

Herausforderungen und Lösungen für die europäische Sprachtechnologie- Forschung und -Entwicklung

Dr. Georg Rehm

DFKI GmbH

georg.rehm@dfki.de

Research Fellow-Präsentation – Berlin, 30. Oktober 2018

14. Juli 2017

1. Herausforderung

**Das mehrsprachige Europa:
Sprachtechnologien für alle europäischen Sprachen?**

2. Herausforderung

**Online-Desinformationskampagnen:
Technische Lösungsansätze gegen „Fake News“?**

3. Herausforderung

**Digitaler Content:
Technologien für die effiziente Content-Kuratierung?**

- 
- **Mehrsprachigkeit ist der Kern der europäischen Idee**
 - **24 EU Sprachen – alle besitzen den gleichen Status**
 - **Dutzende von regionalen und Minderheitensprachen sowie Sprachen von Migranten und Handelspartnern**
 - **Viele ökonomische, gesellschaftliche und technische Herausforderungen:**
 - **Mehrsprachigkeit für den digitalen Binnenmarkt**
 - **Technologien für sprachübergreifende sowie auch kulturübergreifende Kommunikation**
 - **Sprachtechnologien *gegen* den wachsenden Nationalismus und *für* die europäische Identität?**

META=NET

60 Forschungszentren in 34 Ländern.

Vorsitzender: Jan Hajic (CUNI)

Vizev.: J. van Genabith (DFKI), A. Vasiljevs (Tilde)

Generalsekretär: Georg Rehm (DFKI)

META

Multilingual Europe
Technology Alliance.

900+ Mitglieder in
67 Ländern



veröffentlicht 2013



31 Bände, veröffentlicht 2012



T4ME (META-NET)

CESAR

META-NORD

METANET4U



CRACKER

Cracking the Language Barrier

Coordination, Evaluation and Resources for European MT Research

Coordination and Support Action, H2020-ICT17, 2015–2017, 36 Monate – <http://www.cracker-project.eu>

1	DFKI	Deutschland	Georg Rehm
2	CUNI	Tschechien	Jan Hajic
3	ELDA	Frankreich	Khalid Choukri
4	FBK	Italien	Marcello Federico
5	ATHENA RC	Griechenland	Stelios Piperidis
6	UEDIN	UK	Philipp Koehn
7	USFD	UK	Lucia Specia



Zusammenführung und Integration von Communitys

- META-NET mit META-SHARE und META
- MT Evaluierungsinitiativen (WMT, IWSLT, MT Marathon)
- MT und andere LT-Industrien
- Sprachressourcen – META-SHARE, ELRA
- HT/MT Evaluationswerkzeuge – translate5
- Übersetzungsindustrie
- Nutzer maschineller Übersetzung

Strategic Agenda for the Multilingual Digital Single Market

- Version 0.5 präsentiert beim META-FORUM 2015
- Version 0.9 präsentiert beim META-FORUM 2016
- Version 1.0 präsentiert beim META-FORUM 2017

Customers are **six times more likely to buy** from sites in their native language.

English is not the answer
52% of EU customers **do not purchase** from English-language sites.

Adding even a few languages to a SME's website beyond English can have a **major impact on revenue**. Large organizations today often localize products and websites into fifty or more languages to increase market share.

Most EU languages address less than 3% of the market, fundamentally **limiting SMEs** operating in countries where those languages are spoken.

Strategic Research and Innovation Agenda
Language Technologies for Multilingual Europe
Towards a Human Language Project

SRIA Editorial Team
Version 1.0 – December 2017

Cracking the Language Barrier

5



Geo-blocking and language-blocking are barriers to access

Geo-blocking:

- keeps customers from accessing content due to nationality, location, or residence
- can be worked around by tech-savvy customers
- prevents some cross-border commerce

Language-blocking:

- keeps customers from accessing content in languages they do not speak
- customers never even know what they cannot find
- is unavoidable: no-one speaks all languages; however, current online translation is insufficient
- prevents customers from even *trying* to conduct cross-border commerce
- disproportionately impacts speakers of less common languages

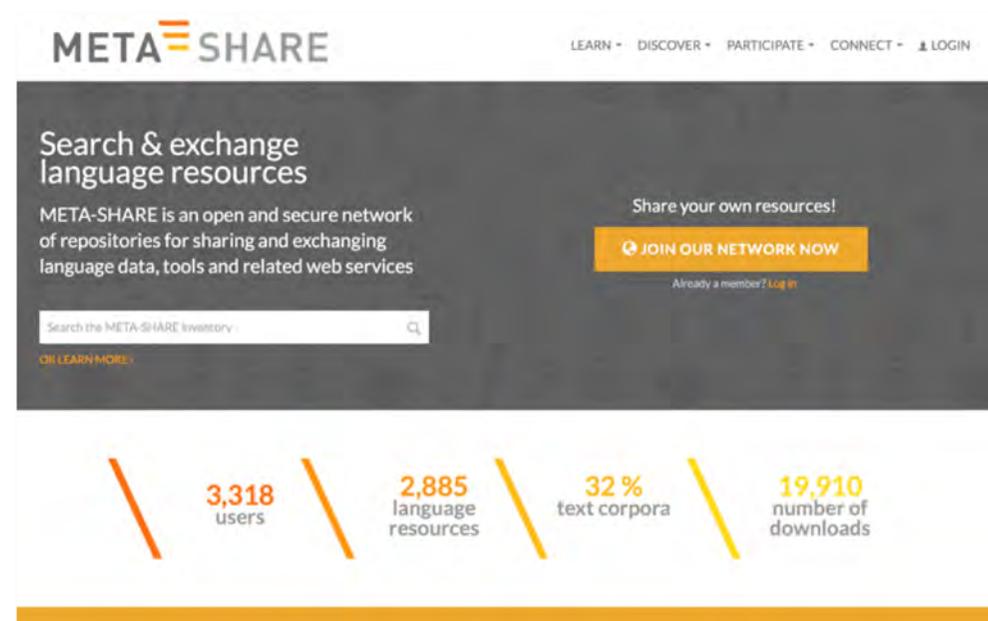
Both geo-blocking and language-blocking are daily problems for tens of millions of EU citizens.

- ❑ META-SHARE adressiert Technologie- bzw. Infrastrukturbedarfe in Bezug auf die

- ❑ Sichtbarkeit
- ❑ Dokumentation
- ❑ Identifizierung
- ❑ Verfügbarkeit
- ❑ Langzeitspeicherung
- ❑ Interoperabilität

von LRs und LTs

- ❑ 35 META-SHARE-Mitglieder und Organisationen in 25 Ländern
- ❑ <http://www.meta-share.org>



Stelios Piperidis, Harris Papageorgiou, Christian Spurk, Georg Rehm, Khalid Choukri, Olivier Hamon, Nicoletta Calzolari, Riccardo del Gratta, Bernardo Magnini, and Christian Girardi. "META-SHARE: One year after." In Nicoletta Calzolari, Khalid Choukri, Thierry Declerck, Hrafn Loftsson, Bente Maegaard, Joseph Mariani, Asuncion Moreno, Jan Odijk, and Stelios Piperidis, editors, Proceedings of the 9th Language Resources and Evaluation Conference (LREC 2014), pages 1532-1538, Reykjavik, Iceland, May 2014.

Georg Rehm. "The Language Resource Life Cycle: Towards a Generic Model for Creating, Maintaining, Using and Distributing Language Resources". In Nicoletta Calzolari (Conference Chair), Khalid Choukri, Thierry Declerck, Marko Grobelnik, Bente Maegaard, Joseph Mariani, Asuncion Moreno, Jan Odijk, and Stelios Piperidis, editors, Proceedings of the 10th Language Resources and Evaluation Conference (LREC 2016), pages 2450-2454, Portorož, Slovenia, May 2016.

- 
- Baskisch
 - Bulgarisch*
 - Deutsch*
 - Dänisch*
 - Englisch*
 - Estnisch*
 - Finnisch*
 - Französisch*
 - Galizisch
 - Griechisch*
 - Irisch*
 - Isländisch
 - Italienisch*
 - Katalanisch
 - Kroatisch*
 - Lettisch*
 - Litauisch*
 - Maltesisch*
 - Niederländisch*
 - Norwegisch
 - Polnisch*
 - Portugiesisch*
 - Rumänisch*
 - Schwedisch*
 - Serbisch
 - Slowakisch*
 - Slowenisch*
 - Spanisch*
 - Tschechisch*
 - Ungarisch*
 - Walisisch

MT

exzellente	gute	moderate	fragmentarische	schwache/keine Unterstützung
	Englisch	Französisch, Spanisch	Katalanisch, Niederländisch, Deutsch, Ungarisch, Italienisch, Polnisch, Rumänisch	Baskisch, Bulgarisch, Kroatisch, Tschechisch, Dänisch, Estnisch, Finnisch, Galizisch, Griechisch, Isländisch, Irisch, Lettisch, Litauisch, Maltesisch, Norwegisch, Portugiesisch, Serbisch, Slowakisch, Slowenisch, Schwedisch, Walisisch

Textanalytik

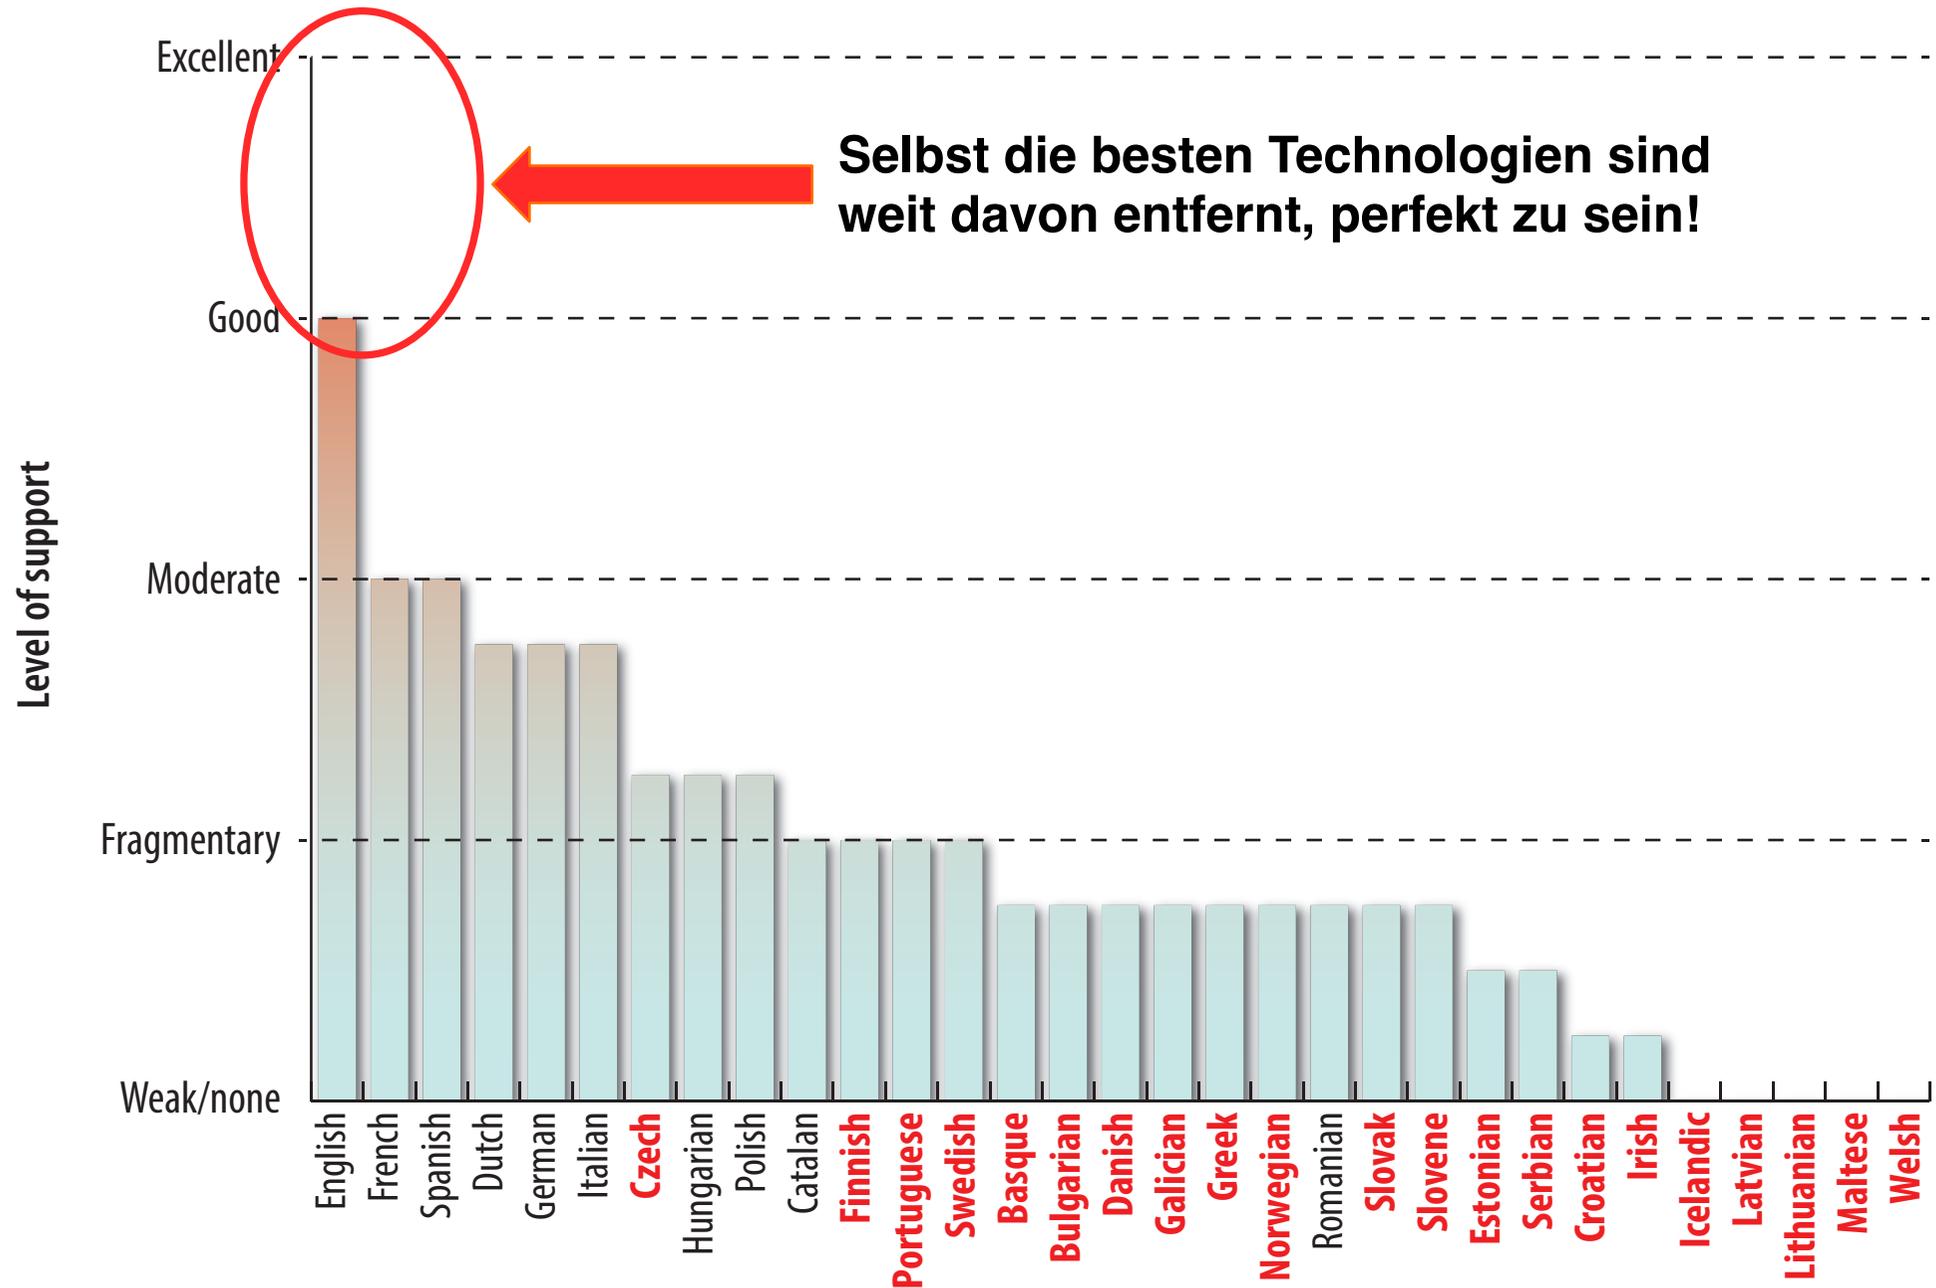
exzellente	gute	moderate	fragmentarische	schwache/keine Unterstützung
	Englisch	Niederländisch, Französisch, Deutsch, Italienisch, Spanisch	Baskisch, Bulgarisch, Katalanisch, Tschechisch, Dänisch, Finnisch, Galizisch, Griechisch, Ungarisch, Norwegisch, Polnisch, Portugiesisch, Rumänisch, Slowakisch, Slowenisch, Schwedisch	Kroatisch, Estnisch, Isländisch, Irisch, Lettisch, Litauisch, Maltesisch, Serbisch, Walisisch

