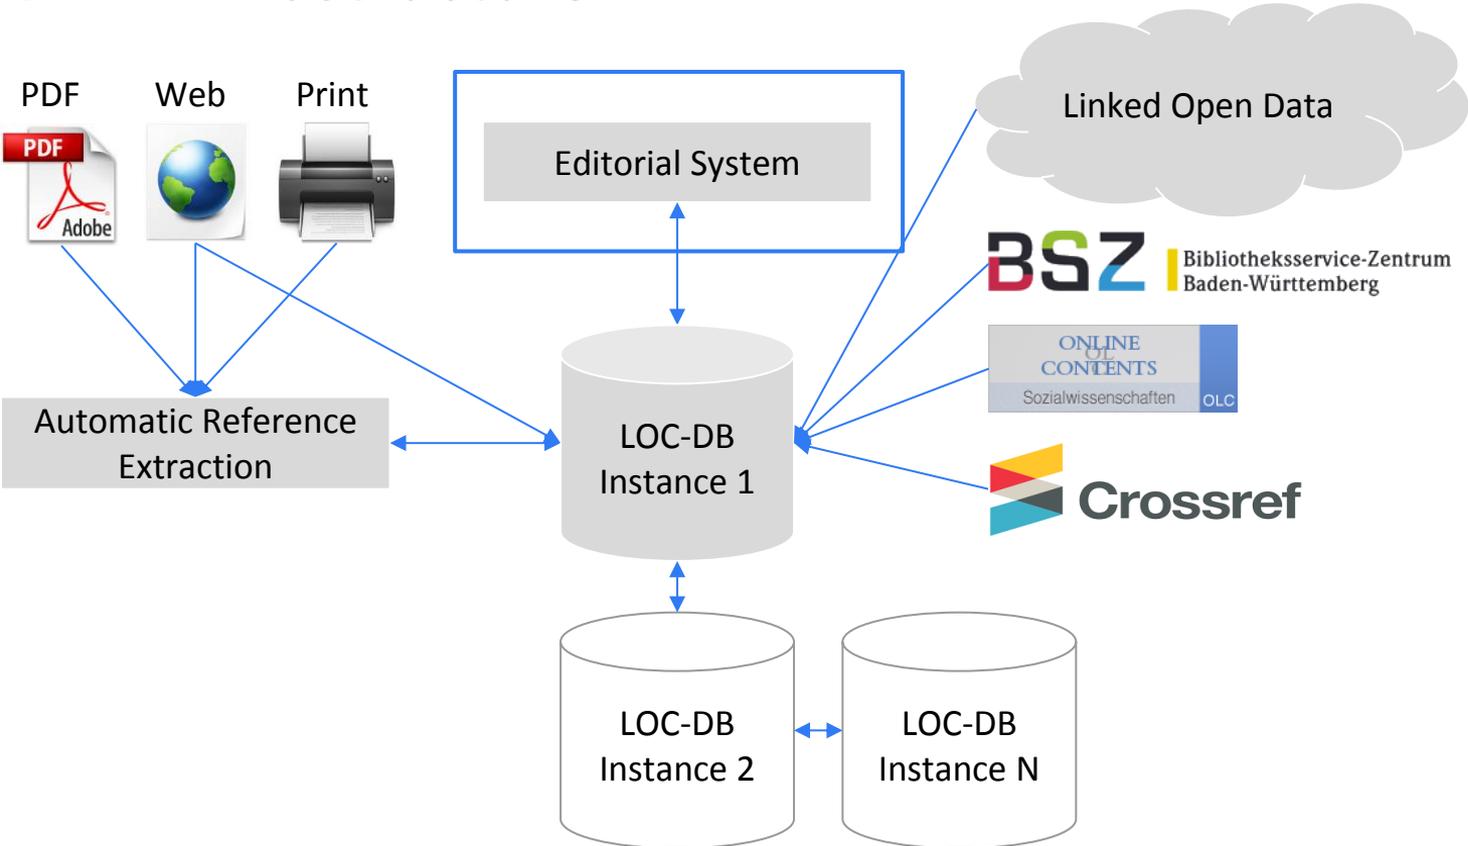
Backhaus-Maul, Holger/Bidermann, Christine/Nährlich, Stefan/Polterauer, Judith (Hg.), *Corporate Citizenship in Deutschland. Gesellschaftliches Engagement von Unternehmen. Bilanz und Perspektiven*, 2. akt. u. erw. Aufl. Wiesbaden 2010.

Baum, Manfred: »Probleme der Begründung Kantischer Tugendpflichtens«, in: *Jahrbuch für Recht und Ethik* VI (1998), S. 41–56.

Benda, Julien, *Der Verrat der Intellektuellen* (1927), Frankfurt/M. 1988.

Berchem, Theodor, *Elitebildung in der Massenuniversität? Bilanz und Perspektiven der Hochschulreform*, Köln 1985.

LOC-DB Infrastructure



Agenda

NOT_OCR_PROCESSED OCR_PROCESSING OCR_PROCESSED EXTERNAL

[Refresh](#)

EDITED_BOOK **2017** **Kritische politische Bildung: Standpunkte und Perspektiven /**

[Edit](#)[References](#)

, Wochenschau, *In*: Görtler, Michael; Lotz, Mathias; Partetzke, Marc; Poma Poma, Sara; Winckler, Marie (ed.), Kritische politische Bildung: Standpunkte und Perspektiven /, Wochenschau, .

BOOK_CHAPTER *In*: Görtler, Michael; Lotz, Mathias; Partetzke, Marc; Poma Poma, Sara;

[Edit](#)[References](#)

Winckler, Marie (ed.), Kritische politische Bildung: Standpunkte und Perspektiven /, Wochenschau, .

14 - 16 PRINT

- [5b13ffbd48b24e6c788da1f3.pdf](#)

Edit Resource

JOURNAL_ARTICLE Platt, Jennifer **1974** **The Phenomenon of Sociology: A Reader in the Sociology of Sociology** , SAGE Publications .

Type

JOURNAL_ARTICLE ▼

Title

The Phenomenon of Sociology: A Reader in the Sociology of Sociology

Subtitle

Contributors

×

AUTHOR ▼

Platt, Jennifer

×

PUBLISHER ▼

SAGE Publications

Add Contributor

Die Zukunft Europas :

- [Back](#)
- [Reference list](#)
- [Scan view](#)

Literaturverzeichnis

Albers, Detlev / Haseler, Stephen / Meyer, Henning: Social Europe - A Continent's Answer to Market Fundamentalism; European Research Forum at London Metropolitan University, London 2006.

Baum-Ceising, Alexandra / Faber, Anne (Hrsg.): Soziales Europa? Perspektiven des Wohlfahrtsstaates im Kontext von Europäisierung und Globalisierung: Festschrift für Klaus Busch; Vs Verlag, Wiesbaden 2005.

Beck, Ulrich / Grande, Edgar: Das kosmopolitische Europa; Suhrkamp Verlag, Frankfurt am Main 2004.

Bundeszentrale für politische Bildung: Vertrag von Lissabon, Bonn 2008.

Collignon, Stefan: Bundesrepublik Europa? Die demokratische Herausforderung und Europas Krise: Vorwärts Buch, Berlin 2007.

Delors, Jacques: Erinnerungen eines Europäers; Parthas Verlag, Berlin 2004.

Dullien, Sebastian / Herr, Hansjörg / Kellermann, Christian: Der gute Kapitalismus; Transcript Verlag, Bielefeld 2009.

Eichenhofer, Eberhard: Geschichte des Sozialstaats in Europa: Von der „sozialen Frage“ bis zur Globalisierung; C.H. Beck Verlag, München 2007.

Europäische Kommission: Der Vertrag von Lissabon: Einführung, Vertrag über die Europäische Union, Vertrag über die Arbeitsweise der Europäischen Union, Charta der Grundrechte der Europäischen Union, Protokolle, Erklärungen, Deutsches Recht; Autoren der Einführung: Brok, Elmar/Leinen, Jo; Bundeszentrale für politische Bildung, Bonn 2008.

Europäische Union: Amtsblatt der Europäischen Union C 306, 17.12.2007: Vertrag von Lissabon;

Bundesrepublik Europa? Die demokratische Herausforderung und Europas Kris; Vorwärts Buch, Stefaan CCollignon

Confidence threshold for internal ... and for external Suggestions

[Search](#)

[Ask Others](#)

Suggestions

External suggestions

Stefan Collignon: Bundesrepublik Europa? Die demokratische Herausforderung und Europas Krise. [CrossRef](#)

New resource from reference metadata

Bundesrepublik Europa? Die demokratische Herausforderung und Europas Kris; Vorwärts Buch, [Local](#)

[Edit](#)