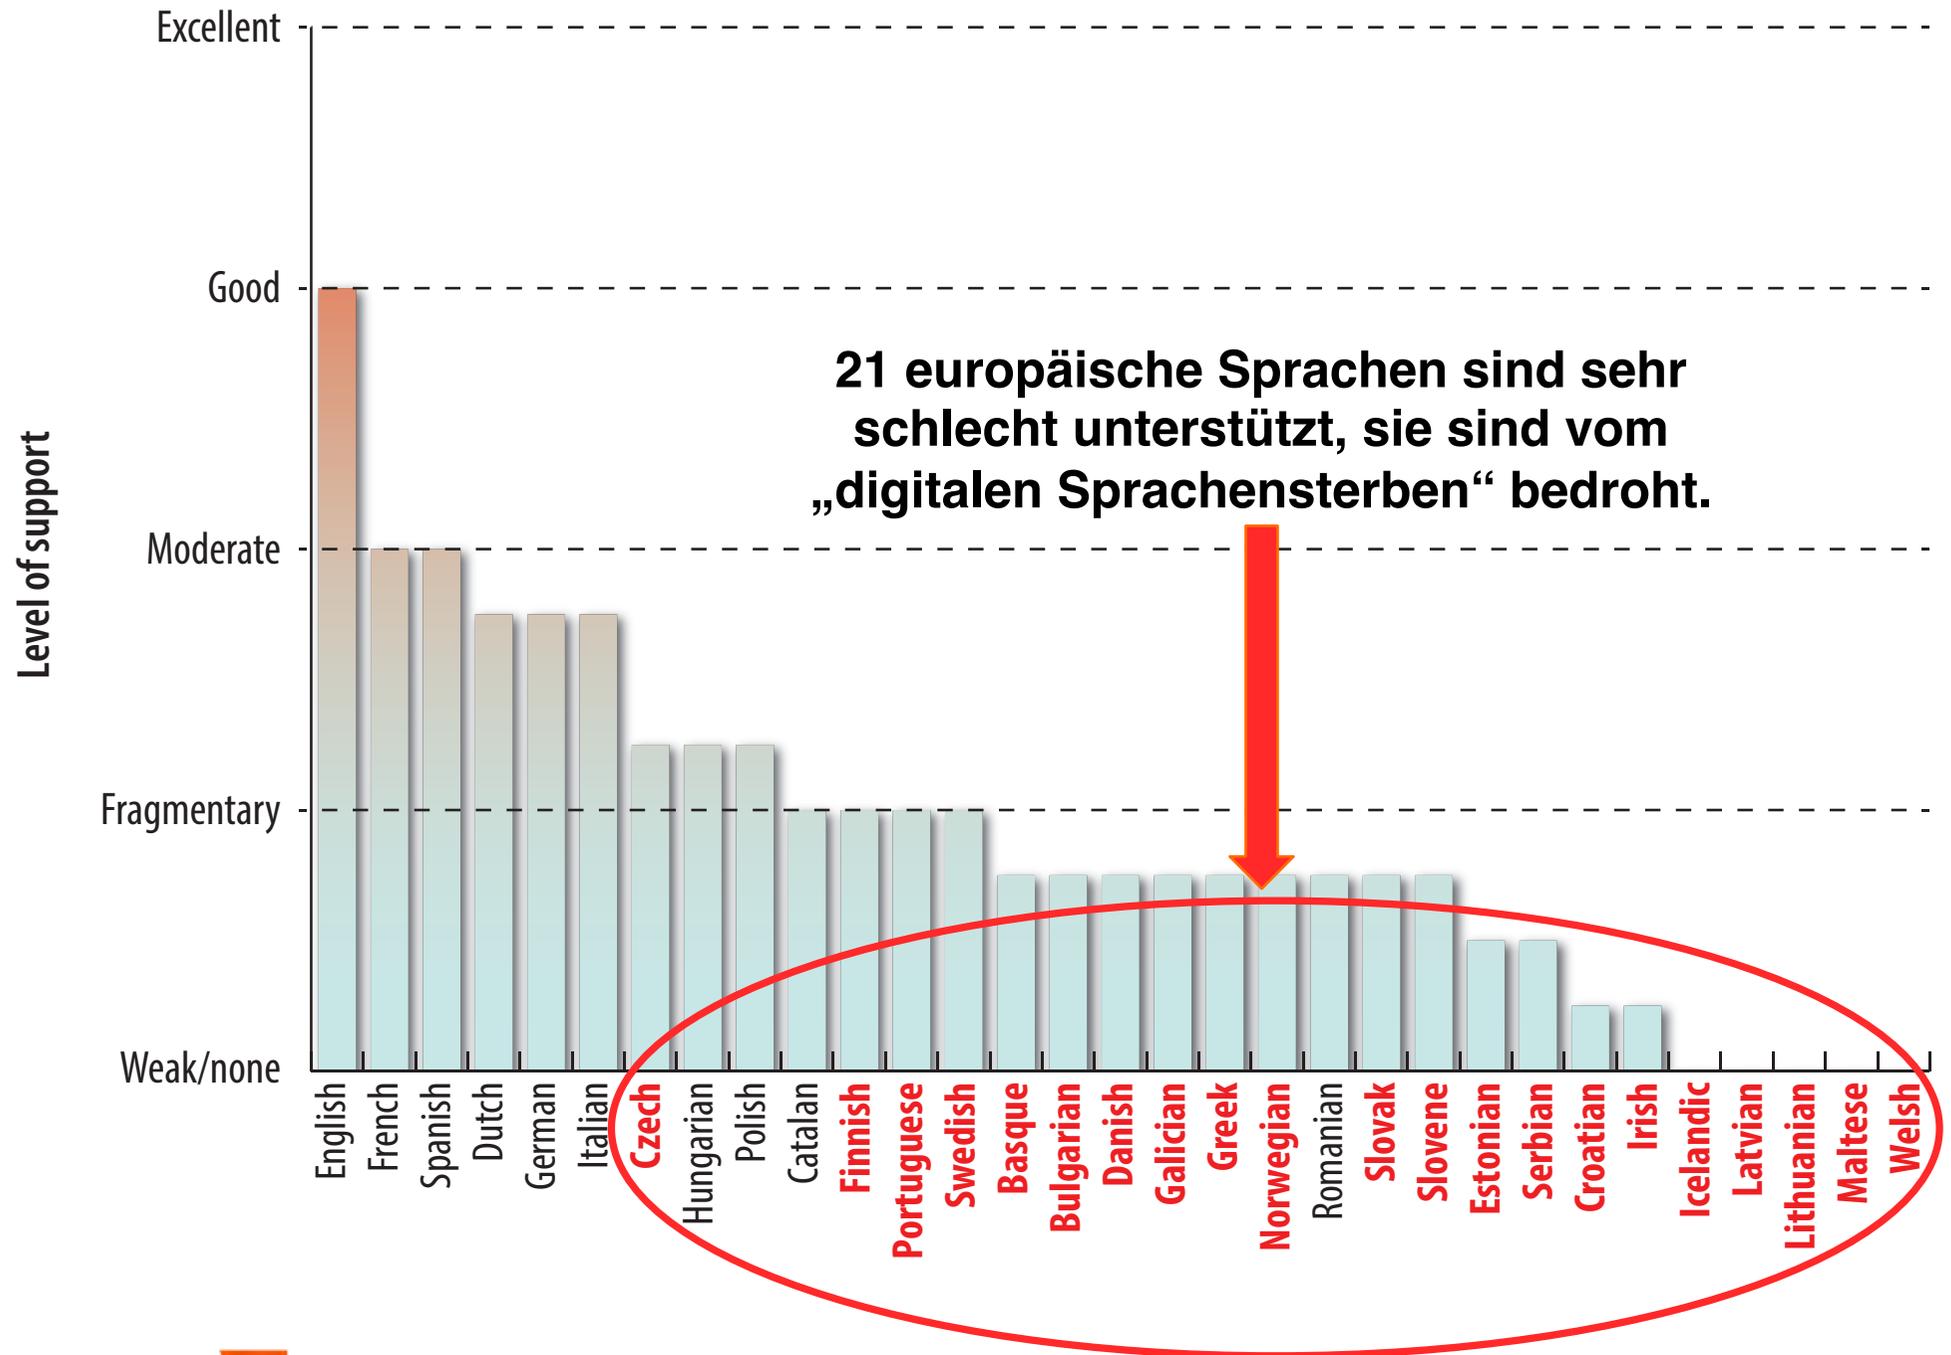
Speech

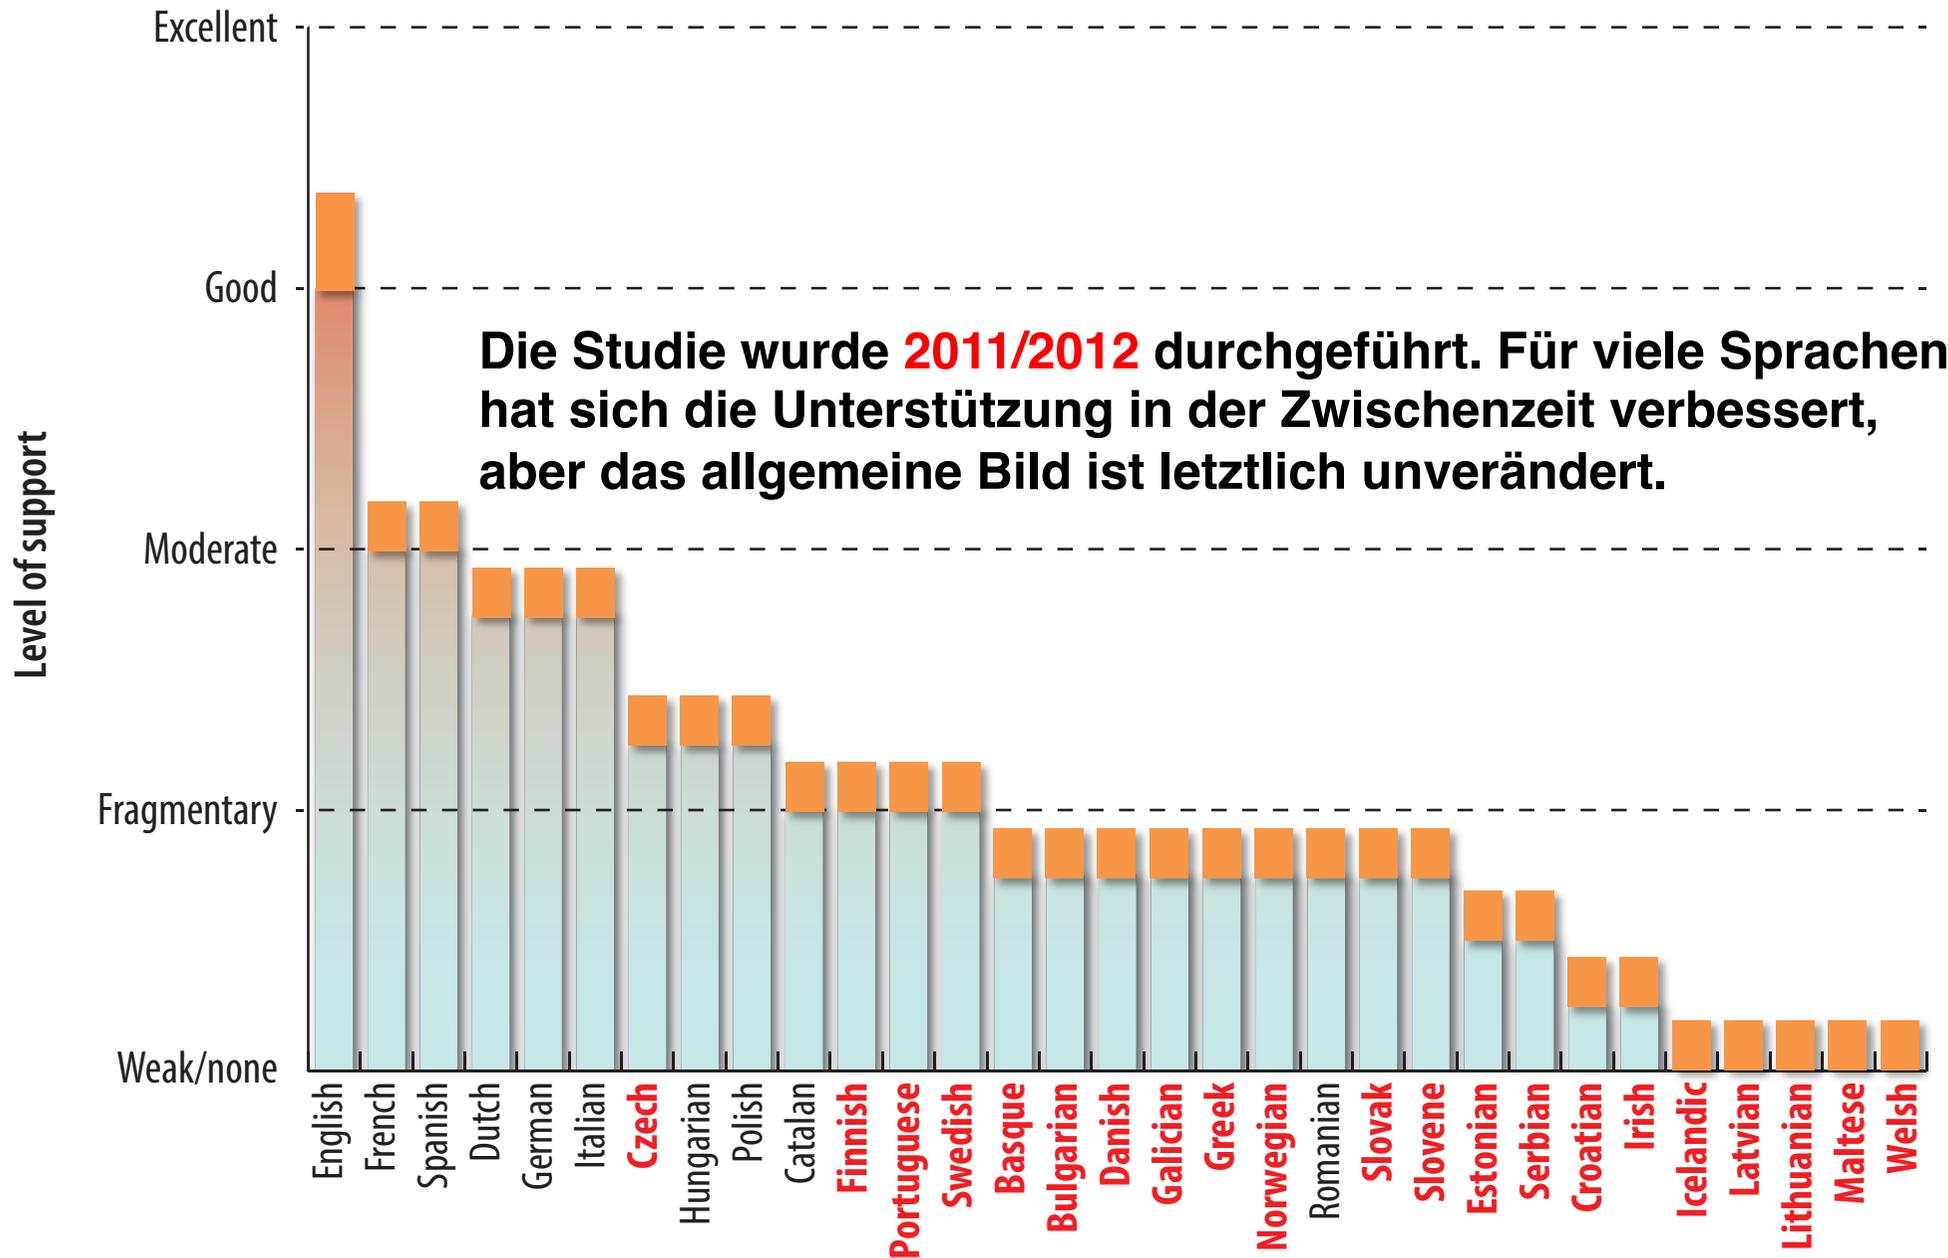
exzellente	gute	moderate	fragmentarische	schwache/keine Unterstützung
	Englisch	Tschechisch, Niederländisch, Finnisch, Französisch, Deutsch, Italienisch, Portugiesisch, Spanisch	Baskisch, Bulgarisch, Katalanisch, Dänisch, Estnisch, Galizisch, Griechisch, Ungarisch, Irisch, Norwegisch, Polnisch, Serbisch, Slowakisch, Slowenisch, Schwedisch	Kroatisch, Isländisch, Lettisch, Litauisch, Maltesisch, Rumänisch, Walisisch