[Scan view](#) [Reference list](#)[BOOK CHAPTER](#)

Theodor W Adorno. 1967. Resume über Kulturindustrie. In: Adorno,Theodor W. Ohne Leitbild. Parva Aesthetica. FrankfurtIM.: Suhrkamp,. In: S. [Edit](#)

Theodor W Adorno. 1971. Nas bedeutet: Aufarbeitung der Vergangenheit. In: Adorno,Theodor W.: Erziehung zur Mündigkeit. Vorträge und Gespräche mit Hellmut Becker 1959-1969. FrankfurtIM.: Suhrkamp,. In: S. [Edit](#)

Ien Ang. 1999. Culture and Communications,'Towards an EthnographicCritique of MediaConsumption in theTransnational Media System. In: [Edit](#)

Ien Ang. 2005. Who needs cultural earesearch? In: Leistyna, Pepi (Hrsg.): Cultural Studies, From 'Theory to Action. Osford: [Edit](#)

Carsten Büniger. 2010. Poliische Bildung nach dem ‚Tod desSubjekts‘.. In: In: Losch, Bettina!Thimmel, Andreas(Hrsg.) Kritischepolitische Bildung. Ein Handbuch. Schwalbach!Te.: Wochenschau, S. [Edit](#)

Halil Can. 2011. Demokratiarbeit und Empowerment gegen Diskriminierung und Rassismus in selbstbestimmten People of Color-Räumen. In: Castro Varela, Maria do MarlDhawan, Nikita (Hrsg.): Soziale (Un)Gerechtigkeit. Kritische Perspektiven auf Diversity, Intersektionalitit und Antidiskriminierung. [Edit](#)

Resume über Kulturindustrie. In: Adorno,Theodor W. Ohne Leitbild. Parva Aesthetica. FrankfurtIM.: Suhrkamp, 1967



Confidence threshold for internal

... and for external Suggestions

[Ask Others](#)