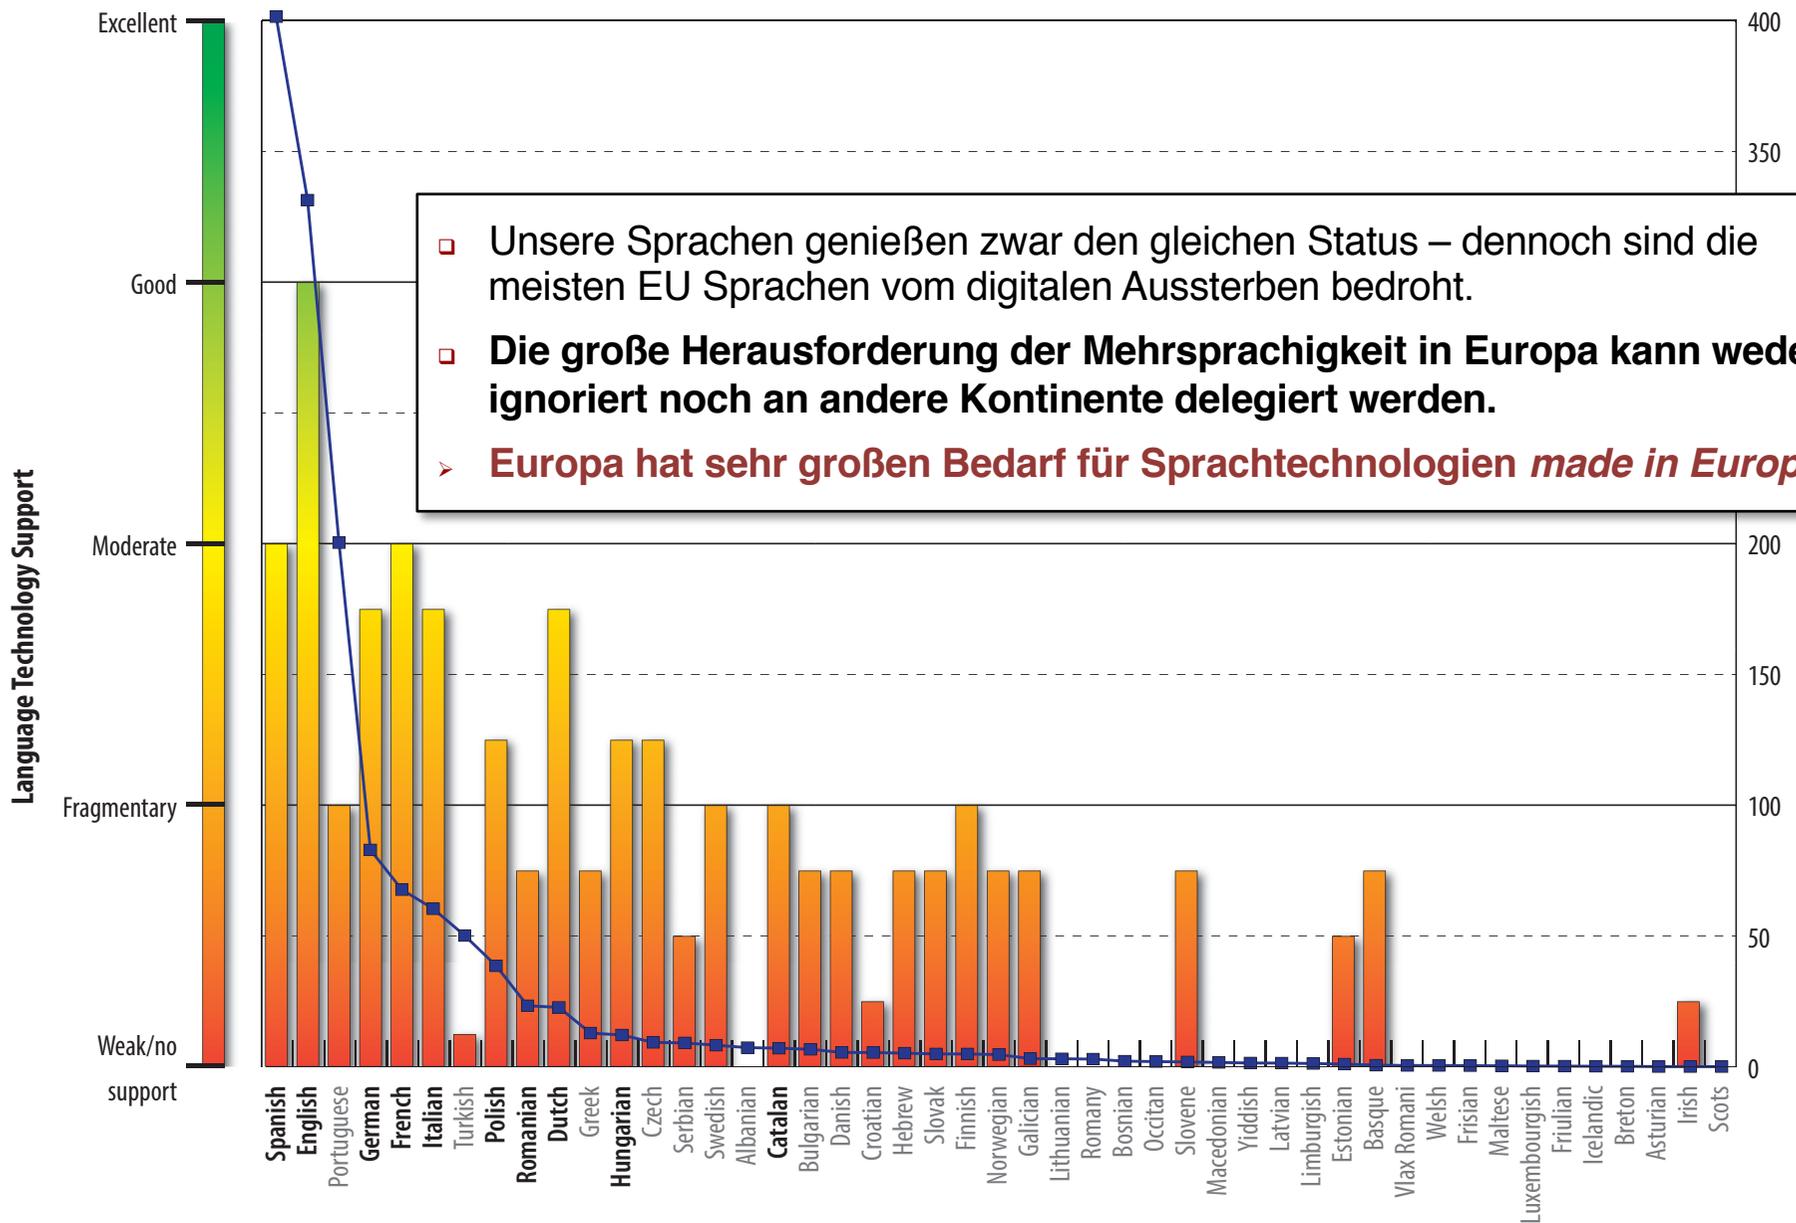
Ressourcen

exzellente	gute	moderate	fragmentarische	schwache/keine Unterstützung
	Englisch	Tschechisch, Niederländisch, Französisch, Deutsch, Ungarisch, Italienisch, Polnisch, Spanisch, Schwedisch	Baskisch, Bulgarisch, Katalanisch, Kroatisch, Dänisch, Estnisch, Finnisch, Galizisch, Griechisch, Norwegisch, Portugiesisch, Rumänisch, Serbisch, Slowakisch, Slowenisch	Isländisch, Irisch, Lettisch, Litauisch, Maltesisch, Walisisch









Georg Rehm, Hans Uszkoreit, Ido Dagan, Vartkes Goetcherian, Mehmet Ugur Dogan, Coskun Mermer, Tamás Váradi, Sabine Kirchmeier-Andersen, Gerhard Stickel, Meirion Prys Jones, Stefan Oeter, and Sigve Gramstad. An Update and Extension of the META-NET Study “Europe’s Languages in the Digital Age”. In Proceedings of the Workshop on Collaboration and Computing for Under-Resourced Languages in the Linked Open Data Era (CCURL 2014), Reykjavik, Iceland, May 2014.

Georg Rehm, Hans Uszkoreit, Sophia Ananiadou, Núria Bel, Audronė Bielevičienė, Lars Borin, António Branco, Gerhard Budin, Nicoletta Calzolari, Walter Daelemans, Radovan Garabík, Marko Grobelnik, Carmen Garcia-Mateo, Josef van Genabith, Jan Hajič, Inma Hernáez, John Judge, Svetla Koeva, Simon Krek, Cvetana Krstev, Krister Lindén, Bernardo Magnini, Joseph Mariani, John McNaught, Maite Melero, Monica Monachini, Asunción Moreno, Jan Odjik, Maciej Ogrodniczuk, Piotr Pezik, Stelios Piperidis, Adam Przepiórkowski, Eiríkur Rögnvaldsson, Mike Rosner, Bolette Sandford Pedersen, Inguna Skadiņa, Koenraad De Smedt, Marko Tadić, Paul Thompson, Dan Tufiş, Tamás Váradi, Andrejs Vasiljevs, Kadri Vider, and Jolanta Zabarskaite. *The Strategic Impact of META-NET on the Regional, National and International Level*. Language Resources and Evaluation, 50(2):351-374, 2016.



META-NET SRA, veröffentlicht im Frühjahr 2013



- Erste strategische Forschungsagenda unseres Gebiets
- Komplexer Prozess der Sammlung von Technologievisionen
- Etwa 200 Forscherinnen und Forscher haben mitgewirkt

SRIA V0.5 präsentiert beim META-NET FORUM 2015

- Basiert auf Strategiepapieren und Roadmaps, die von diversen EU-Projekten erstellt wurden, inklusive META-NET SRA (s.o.)



SRIA V0.9 präsentiert beim META-NET FORUM 2016

- Vorbereitet, präsentiert und unterstützt von der Cracking the Language Barrier Föderation
- Erläutert, wie die LT-Community für Mehrsprachigkeit im digitalen Binnenmarkt sorgen kann.



SRIA V1.0 präsentiert beim META-NET FORUM 2017

- Unterstützt und komplementiert die STOA-Studie.
- Wichtigste Empfehlung: Das Human Language Project initiieren.

Georg Rehm and Hans Uszkoreit, editors. *The META-NET Strategic Research Agenda for Multilingual Europe 2020*. Springer, Heidelberg, New York, Dordrecht, London, 2013.

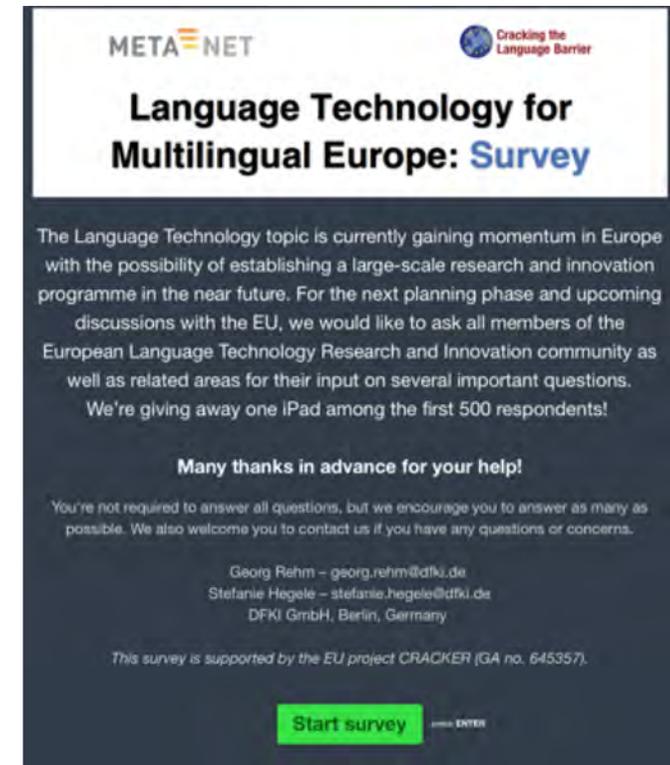
Georg Rehm, editor. *Language Technologies for Multilingual Europe: Towards a Human Language Project*. Strategic Research and Innovation Agenda. Dec. 2017. Version 1.0. Unveiled at META-FORUM 2017 in Brussels, Belgium, on Nov. 13/14, 2017. Prepared by the Cracking the Language Barrier federation, supported by CRACKER.

Georg Rehm, editor. *Language as a Data Type and Key Challenge for Big Data*. Strategic Research and Innovation Agenda for the Multilingual Digital Single Market. CRACKER and Cracking the Language Barrier federation, July 2016. Version 0.9. 04 July 2016. Supported by CRACKER and LT_Observatory.

Georg Rehm, editor. *Strategic Agenda for the Multilingual Digital Single Market – Technologies for Overcoming Language Barriers towards a truly integrated European Online Market*. CRACKER and LT_Observatory, April 2015. Version 0.5. 22 April 2015. Prepared by the EU-funded projects CRACKER and LT_Observatory.

“Multilingual Europe”-Umfrage

- Durchgeführt im Mai/Juni 2017
- 29 Fragen (16 offene, 13 multiple choice)
- 634 Teilnehmer aus 52 Ländern
- Sehr hohe Komplettierungsrate (27%)
- Durchschnitt: 35,48 Minuten (!)
- 97% unterstützen das HLP
- 87% glauben, dass „tiefes maschinelles Sprachverstehen bis 2030“ ein adäquates wissenschaftliches Ziel ist.



Georg Rehm, Jan Hajic, Josef van Genabith, and Andrejs Vasiljevs. “Fostering the Next Generation of European Language Technology: Recent Developments – Emerging Initiatives – Challenges and Opportunities.” In Nicoletta Calzolari (Conference Chair), Khalid Choukri, Thierry Declerck, Marko Grobelnik, Bente Maegaard, Joseph Mariani, Asuncion Moreno, Jan Odijk, and Stelios Piperidis, editors, Proceedings of the 10th Language Resources and Evaluation Conference (LREC 2016), pages 1586-1592, Portorož, Slovenia, May 2016. European Language Resources Association (ELRA).

Georg Rehm and Stefanie Hegele. “Language Technology for Multilingual Europe: An Analysis of a Large-Scale Survey regarding Challenges, Demands, Gaps and Needs.” In Nicoletta Calzolari, Khalid Choukri, Christopher Cieri, Thierry Declerck, Sara Goggi, Koiti Hasida, Hitoshi Isahara, Bente Maegaard, Joseph Mariani, H el ene Mazo, Asuncion Moreno, Jan Odijk, Stelios Piperidis, and Takenobu Tokunaga, editors, Proceedings of the 11th Language Resources and Evaluation Conference (LREC 2018), pages 3282-3289, Miyazaki, Japan, May 2018. European Language Resources Association (ELRA).



Language equality in the digital age

Towards a Human
Language Project

STUDY

Science and Technology Options Assessment

EPRS | European Parliamentary Research Service
Scientific Foresight Unit (STOA)
PE 581.621



**STOA Workshop
Europaparlament
10. Januar 2017**



WORKSHOP
STOA | SCIENCE AND TECHNOLOGY OPTIONS ASSESSMENT
Tuesday 10.01.2017 – 14:00-17:00
EUROPEAN PARLIAMENT, BRUSSELS,
PAUL-HENRY SPAAK BUILDING – ROOM P7C050

**Language equality in the digital age -
Towards a Human Language Project**

CHAIR:
Algirdas SAUDARGAS, MEP

SPEAKERS:
Maite MELERO,
Universitat Pompeu Fabra, Barcelona
Georg REHM,
Network of Excellence META-NET, Berlin
Andrejs VASILJEVS,
Tilde, Riga
Sabine KIRCHMEIER,
European Federation of National Institutions for Language (EFNIL), Copenhagen
István HORVÁTH,
Institute for Research on Minorities Issues, Chajnikošvár
Hans USZKOREIT,
German Research Centre for Artificial Intelligence (DFKI), Berlin

With the participation of:
JILL EVANS (MEP), Adám KÓSA (MEP), Csaba SÓGOR (MEP) and Evžen TOŠENOVSKÝ (MEP and STOA Panel Vice-Chair)

EPRS | European Parliamentary Research Service

- STOA-Studie – veröffentlicht im März 2017
- Empfiehlt der EC, das Human Language Project (HLP) zu initiieren
- Drei wesentliche Vorschläge im Bereich Forschungspolitik:
 - Forschung stärken und auf das HLP fokussieren
 - Europäische LT-Plattform von Daten und Services aufbauen
 - Technologiekluft zwischen den europäischen Sprachen überbrücken

STOA
Science and Technology Options Assessment



“Language equality”-Resolution

- EP-Resolution “Language equality in the digital age”
P8_TA(2018)0332 – basiert partiell auf der STOA-Studie
- Abstimmung im EP am 11. Sept. 2018:
592 Ja- vs. 45 Nein-Stimmen!
- **Unsere aktuellen Initiativen adressieren sehr viele der 45 Empfehlungen**
 - **25. Establish a large-scale, long-term LT funding programme**
 - 27. Europe has to secure its leadership in language-centric AI
 - **29. Create a European LT platform for sharing of services**
 - 31. Recommends an update of the META-NET white paper series



European Parliament
2014-2019



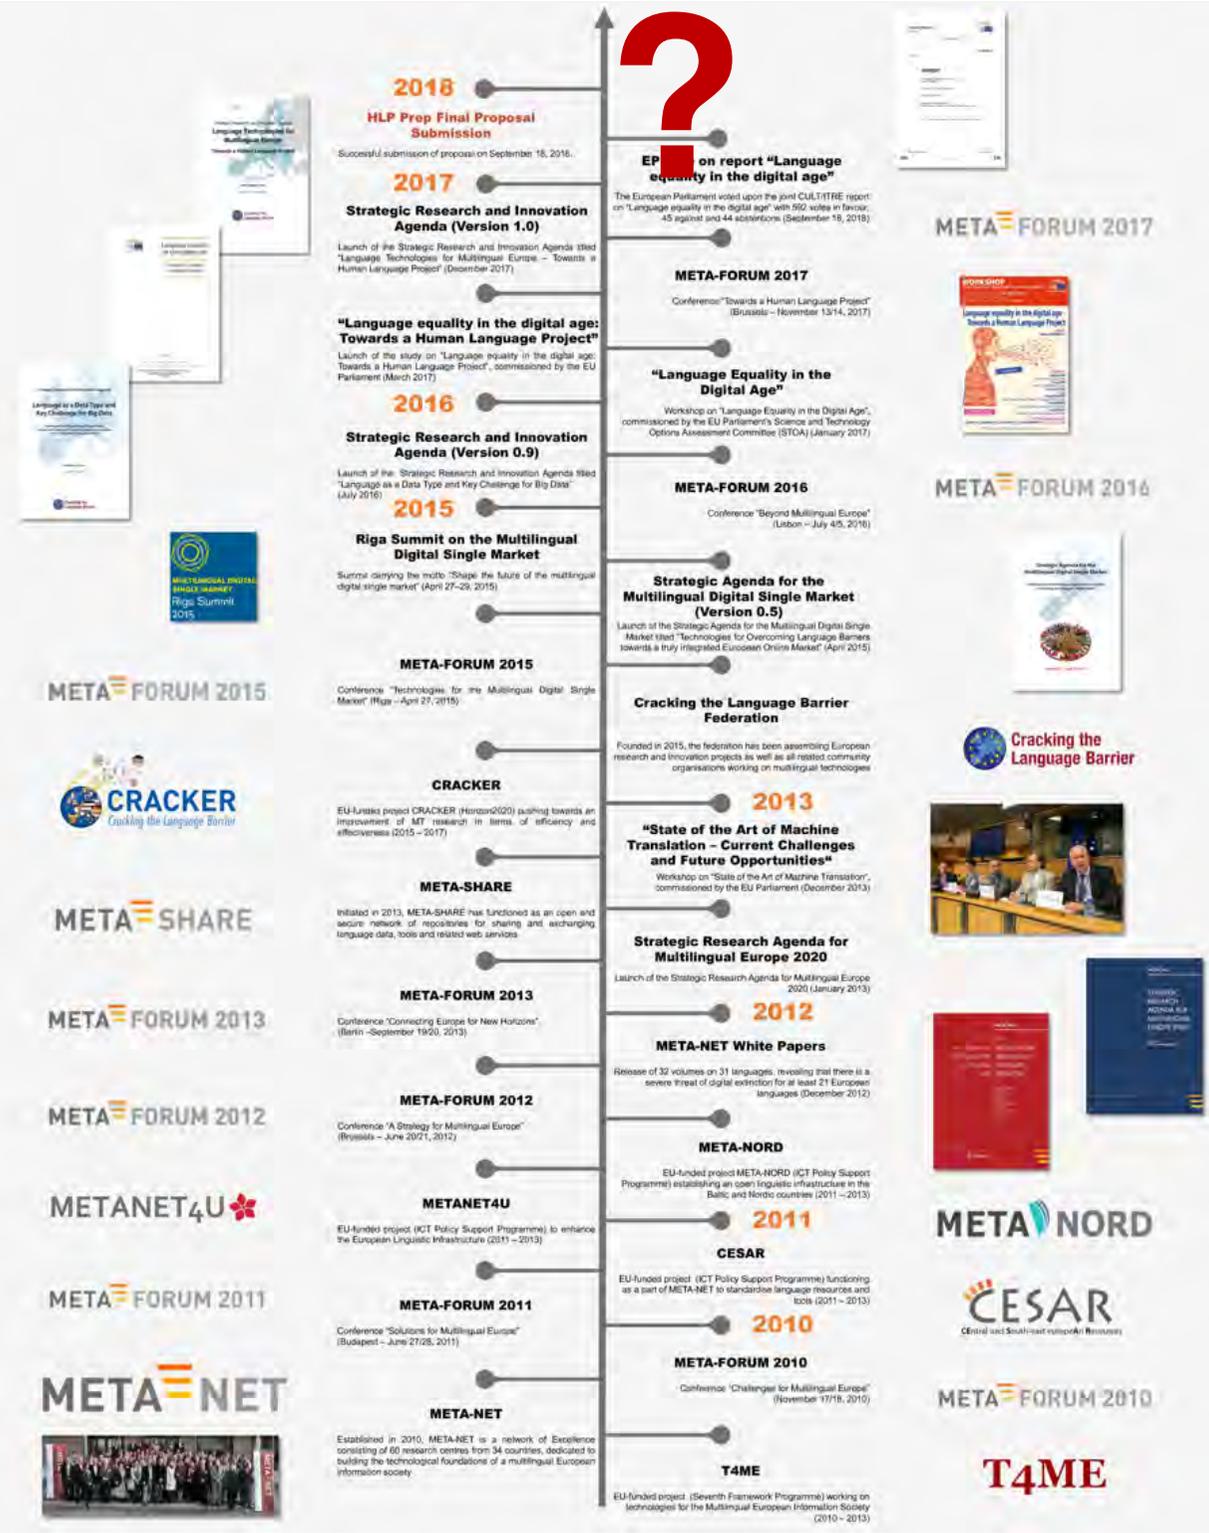
TEXTS ADOPTED
Provisional edition

P8_TA-PROV(2018)0332
Language equality in the digital age
European Parliament resolution of 11 September 2018 on language equality in the digital age (2018/2028(INI))

The European Parliament,

- having regard to Articles 2 and 3(3) of the Treaty on the Functioning of the European Union (TFEU),
- having regard to Articles 21(1) and 22 of the Charter of Fundamental Rights of the European Union,
- having regard to the 2003 UNESCO Convention for the Safeguarding of the Intangible Cultural Heritage,
- having regard to Directive 2003/98/EC of the European Parliament and of the Council of 17 November 2003 on the re-use of public sector information¹,
- having regard to Directive 2013/37/EU of the European Parliament and of the Council of 26 June 2013 amending Directive 2003/98/EC on the re-use of public sector information²,
- having regard to Decision (EU) 2015/2240 of the European Parliament and of the Council of 25 November 2015 establishing a programme on interoperability solutions and common frameworks for European public administrations, businesses and citizens (ISA2 programme) as a means for modernising the public sector³,
- having regard to the Council resolution of 21 November 2008 on a European strategy for multilingualism (2008/C 320/01)⁴,
- having regard to the Council decision of 3 December 2013 establishing the specific programme implementing Horizon 2020 – the Framework Programme for Research and

¹ OJ L 345, 31.12.2003, p. 90.
² OJ L 175, 27.6.2013, p. 1.
³ OJ L 318, 4.12.2015, p. 1.
⁴ OJ C 320, 16.12.2008, p. 1.



2018
HLP Prep Final Proposal Submission
 Successful submission of proposal on September 18, 2018.

2017
Strategic Research and Innovation Agenda (Version 1.0)
 Launch of the Strategic Research and Innovation Agenda titled "Language Technologies for Multilingual Europe – Towards a Human Language Project" (December 2017)

"Language equality in the digital age: Towards a Human Language Project"
 Launch of the study on "Language equality in the digital age: Towards a Human Language Project", commissioned by the EU Parliament (March 2017)

2016
Strategic Research and Innovation Agenda (Version 0.9)
 Launch of the Strategic Research and Innovation Agenda titled "Language as a Data Type and Key Challenge for Big Data" (July 2016)

2015
Riga Summit on the Multilingual Digital Single Market
 Summits carrying the motto "Shape the future of the multilingual digital single market" (April 27-29, 2015)

META-FORUM 2015
 Conference "Technologies for the Multilingual Digital Single Market" (Riga – April 27, 2015)

CRACKER
 EU-Lessica project CRACKER (Horizon2020) pushing towards an improvement of MT research in terms of efficiency and effectiveness (2015 – 2017)

META-SHARE
 Initiated in 2013, META-SHARE has functioned as an open and secure network of repositories for sharing and exchanging language data, tools and related web services

META-FORUM 2013
 Conference "Connecting Europe for New Horizons" (Berlin – September 19/20, 2013)

META-FORUM 2012
 Conference "A Strategy for Multilingual Europe" (Brussels – June 20/21, 2012)

METANET4U
 EU-funded project (ICT Policy Support Programme) to enhance the European Linguistic Infrastructure (2011 – 2013)

META-FORUM 2011
 Conference "Solutions for Multilingual Europe" (Budapest – June 27/28, 2011)

META-NET
 Established in 2010, META-NET is a network of Excellence consisting of 60 research centres from 34 countries, dedicated to building the technological foundations of a multilingual European information society

EP report "Language equality in the digital age"
 The European Parliament voted upon the joint CULT/ITRE report on "Language equality in the digital age" with 562 votes in favour, 45 against and 44 abstentions (September 18, 2018)

META-FORUM 2017
 Conference "Towards a Human Language Project" (Brussels – November 13/14, 2017)

"Language Equality in the Digital Age"
 Workshop on "Language Equality in the Digital Age", commissioned by the EU Parliament's Science and Technology Options Assessment Committee (STOA) (January 2017)

META-FORUM 2016
 Conference "Beyond Multilingual Europe" (Lisbon – July 4/5, 2016)

Strategic Agenda for the Multilingual Digital Single Market (Version 0.5)
 Launch of the Strategic Agenda for the Multilingual Digital Single Market titled "Technologies for Overcoming Language Barriers towards a truly integrated European Online Market" (April 2015)

Cracking the Language Barrier Federation
 Founded in 2015, the federation has been assembling European research and innovation projects as well as all related community organisations working on multilingual technologies

2013
"State of the Art of Machine Translation – Current Challenges and Future Opportunities"
 Workshop on "State of the Art of Machine Translation", commissioned by the EU Parliament (December 2013)

Strategic Research Agenda for Multilingual Europe 2020
 Launch of the Strategic Research Agenda for Multilingual Europe 2020 (January 2013)

2012
META-NET White Papers
 Release of 32 volumes on 31 languages, revealing that there is a severe threat of digital extinction for at least 21 European languages (December 2012)

META-NORD
 EU-funded project META-NORD (ICT Policy Support Programme) establishing an open linguistic infrastructure in the Baltic and Nordic countries (2011 – 2013)

2011
CESAR
 EU-funded project (ICT Policy Support Programme) functioning as a part of META-NET to standardise language resources and tools (2011 – 2013)

2010
META-FORUM 2010
 Conference "Challenges for Multilingual Europe" (November 17/18, 2010)

T4ME
 EU-funded project (Seventh Framework Programme) working on technologies for the Multilingual European Information Society (2010 – 2013)



META-FORUM 2015



META-SHARE

META-FORUM 2013

META-FORUM 2012

METANET4U

META-FORUM 2011

META-NET



META-FORUM 2017



META-FORUM 2016



Cracking the Language Barrier



META-NORD

CESAR

META-FORUM 2010

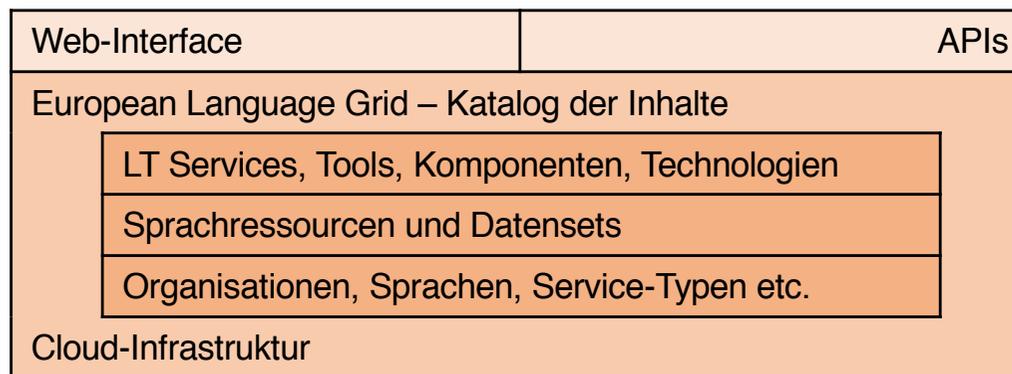
T4ME

ELG – Die Sprachtechnologie-Cloud-Plattform für Europa

- **Entwicklung einer funktionalen Sprachtechnologie-Cloud-Plattform für Europa**
- Marktplatz für die europäische Sprachtechnologie-Industrie
- Hunderte von LT-Services und -Ressourcen für alle europäischen Sprachen
- 30+ nationale Kompetenzzentren als starkes europäisches Netzwerk
- Stärkung des mehrsprachigen digitalen Binnenmarktes
- Evaluation durch 15-20 Pilotprojekte
- Interoperabilität von Services durch Containerisierung
- Gründung eines Spin-offs, um den langfristigen Betrieb und das Wachstum der Plattform zu gewährleisten

Konsortium

- DFKI GmbH (Koordinator) (DE)
- ILSP, R.C. “Athena“ (GR)
- Universität Sheffield (UK)
- Charles Universität (CZ)
- ELDA (FR)
- Tilde (LV)
- SAIL LABS GmbH (AT)
- Expert System Iberia (ES)
- Universität Edinburgh (UK)



- ICT-29-2018: **Multilingual Next Generation Internet**
 - Zwei Sub-Topics (Gesamtbudget 25M€)
- ICT-29 a) **European Language Grid**
 - Eine Innovation Action (7M€)
- ICT-29 b) **Domain-specific/challenge-oriented HLT**
 - Sechs Research and Innovation Actions (je 3M€)

Human Language Project

- **Ziel:** **Tiefes maschinelles Sprachverstehen bis 2030**
- **Alle offiziellen europäischen und viele weitere Sprachen**
- **Breite Abdeckung, hohe Qualität, hohe Präzision**
- **Ganz neue Ansätze, Algorithmen, Datensets**
- **Alle Modalitäten:** Text, Texttypen, Speech, Video etc.
- **Alle Plattformen:** Messaging, Telefonie, Social, Mobil, IoT, Roboter, smarte Geräte, persönliche Assistenten etc.
- **Kulturübergreifend:** Wissen, Bräuche, Formalitäten, Humor, Emotion, Subjektivität, Meinungen, Filterblase etc.
- **Wie?** **Als das nächste EU FET Flagship-Projekt!**

HLP Prep Antrag

- FET Flagship Projekte: 1 Mrd. € Förderung für 10 Jahre
- Aktuelle Flagships: HBP, Graphene, Quantum (2019)
- H2020 FETFLAG-01-2018 für kleine Projekte zur Vorbereitung von Anträgen (1M€, 12 Monate Laufzeit)
- Unser Antrag: “Human Language Project Preparation”
- Konsortium mit 16 Partnern, koordiniert vom DFKI
- Bisher 375+ Unterstützungsbriefe, inklusive 16 Ministerien und 24 nationalen Sprachinstitutionen
- Mehr Informationen: <http://human-language-project.eu>



Das HLP ist ein großes, langfristig angelegtes Forschungs-, Entwicklungs- und Innovationsprogramm, in dem Grundlagen- und angewandte Forschung und Entwicklung sowie Innovation und Kommerzialisierung eng zusammenarbeiten, um bahnbrechende Technologien für das **tiefe maschinelle Sprachverstehen bis 2030** zu entwickeln.