Suggestions

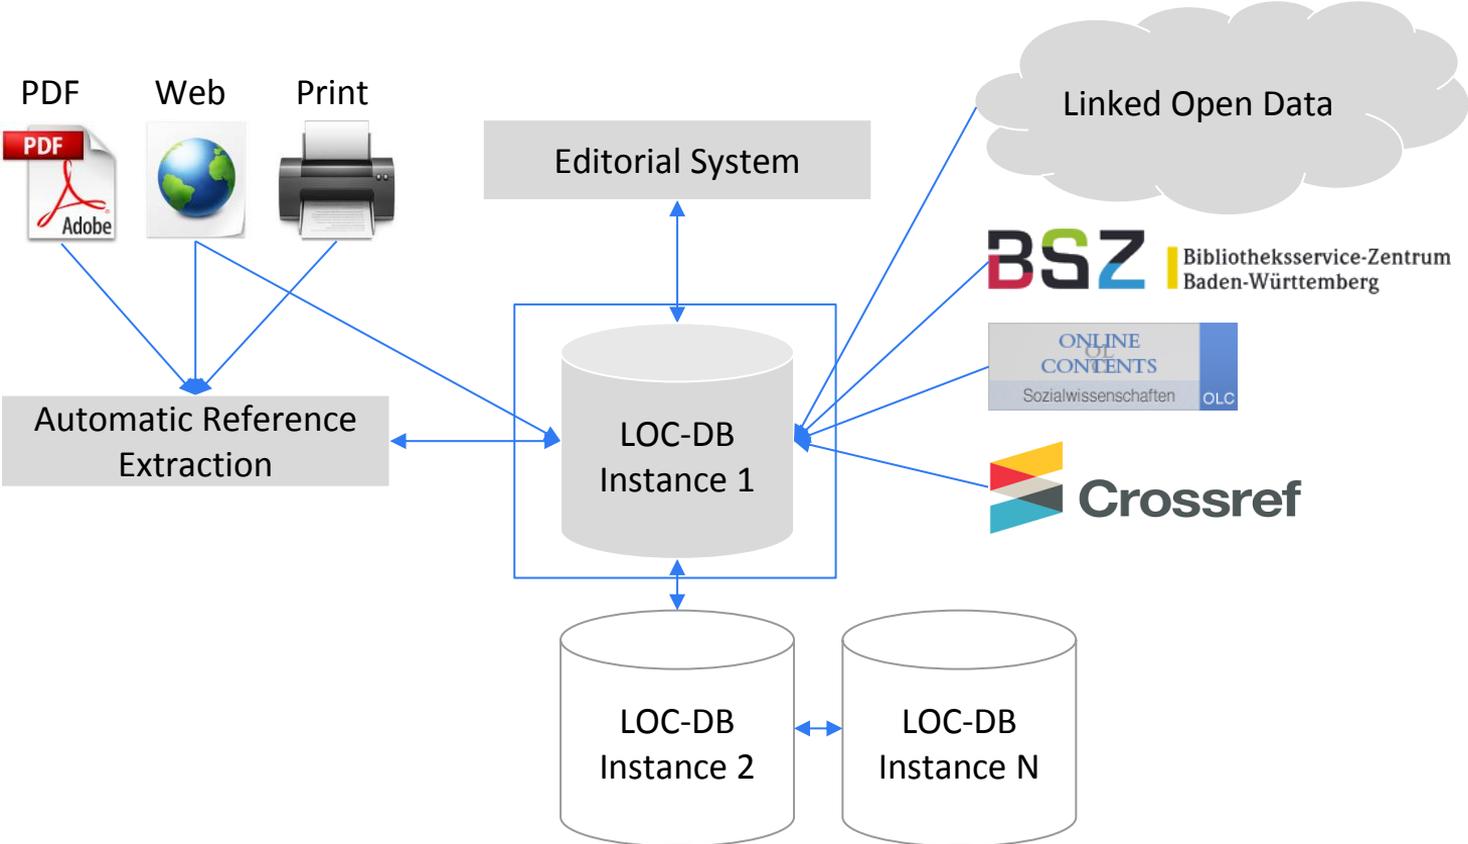
External Suggestions

[BOOK](#) Adorno, Theodor W. [1970](#) **OHNE LEITBILD. PARVA AESTHETICA. VON THEODOR W. ADORNO. 4. AUFL. FRANKFURT A.M.: SUHRKAMP 1970. 193 S.**, [GVI](#) [Edit](#)

New resource from reference metadata

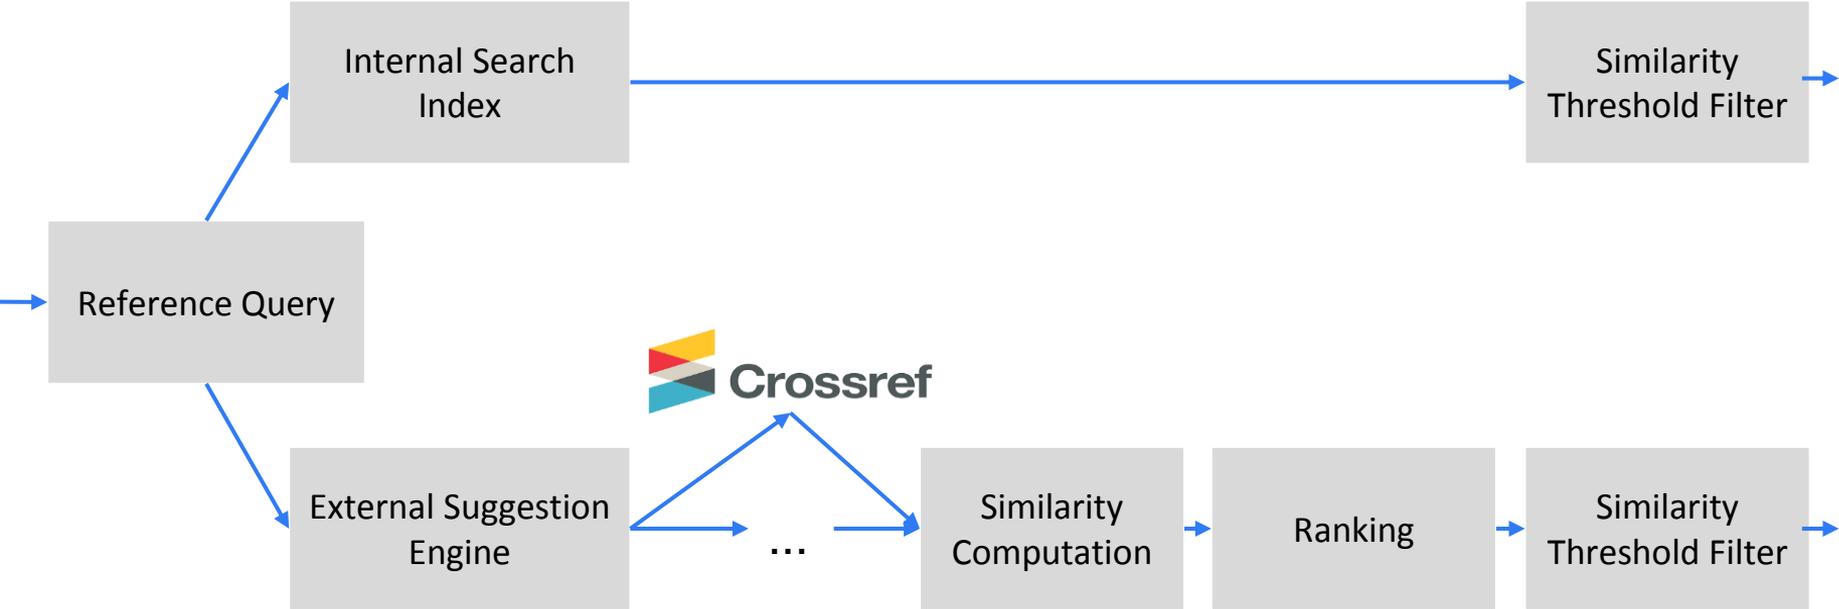
[Create Resource](#)