Im HLP werden u.a. die folgenden Gebiete kollaborieren:

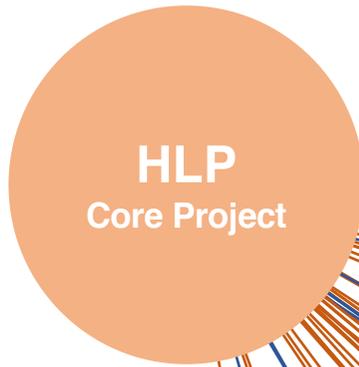
Primäre Gebiete:

- Computerlinguistik & LT
- Linguistik
- Künstliche Intelligenz
- Wissenstechnologien

Sekundäre Gebiete:

- Gesellschaftswissenschaften und Digital Humanities
- Informatik
- Kognitionswissenschaft

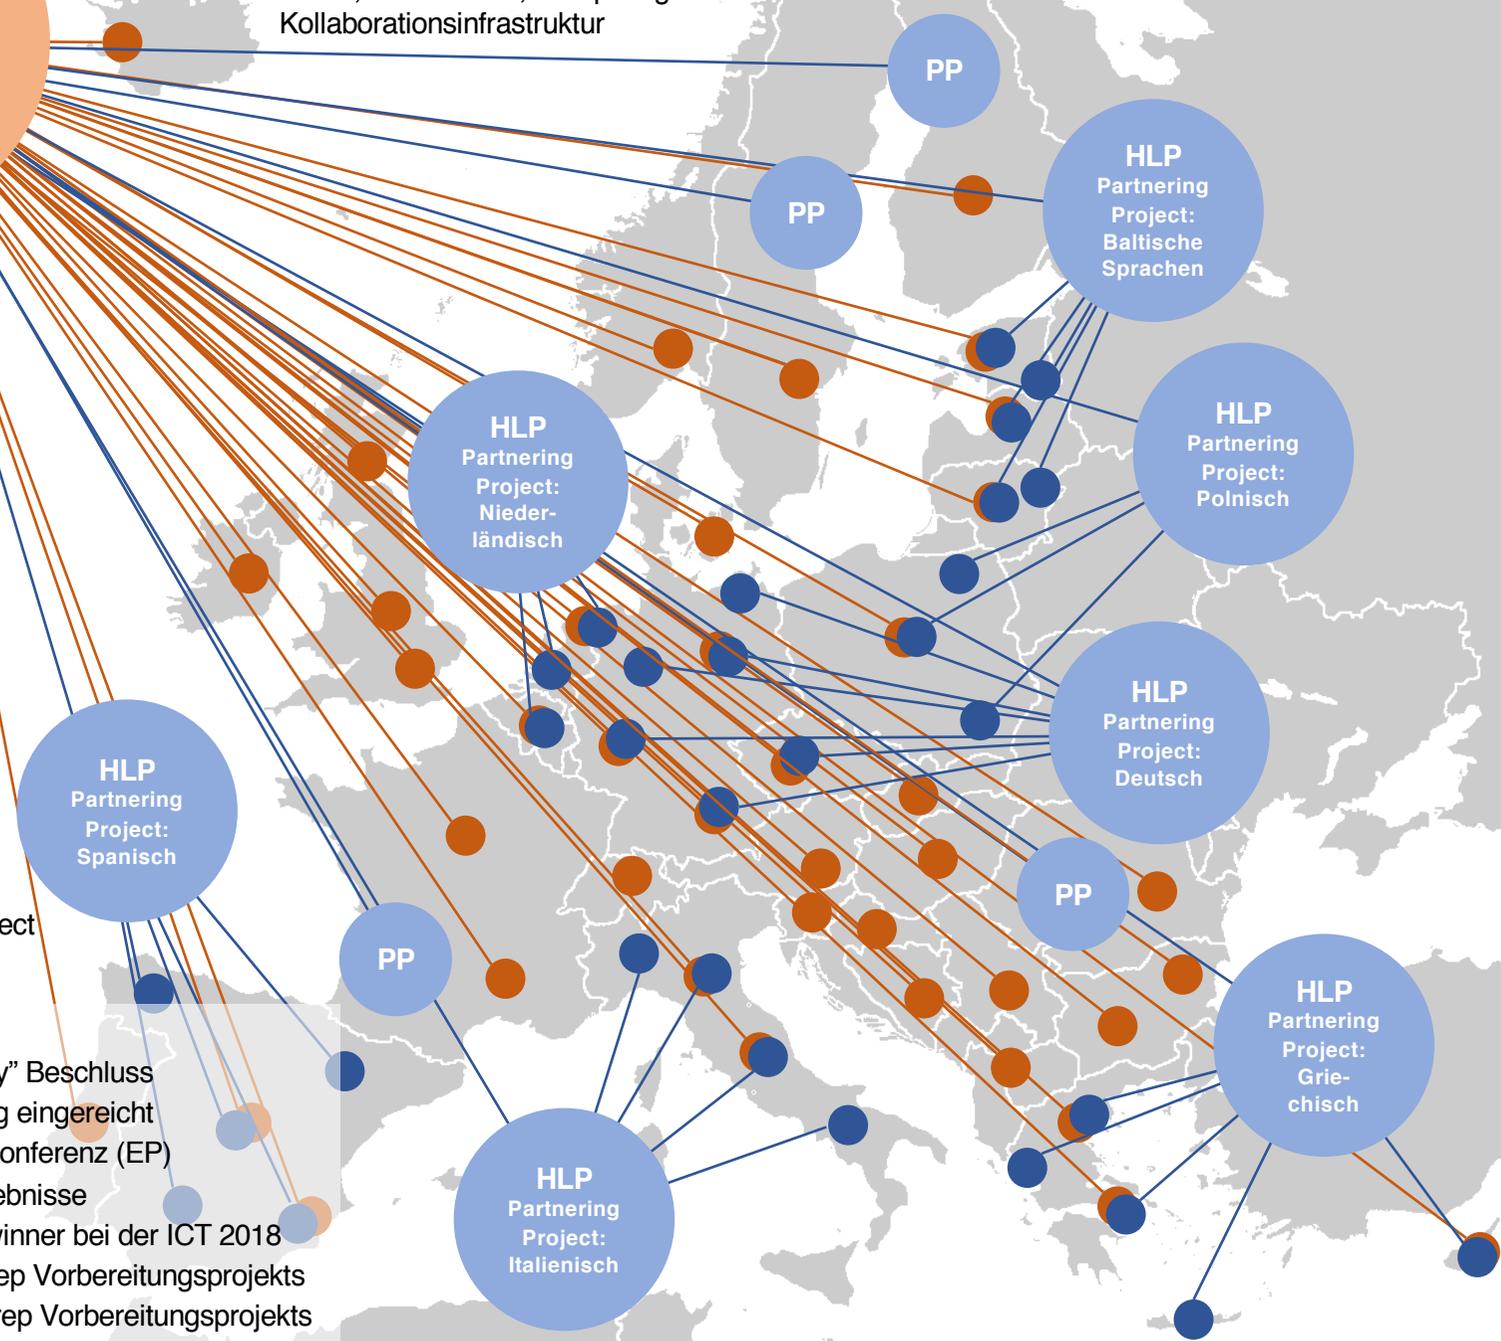




**HLP
Core Project**

HLP Core Project

- Koordination des Flagships (CP und PPs)
- Weiterentwicklung der Roadmap
- Allgemeine Forschung und Technologieentwicklung
- Daten, Ressourcen, Computing- und Kollaborationsinfrastruktur



HLP Partnering Projects

- Sprachspezifische und/oder regionale Konsortien, die Forschung für ihre eigenen Sprachen betreiben
- Enge Kooperation mit dem Core Project
- CP und PP teilen sich einige Partner

Wichtige Daten und nächste Schritte

- 11. Sep. 2018: EP "Language equality" Beschluss
- 18. Sep. 2018: HLP Prep Hauptantrag eingereicht
- 27. Sep. 2018: "Language equality" Konferenz (EP)
- 29. Nov. 2018: Bekanntgabe der Ergebnisse
- 04. Dez. 2018: Ankündigung der Gewinner bei der ICT 2018
- 01. Mrz. 2019: Ggf. Start des HLP Prep Vorbereitungsprojekts
- 29. Feb. 2020: Ggf. Ende des HLP Prep Vorbereitungsprojekts

1. Herausforderung

**Das mehrsprachige Europa:
Sprachtechnologien für alle europäischen Sprachen?**

2. Herausforderung

**Online-Desinformationskampagnen:
Technische Lösungsansätze gegen „Fake News“?**

3. Herausforderung

**Digitaler Content:
Technologien für die effiziente Content-Kuratierung?**

ARD.de-Spezial: Fake News



Falschmeldungen und Propaganda
Fake News: Wie sie wirken und wie man sie entlarvt
 Flüchtlinge urinieren gegen eine Kirche, Hillary Clinton leitet einen Kinderporno-Ring und es gehen Koran-CDs mit Gift um. Das sind Fake News - also Lügenmärchen, die gezielt verbreitet werden. Sie beeinflussen das gesellschaftliche Klima und können sich auf Wahlen auswirken. Auch für die kommende Bundestagswahl wird mit Fake News und Social Bots gerechnet. Das ARD.de-Spezial zeigt, wer dahinter steckt, was Fake News bewirken und wie man sie erkennt.

Falschmeldungen: Was steckt dahinter?



Hintergrund
Was sind Fake News?
 Ist die Nachricht echt oder frei erfunden? Was sind Fake News? Was ist Spear Phishing? Deutsche Politiker warnen vor gezielter Manipulation. 1 mehr



Wie eine Ente im Netz entsteht
Das Geschäft mit den Fake News
 Die Falschmeldung, der Papst unterstütze Donald Trump, wurde 960.000 Mal auf Facebook geteilt. Wer sind die Menschen, die gezielt unwahre Artikel streuen? 1 hr



Wahlkampf
Die Macht der Social Bots
 Computerprogramme, die in sozialen Medien wie Nutzer agieren, mischten schon im Ukraine-Konflikt, dem Brexit-Referendum und im US-Wahlkampf mit. 1 dradio

Explore **INVERSE** Follow

Innovation Fake News share this

Artificial Intelligence is Going to Destroy Fake News
 But A.I. can also cause the volume of fake news to explode.

By Rosalie Chan on February 21, 2017 Filed Under AI, Politics & Social Networks

With the rise of email came the rise of spam filling inboxes. Email has become sophisticated faster than spamming technology and now, the internet's junk mail is often caught in a folder; out of sight and out of mind are messages with the subject line "Kindly get back to me urgently" and the greeting "Dear Beneficiary."

The worlds may be virtual but the prize is very real.

MACHINE-ACTIONS

In the fight against fake news, artificial intelligence is waging a battle it cannot win



There are now 114 fact-checking initiatives in 47 countries

By **Alexios Mantzarlis** • February 28, 2017



SOURCE **DUKE REPORTERS' LAB**

Facts may be passé, but fact-checking appears to be a growth industry.



Falschmeldungen und Propaganda
Fake News: Wie sie wirken und wie man sie entlarvt

Falschmeldungen: W



Hintergrund
Was sind Fake News?
Ist die Nachricht echt oder frei erfunden? Sind Fake News? Was ist Spear Phishing? Deutsche Politiker warnen vor gezielter Manipulation. Mehr

OUR PICKS LATEST POPULAR

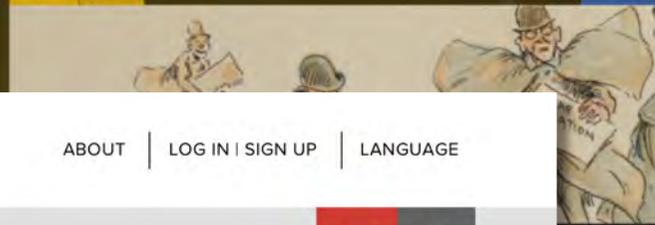
MACHINE-ACTIONS

In the fight against intelligent



Innovation Fake News

share this



ABOUT | LOG IN | SIGN UP | LANGUAGE

FIRST DRAFT

Home Projects Latest Resources Topics



Fake news. It's complicated.



To understand the misinformation ecosystem, here's a break down of the types of fake content, content creators motivations and how it's being disseminated

by: Claire Wardle, First Draft
Date: February 16, 2017


4 mins ⌚

Recommend: 70

Log in to save this article

Add to a pack 📁

Share:

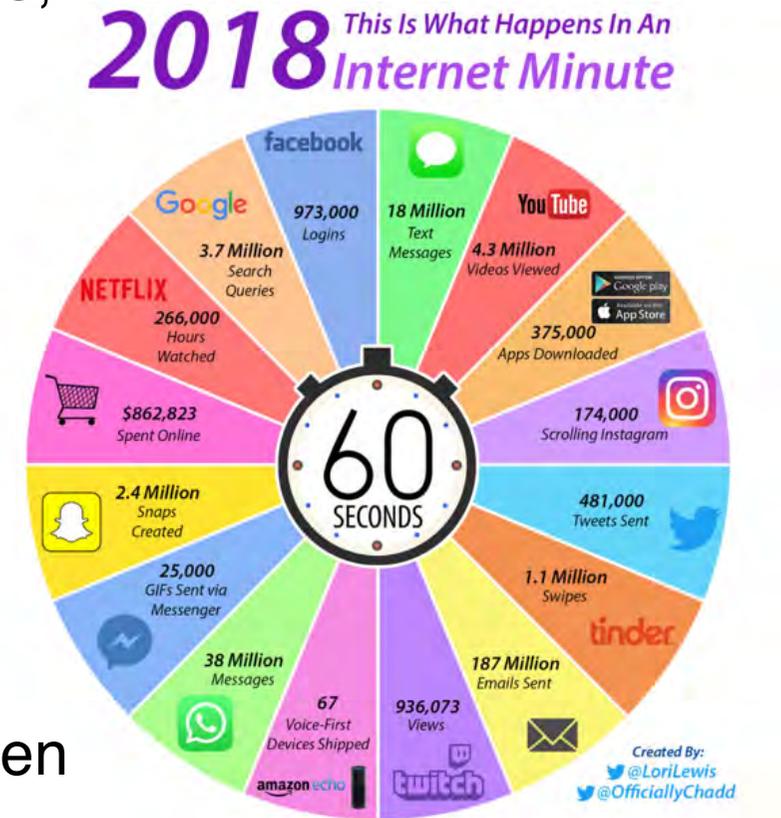


SOURCE DUKE REPORTERS' LAB

Facts may be passé, but fact-checking appears to be a growth industry.

Relevanz Digitaler Medien

- Immens zunehmende (global)politische, gesellschaftliche und ökonomische Relevanz
- Facebook: >2 Mrd. Nutzer
- WhatsApp: >1 Mrd. Nutzer
- Instagram: >1 Mrd. Nutzer
- Öffentliche Debatten finden in erster Linie online statt.
- Diskussionen zu aktuellen Themen, Parteien, Wahlen, Personen etc. werden durch Social-Media-Kampagnen sehr geschickt beeinflusst und manipuliert.



Viralität und „Fake News“

- Inhalte werden ohne Kontrollinstanz publiziert, über soziale Medien entdeckt und, falls relevant, zügig geteilt
- Dies geschieht oft *ohne* Lektüre oder kritische Prüfung
- Ziel: Viralität → Reichweite → Klicks → Werbeeinnahmen
- Ziel: die Meinung bestimmter Personen manipulieren
- Nicht alle „journalistisch“ aussehenden Inhalte fühlen sich tatsächlich der Wahrheit verpflichtet
- Bürde der kritischen Prüfung liegt heute bei den Lesern
- „Fake News“: Etikett für mehrere Klassen von Inhalten

Georg Rehm. "An Infrastructure for Empowering Internet Users to handle Fake News and other Online Media Phenomena". In Georg Rehm and Thierry Declerck, editors, *Language Technologies for the Challenges of the Digital Age: Proceedings of the GSCL Conference 2017*, Berlin, September 2017. Gesellschaft für Sprachtechnologie und Computerlinguistik e.V. 13.-15. September 2017.

Sieben Klassen von Falschnachrichten



		Satire oder Parodie: führt Menschen aber dennoch manchmal auf das Glatteis	Falscher Zusammenhang: wenn Titel und Fotos den Inhalt nicht stützen	Irreführender Inhalt: Nutzung von Informationen, um etwas/jmd. In ein schlechtes Licht zu rücken	Falscher Kontext: wenn echte Inhalte im falschen Kontext präsentiert werden	Betrügerische Inhalte: wenn echte Quellen imitiert werden	Manipulierter Inhalt: Manipulation von Inhalten zum Zweck der Täuschung	Fabrizierter Inhalt: basiert zu 100% nicht auf Tatsachen, geschrieben um zu täuschen
Charakteristika	Clickbait		X	X	?		?	?
	Desinformation			X	X		X	X
	Politisch gefärbt		?	X	?		?	X
	Schlechter Journalismus		X	X	X			
Intentionen der Urheber	Parodie	X				?		?
	Provokation					X	X	X
	Profit	?	X			X		X
	Täuschung		X	X	X	X	X	X
	Politik beeinflussen			X	X		X	X
	Meinungen beeinflussen			X	X	X	X	X

Unterschiedliche Klassen von Falschnachrichten und ihre jeweiligen Charakteristika und Intentionen (nach Wardle, 2017; Walbrühl, 2017; Rubin et al., 2015; Holan, 2016; Weedon et al., 2017)

		Satire oder Parodie: führt Menschen aber dennoch manchmal auf das Glatteis	Falscher Zusammenhang: wenn Titel und Fotos den Inhalt nicht stützen	Irreführender Inhalt: Nutzung von Informationen, um etwas/jmd. In ein schlechtes Licht zu rücken	Falscher Kontext: wenn echte Inhalte im falschen Kontext präsentiert werden	Betrügerische Inhalte: wenn echte Quellen imitiert werden	Manipulierter Inhalt: Manipulation von Inhalten zum Zweck der Täuschung	Fabrizierter Inhalt: basiert zu 100% nicht auf Tatsachen, geschrieben um zu täuschen
Charakteristika	Clickbait		X	X	?		?	?
	Desinformation			X	X		X	X
	Politisch gefärbt		?	X	?		?	X
	Schlechter Journalismus		X	X	X			
Intentionen der Urheber	Parodie	Parodie X	Clickbait Schlechter Journalismus			Desinformation Bewusste Täuschung Versuch der Beeinflussung von Meinungen und Politik		
	Provokation					X	X	X
	Profit	?	X			X		X
	Täuschung		X	X	X	X	X	X
	Politik beeinflussen			X	X		X	X
	Meinungen beeinflussen			X	X	X	X	X

Unterschiedliche Klassen von Falschnachrichten und ihre jeweiligen Charakteristika und Intentionen (nach Wardle, 2017; Walbrühl, 2017; Rubin et al., 2015; Holan, 2016; Weedon et al., 2017)

Beispiel 1: Clickbait-Erkennung

- Automatische Prüfung arbiträrer Behauptungen bis auf Weiteres technisch nicht möglich
- Annäherung: Ermittlung der Haltung eines Textes zu einem Thema („Stance Detection“)

Annotierte Titel/Artikel-Paare	49.972	100%	
Klasse: <i>unrelated</i>	36.545	73%	Schritt 1: Klassifikation <i>related</i> vs. <i>unrelated</i> = Clickbait-Erkennung
Klasse: <i>discuss</i>	8.909	18%	Schritt 2: Nur wenn sich der Titel auf den Text <i>bezieht</i> , kann <i>discuss</i> , <i>agree</i> , <i>disagree</i> klassifiziert werden.
Klasse: <i>agree</i>	3.678	7%	
Klasse: <i>disagree</i>	840	2%	

DFKI-System	Relatedness	93,29
	Drei Klassen	88,36
	Gewichtet	89,59

Mit einer Präzision von 89,59 haben wir bei der ersten Fake News Challenge (FNC1) Platz 9 von 50 Teams erreicht.

Peter Bourgonje, Julian Moreno Schneider, and Georg Rehm. "From Clickbait to Fake News Detection: An Approach based on Detecting the Stance of Headlines to Articles". In Octavian Popescu and Carlo Strapparava, editors, *Proceedings of Natural Language Processing meets Journalism – EMNLP 2017 Workshop (NLPMJ 2017)*, Copenhagen, Denmark, September 2017. 7. September.

Beispiel 2: Beleidigende Sprache

- Beleidigende Beiträge verhindern konstruktive Online-Debatten
- Klassifikationsexperimente mit verschiedenen Datensets
- Englische Tweets: *neutral*, *rassistisch*, *sexistisch*
- Deutsche Tweets: *hasserfüllt* vs. *nicht hasserfüllt*
- Wikipedia-Talk-Seiten mit Nutzerkommentaren
 - A1: *Angriff auf eine Person* vs. *kein Angriff auf eine Person*
 - A2: *Aggression* vs. *keine Aggression*

	Tweets EN (15.979)	Tweets DE (469)	Wikipedia A1 (11.304)	Wikipedia A2 (11.304)
Precision	85,67	78,19	80,90	80,42
Recall	77,45	78,16	80,97	80,46

Schlussfolgerungen: Viel versprechende Ergebnisse, allerdings stellt die Aufgabe eine große Herausforderung dar – Teilnahme an SemEval 2019.

Peter Bourgonje, Julian Moreno Schneider, and Georg Rehm. "Automatic Classification of Abusive Language and Personal Attacks in Various Forms of Online Communication". In Georg Rehm and Thierry Declerck, editors, *Language Technologies for the Challenges of the Digital Age: Proceedings of the GSCL Conference 2017*, Berlin, September 2017. Gesellschaft für Sprachtechnologie und Computerlinguistik e.V. 13.-15. September 2017.

Julian Moreno Schneider, Roland Roller, Peter Bourgonje, Stefanie Hegele, and Georg Rehm. "Towards the Automatic Classification of Offensive Language and Related Phenomena in German Tweets". In Josef Ruppenhofer, Melanie Siegel, and Michael Wiegand, editors, *Proceedings of the GermEval Workshop 2018 – Shared Task on the Identification of Offensive Language*, pages 95-103, Vienna, Austria, September 2018. 21 September 2018.

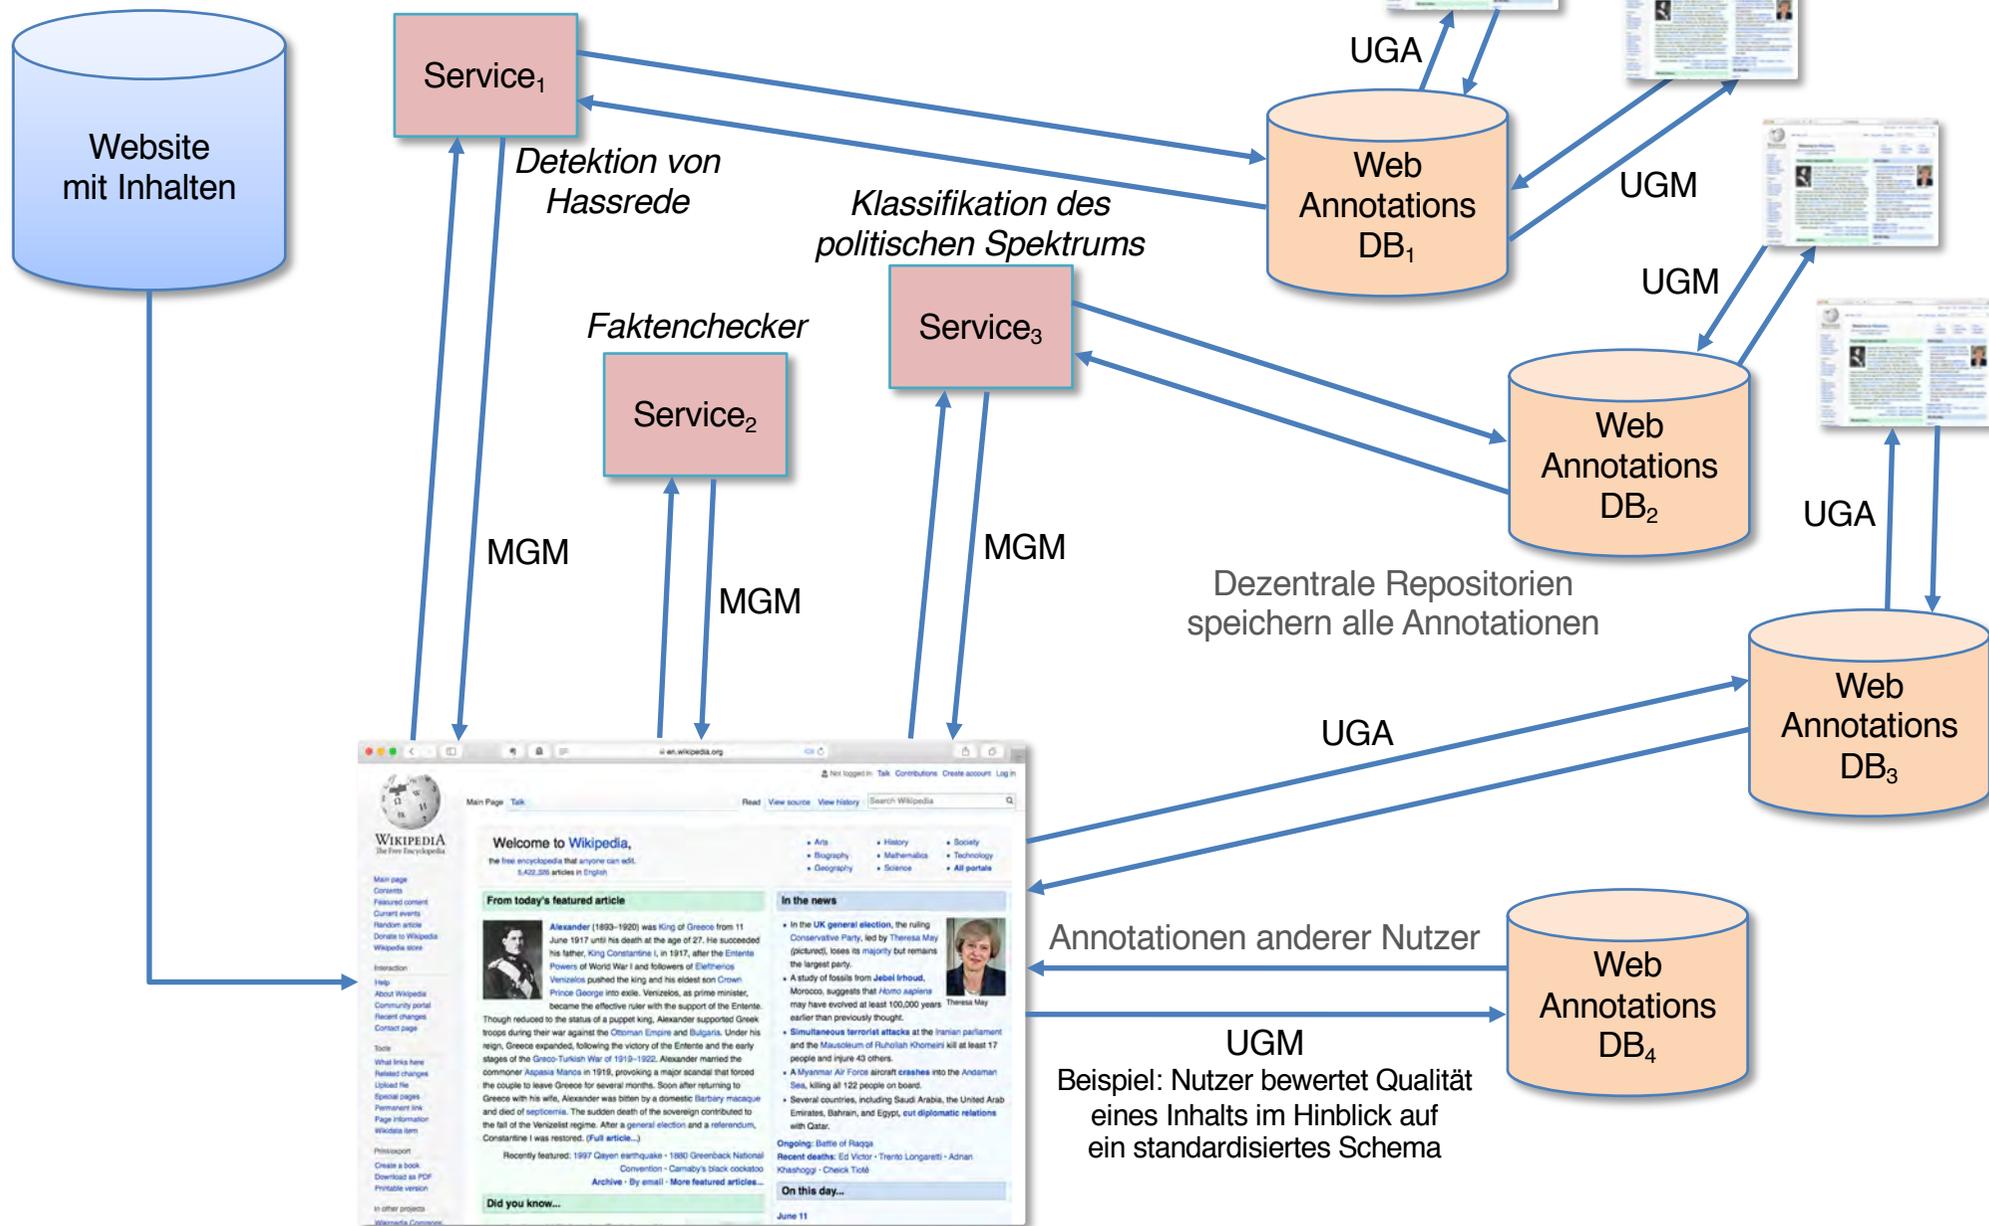
Lösungsvorschlag: Infrastruktur

- Inhalte werden im/über das World Wide Web konsumiert
- Ziel: Leser im Umgang mit Inhalten unterstützen, Fakten prüfen, Täuschungsversuche erkennen etc.
- Im Browser z.B. Ampelmetaphorik: Rot, Gelb, Grün
- Somit Filterblasen- und Netzwerkeffekte ausbalancieren
- Kombination aus automatischen Werkzeugen und menschlicher Schwarmintelligenz
- 2019: Kollaboration mit W3C Credible Web CG 
- 2019: Re-submission des EU-Antrags PROTECT-IT

Georg Rehm. "An Infrastructure for Empowering Internet Users to handle Fake News and other Online Media Phenomena". In Georg Rehm and Thierry Declerck, editors, *Language Technologies for the Challenges of the Digital Age: Proceedings of the GSCL Conference 2017*, Berlin, September 2017. 13.-15.09.2017.

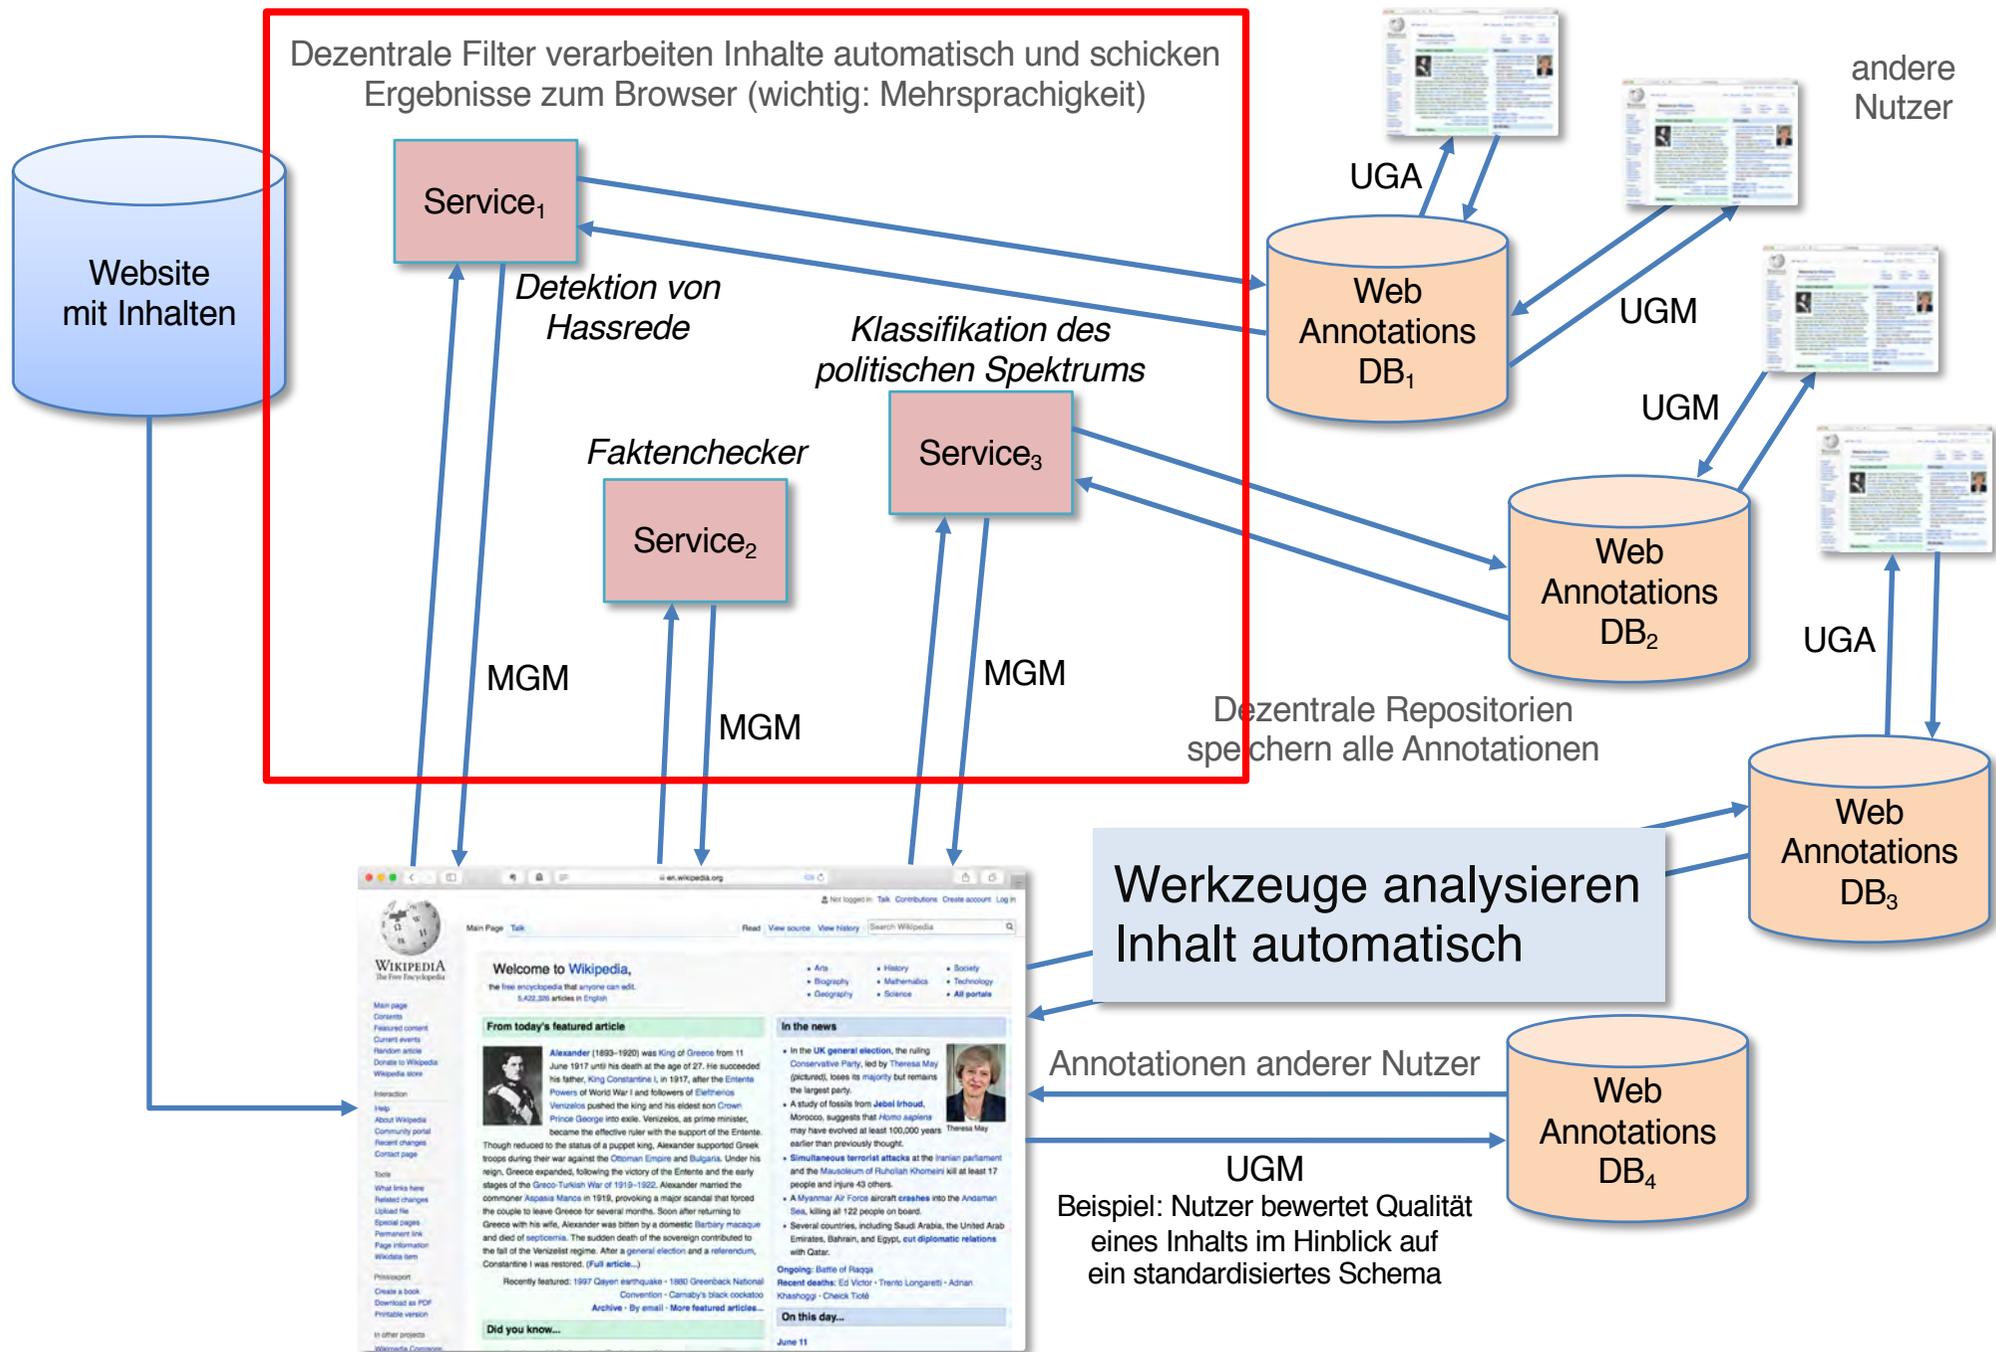
Georg Rehm, Julian Moreno Schneider, and Peter Bourgonje. "Automatic and Manual Web Annotations in an Infrastructure to handle Fake News and other Online Media Phenomena." In Nicoletta Calzolari, Khalid Choukri, Christopher Cieri, Thierry Declerck, Sara Goggi, Koiti Hasida, Hitoshi Isahara, Bente Maegaard, Joseph Mariani, H el ene Mazo, Asuncion Moreno, Jan Odijk, Stelios Piperidis, and Takenobu Tokunaga, editors, *Proceedings of the 11th Language Resources and Evaluation Conference (LREC 2018)*, pages 2416-2422, Miyazaki, Japan, May 2018. European Language Resources Association (ELRA).