LOC-DB Infrastructure



Reference Target Suggestions

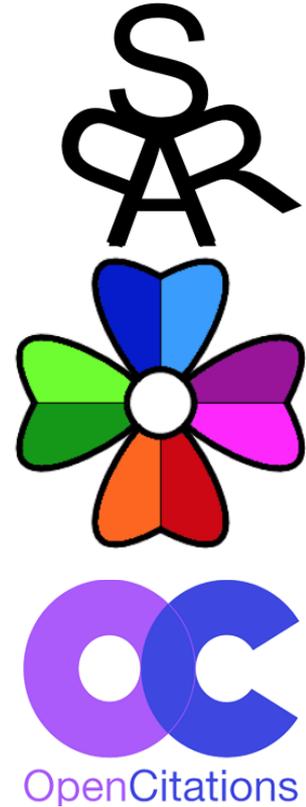
Speeding up the linking process



Data Model and Publishing

Ensuring optimal reusability
and interoperability of the produced data

- Adaption of the OpenCitations metadata model (Peroni and Shotton, 2016)
- Publishing of the Data in RDF format by using the Semantic Publishing and Referencing (SPAR) Ontologies (Peroni, 2014)



Agenda

1. Motivation
2. Data
3. Reference Linking Workflow
4. LOC-DB Infrastructure
- 5. Evaluation**
6. Conclusion

Results of our Public Workshop (Wilke and Retter, 2017)

- Cataloging citation data is an important task for libraries
- Data from union catalogs should be used
- Suggestions help to minimize the time required to resolve a link
- Acquired citation data should be integrated in existing systems



Save the date: The LOC-DB
Workshop 2018 will take place on
the **6th November, 2018** in
Mannheim!



How much time does the whole process take?

Scanning of the list of references (only print)

Upload to LOC-DB

Reference Linking

- > 100 pages per person per hour
- Upper bound ~ 15 minutes for scanning for an average book (26 pages of references)
- Additional scanning time does not significantly affect other processes in the library
- Prolongs the processing of a book on average by only 3 minutes

How much time does the whole process take?

Scanning of the list of references (only print)

Upload to LOC-DB

Reference Linking

- Batch upload
- Background processing for meta data retrieval and reference extraction
→ Does not affect the process in the library

How much time does the whole process take?

Scanning of the list of references (only print)

Upload to LOC-DB

Reference Linking

Criterion	Minimum	Maximum	Median
Citation Linking (s)	9.93	557.20	89.45
Internal Suggestion Retrieval (s)	0.02	0.5	0.06
External Suggestion Retrieval (s)	0.50	95.65	0.89
# Searches per Reference	1	36	2