Dezentrale Filter verarbeiten Inhalte automatisch und schicken Ergebnisse zum Browser (wichtig: Mehrsprachigkeit)



Browser unterstützt Infrastruktur nativ und aggregiert unterschiedlichen Bewertungen, Kommentare und Meinungen über einen Inhalt in klare Botschaften oder Warnungen

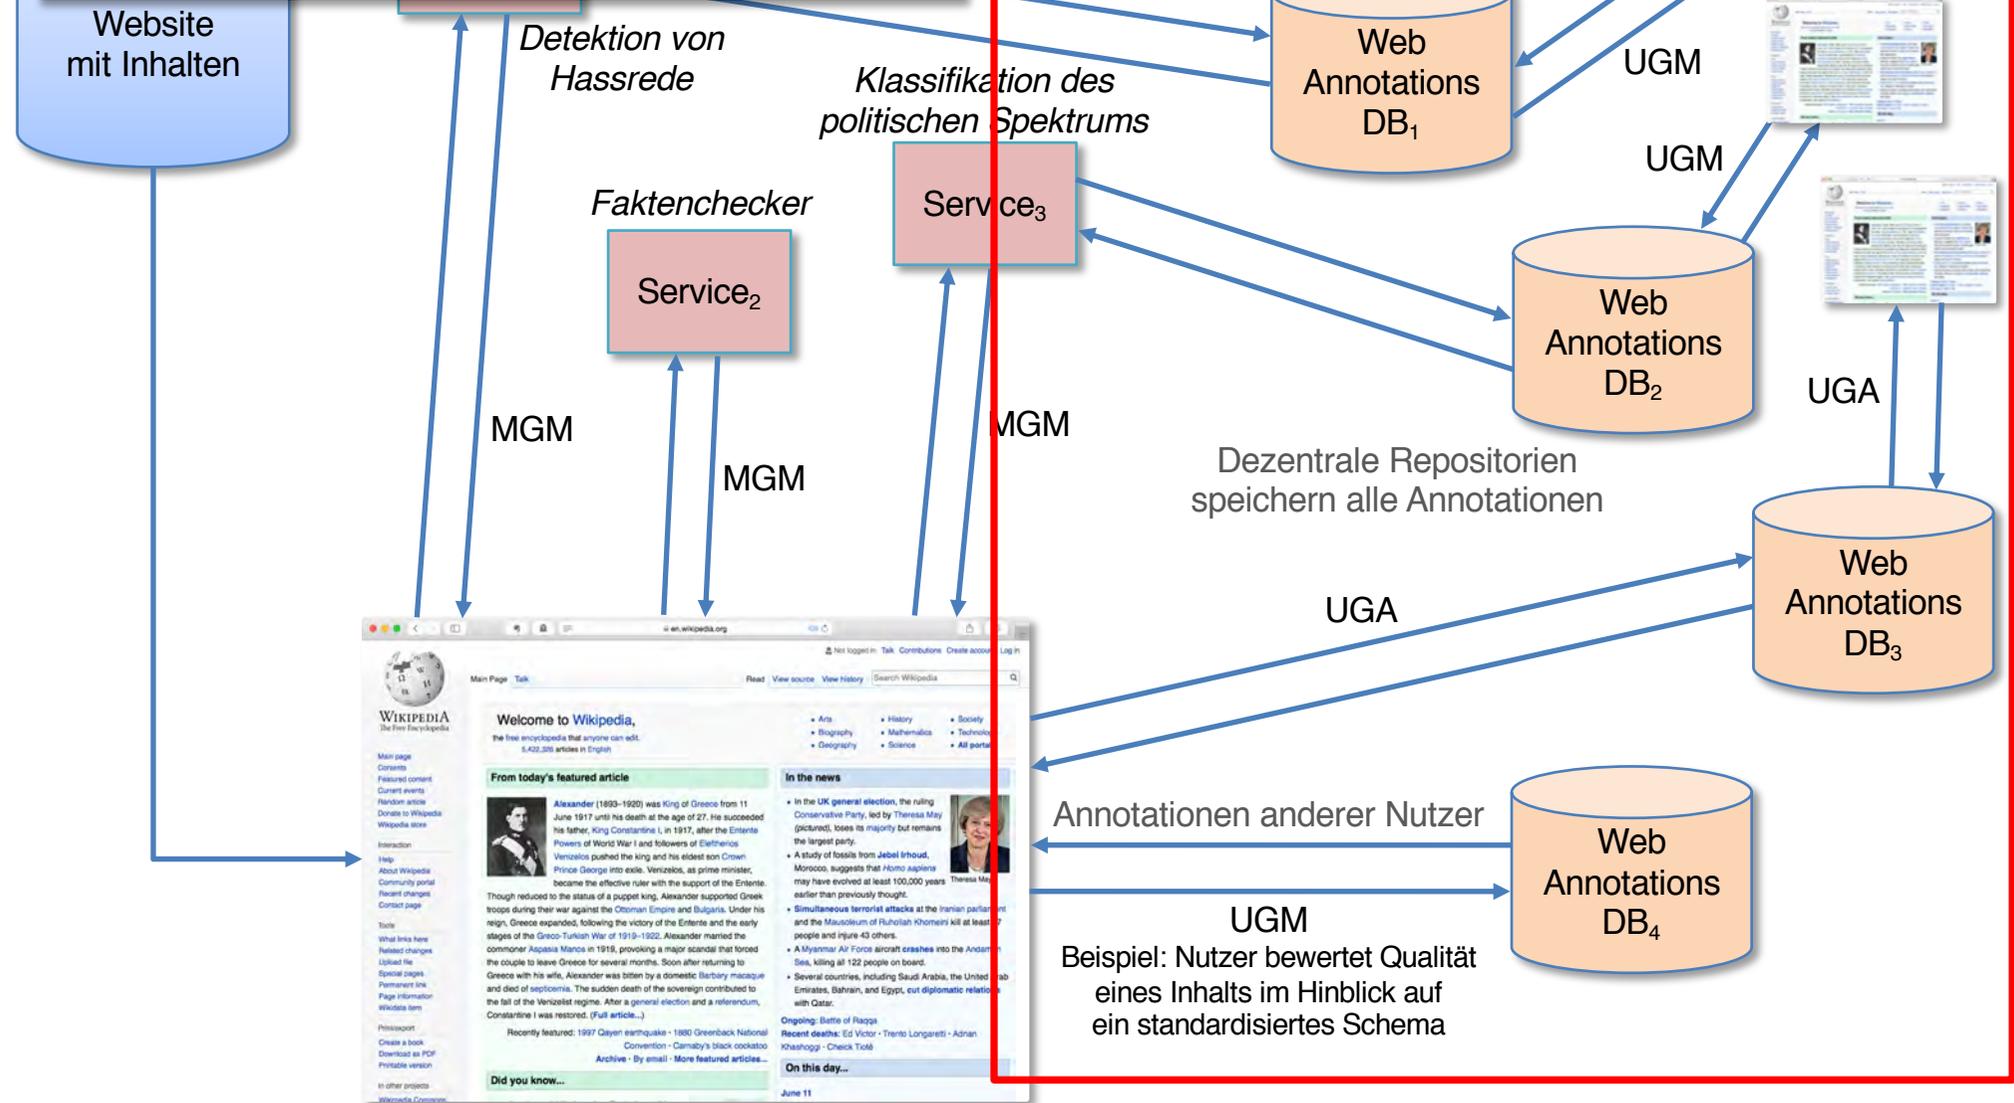
UGA: User-generierte Annotationen (Freitext)
 UGM: User-generierte Metadaten (standardisiert)
 MGM: Maschinen-generierte Metadaten (standardisiert)



Browser unterstützt Infrastruktur nativ und aggregiert unterschiedlichen Bewertungen, Kommentare und Meinungen über einen Inhalt in klare Botschaften oder Warnungen

UGA: User-generierte Annotationen (Freitext)
 UGM: User-generierte Metadaten (standardisiert)
 MGM: Maschinen-generierte Metadaten (standardisiert)

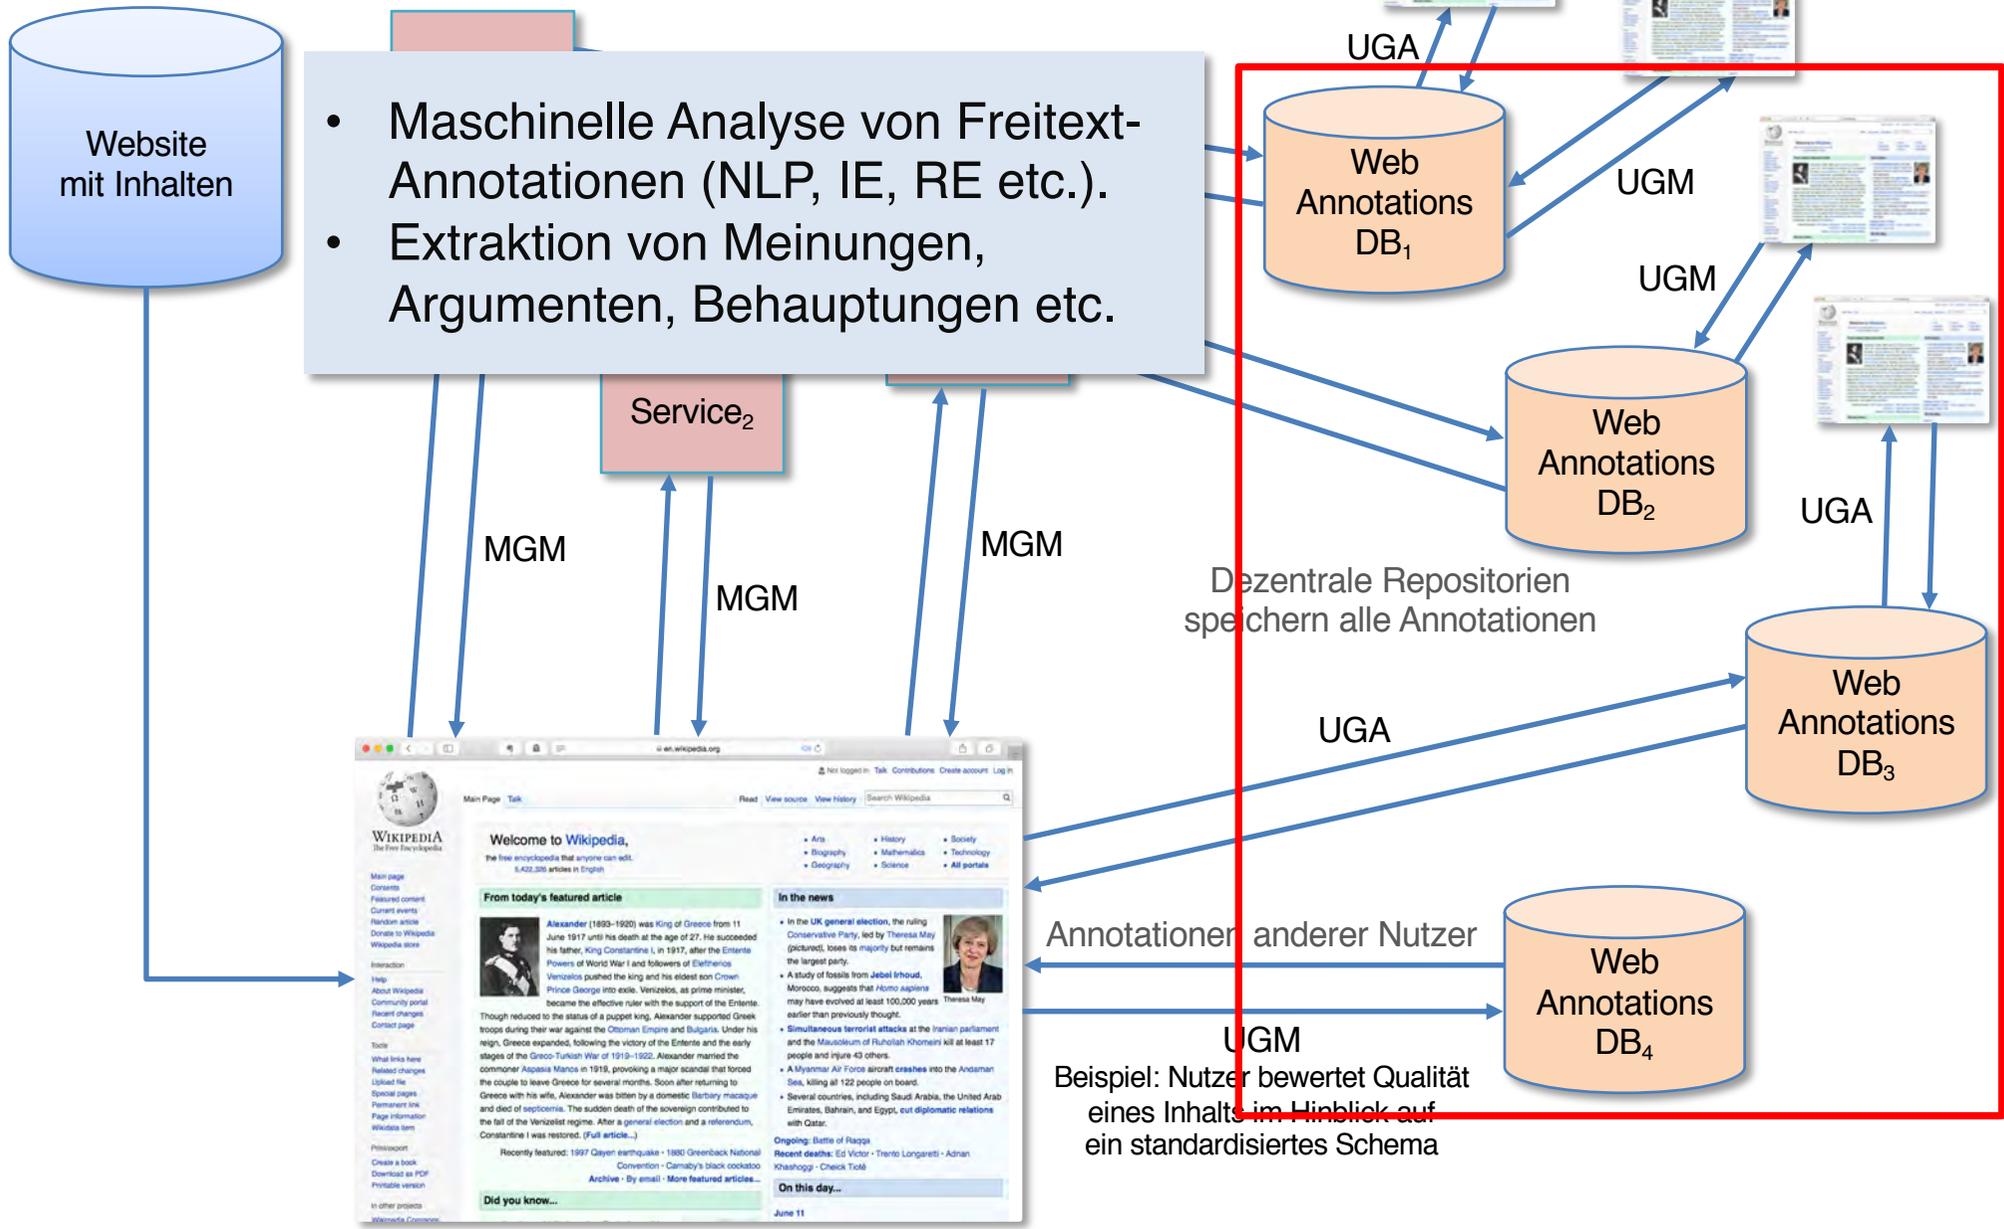
- Maschinelle Ergebnisse sowie auch Freitext-Anmerkungen werden als W3C Web Annotations gespeichert.