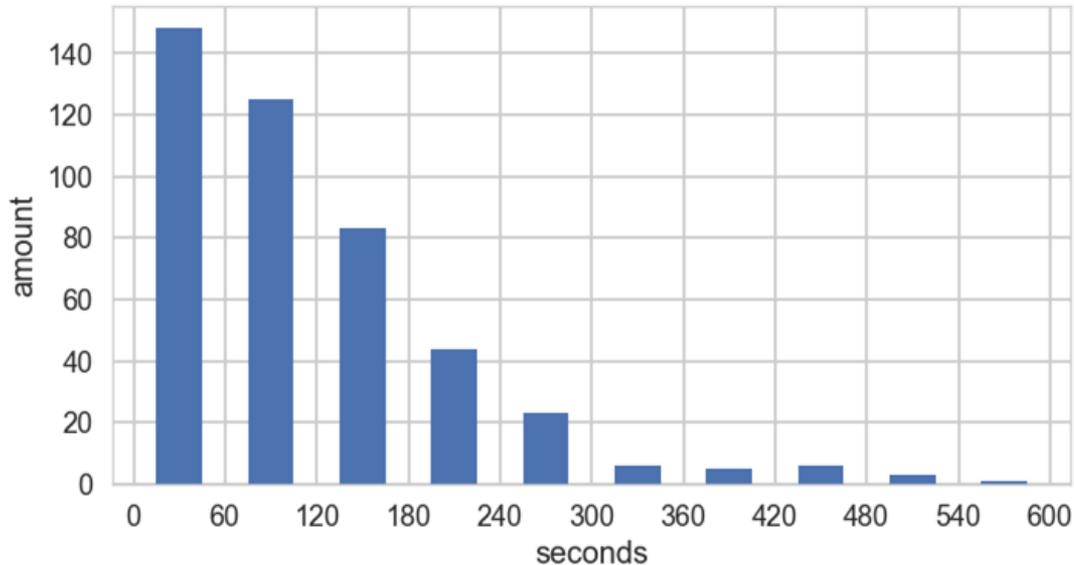
Minimum, maximum, and median time in seconds for the reference linking step

How much time does the whole process take?

Scanning of the list of references (only print)

Upload to LOC-DB

Reference Linking



Histogram of reference linking times

Agenda

1. Motivation
2. Data
3. Reference Linking Workflow
4. LOC-DB Infrastructure
5. Evaluation
6. **Conclusion**

How much would it cost if libraries catalogued everything and curated the citation graph?

Estimation about the number of full-time employees needed to process all literature of social sciences bought in 2011 by Mannheim University Library, depending on the time t in seconds to resolve a reference.

t	1	5	10	20	30	60	120
# employees	0.1	0.5	1	2	3	5.9	11.9

How much would it cost if libraries catalogued everything and curated the citation graph?

Preliminary results suggest general feasibility of the approach
Continuous improvement on the infrastructure and processes ongoing

Semi-automated approach ensures human-level quality
of the generated data

Thank you for your interest

For more information please visit

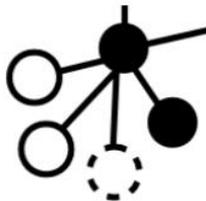
<https://locdb.bib.uni-mannheim.de>

<https://github.com/locdb/>

<http://wisslab.org>



Anne Lauscher & Kai Eckert



Tiessen, Jan (2007): Die Resultate im Blick?
ner/Döhler, Marian (Hrsg.): Agencies in W
Tondorf, Karin/Bahn Müller, Reinhard/Klages,
instrument. Anwendungspraxis, Probleme
sigma.
Touraine, Alain (1984): Le retour de l'acteur: e
Treiber, Hubert (1984): Warum man nicht die
Mikroskop den ganzen Elefanten zu sehen.



Bibliography

- Marshall Breeding. 2015. Future of Library Discovery Systems. Information Standards Quarterly 27, 1 (2015), 24. <https://doi.org/10.3789/isqv27no1.2015.04>
- Christian Wilke and Regina Retter. 2017. Zitationsdaten extrahieren: halbautomatisch, offen, vernetzt. Ein Workshopbericht. Informationspraxis 3, 2 (Dec. 2017). <https://doi.org/10.11588/ip.2017.2.43235>
- Silvio Peroni and David Shotton. 2016. Metadata for the OpenCitations Corpus. Technical Report. <https://dx.doi.org/10.6084/m9.figshare.3443876>
- Akansha Bhardwaj, Dominik Mercier, Andreas Dengel, and Sheraz Ahmed. 2017. DeepBIBX: Deep Learning for Image Based Bibliographic Data Extraction. Springer International Publishing, Cham, 286–293. https://doi.org/10.1007/978-3-319-70096-0_30

Bibliography

- Silvio Peroni. 2014. The Semantic Publishing and Referencing Ontologies. In Semantic Web Technologies and Legal Scholarly Publishing. Springer, Cham, 121–193. https://doi.org/10.1007/978-3-319-04777-5_5