Browser unterstützt Infrastruktur nativ und aggregiert unterschiedlichen Bewertungen, Kommentare und Meinungen über einen Inhalt in klare Botschaften oder Warnungen

UGA: User-generierte Annotationen (Freitext)
 UGM: User-generierte Metadaten (standardisiert)
 MGM: Maschinen-generierte Metadaten (standardisiert)

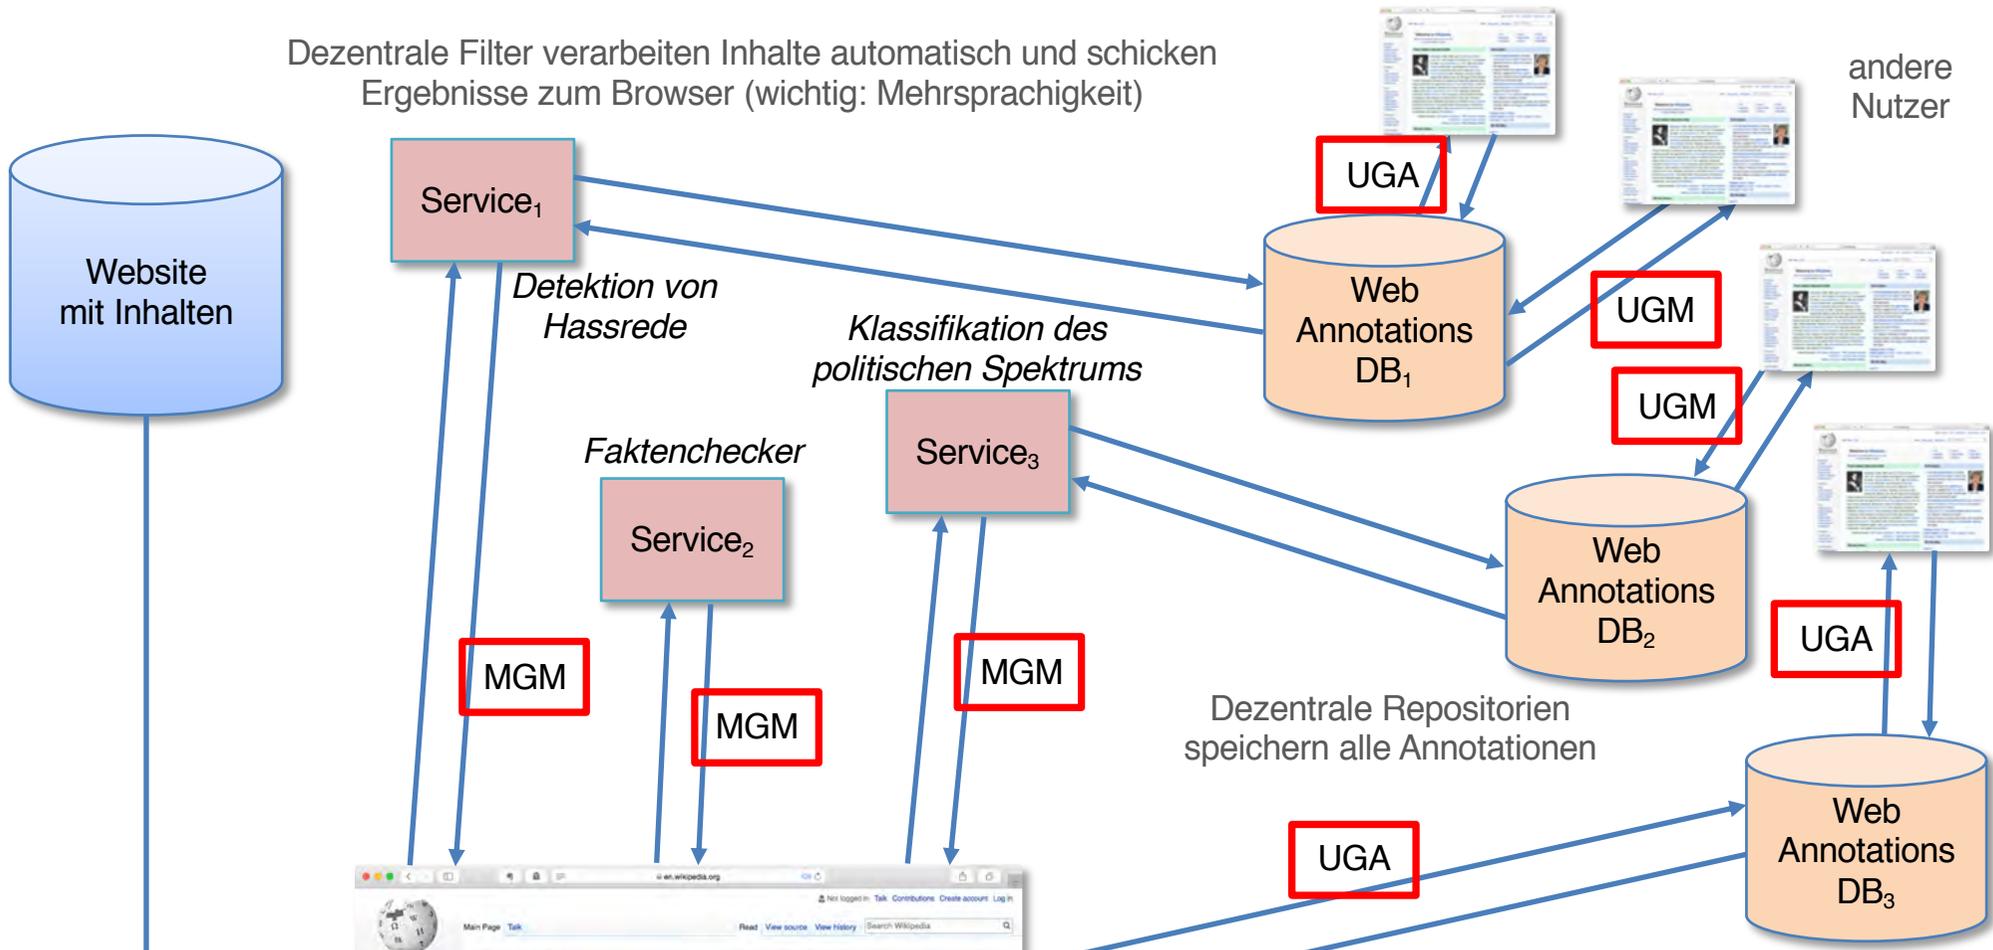
Dezentrale Filter verarbeiten Inhalte automatisch und schicken Ergebnisse zum Browser (wichtig: Mehrsprachigkeit)



Browser unterstützt Infrastruktur nativ und aggregiert unterschiedlichen Bewertungen, Kommentare und Meinungen über einen Inhalt in klare Botschaften oder Warnungen

UGA: User-generierte Annotationen (Freitext)
 UGM: User-generierte Metadaten (standardisiert)
 MGM: Maschinen-generierte Metadaten (standardisiert)

Dezentrale Filter verarbeiten Inhalte automatisch und schicken Ergebnisse zum Browser (wichtig: Mehrsprachigkeit)

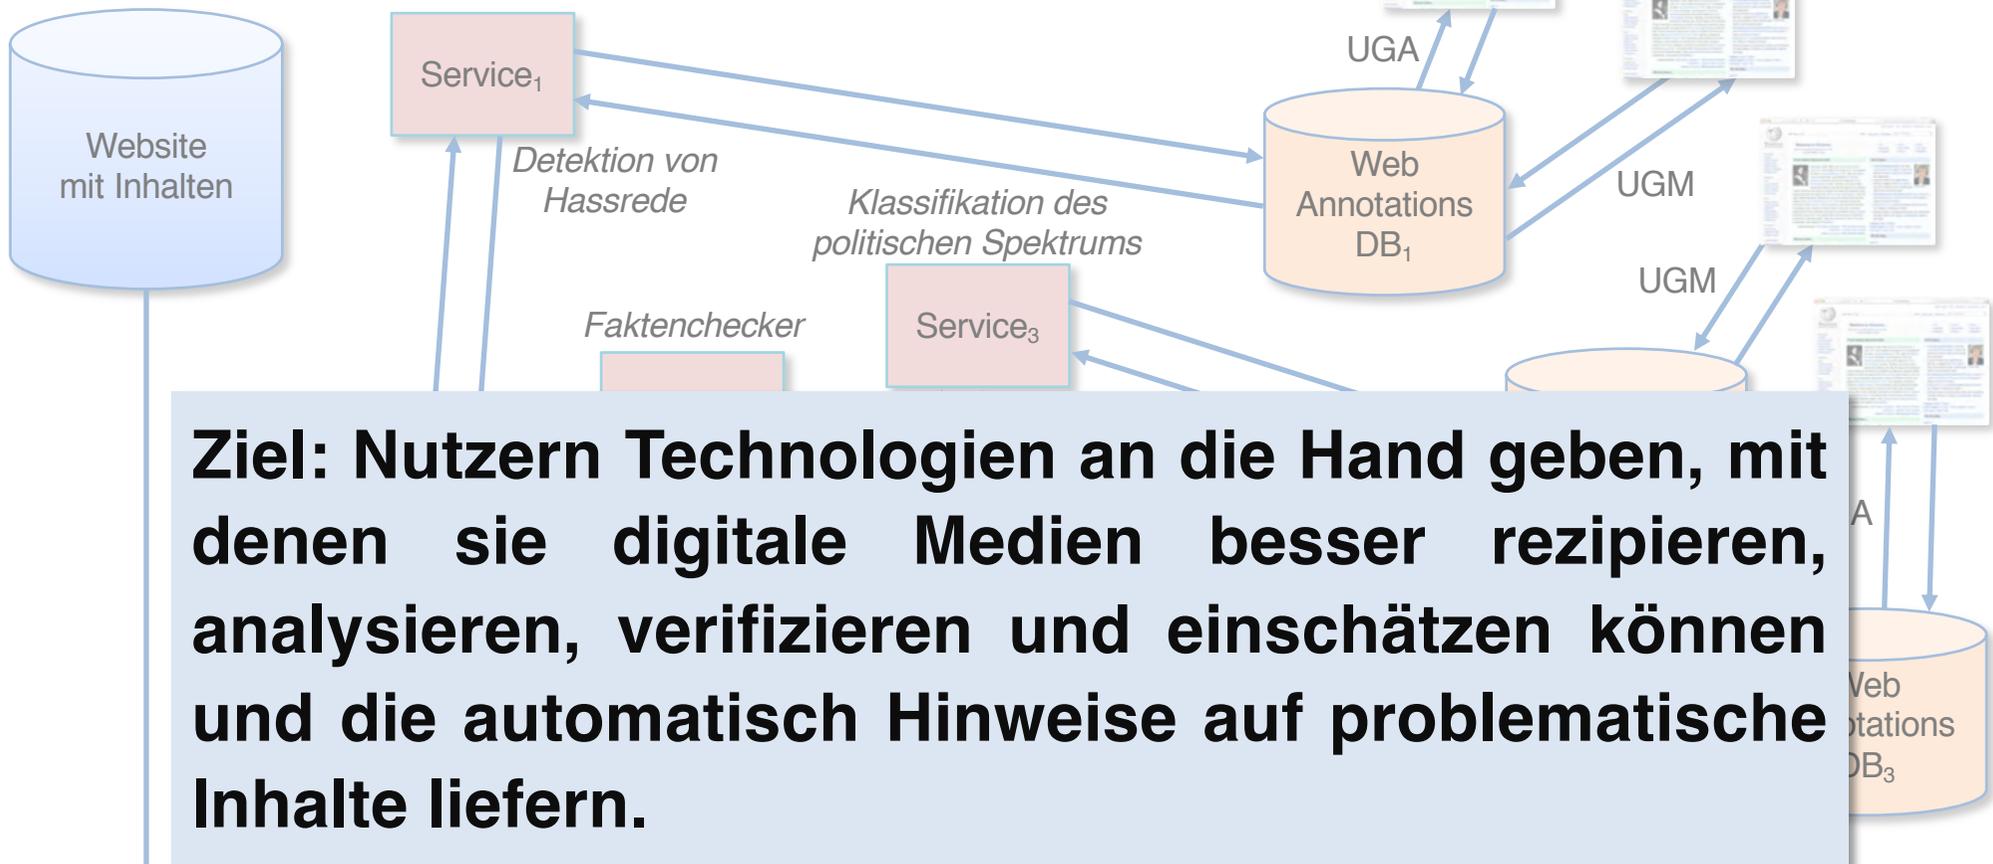


- Standardisierte Metadaten-Schemata für effiziente RDF-Annotationen, z.B. „Inhalt ist bewusste Täuschung.“
- W3C Provenance Ontology, Schema.org (ClaimReview).
- W3C Credible Web Community Group arbeitet seit Kurzem an den notwendigen Konzepten.

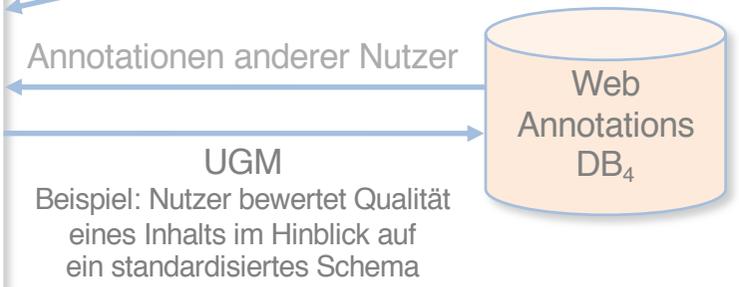
Browser unterstützt Infrastruktur nativ und aggregiert unterschiedlichen Bewertungen, Kommentare und Meinungen über einen Inhalt in klare Botschaften oder Warnungen

UGA: User-generierte Annotationen (Freitext)
 UGM: User-generierte Metadaten (standardisiert)
 MGM: Maschinen-generierte Metadaten (standardisiert)

Dezentrale Filter verarbeiten Inhalte automatisch und schicken Ergebnisse zum Browser (wichtig: Mehrsprachigkeit)



Ziel: Nutzern Technologien an die Hand geben, mit denen sie digitale Medien besser rezipieren, analysieren, verifizieren und einschätzen können und die automatisch Hinweise auf problematische Inhalte liefern.



Browser unterstützt Infrastruktur nativ und aggregiert unterschiedlichen Bewertungen, Kommentare und Meinungen über einen Inhalt in klare Botschaften oder Warnungen

- UGA: User-generierte Annotationen (Freitext)
- UGM: User-generierte Metadaten (standardisiert)
- MGM: Maschinen-generierte Metadaten (standardisiert)

1. Herausforderung

**Das mehrsprachige Europa:
Sprachtechnologien für alle europäischen Sprachen?**

2. Herausforderung

**Online-Desinformationskampagnen:
Technische Lösungsansätze gegen „Fake News“?**

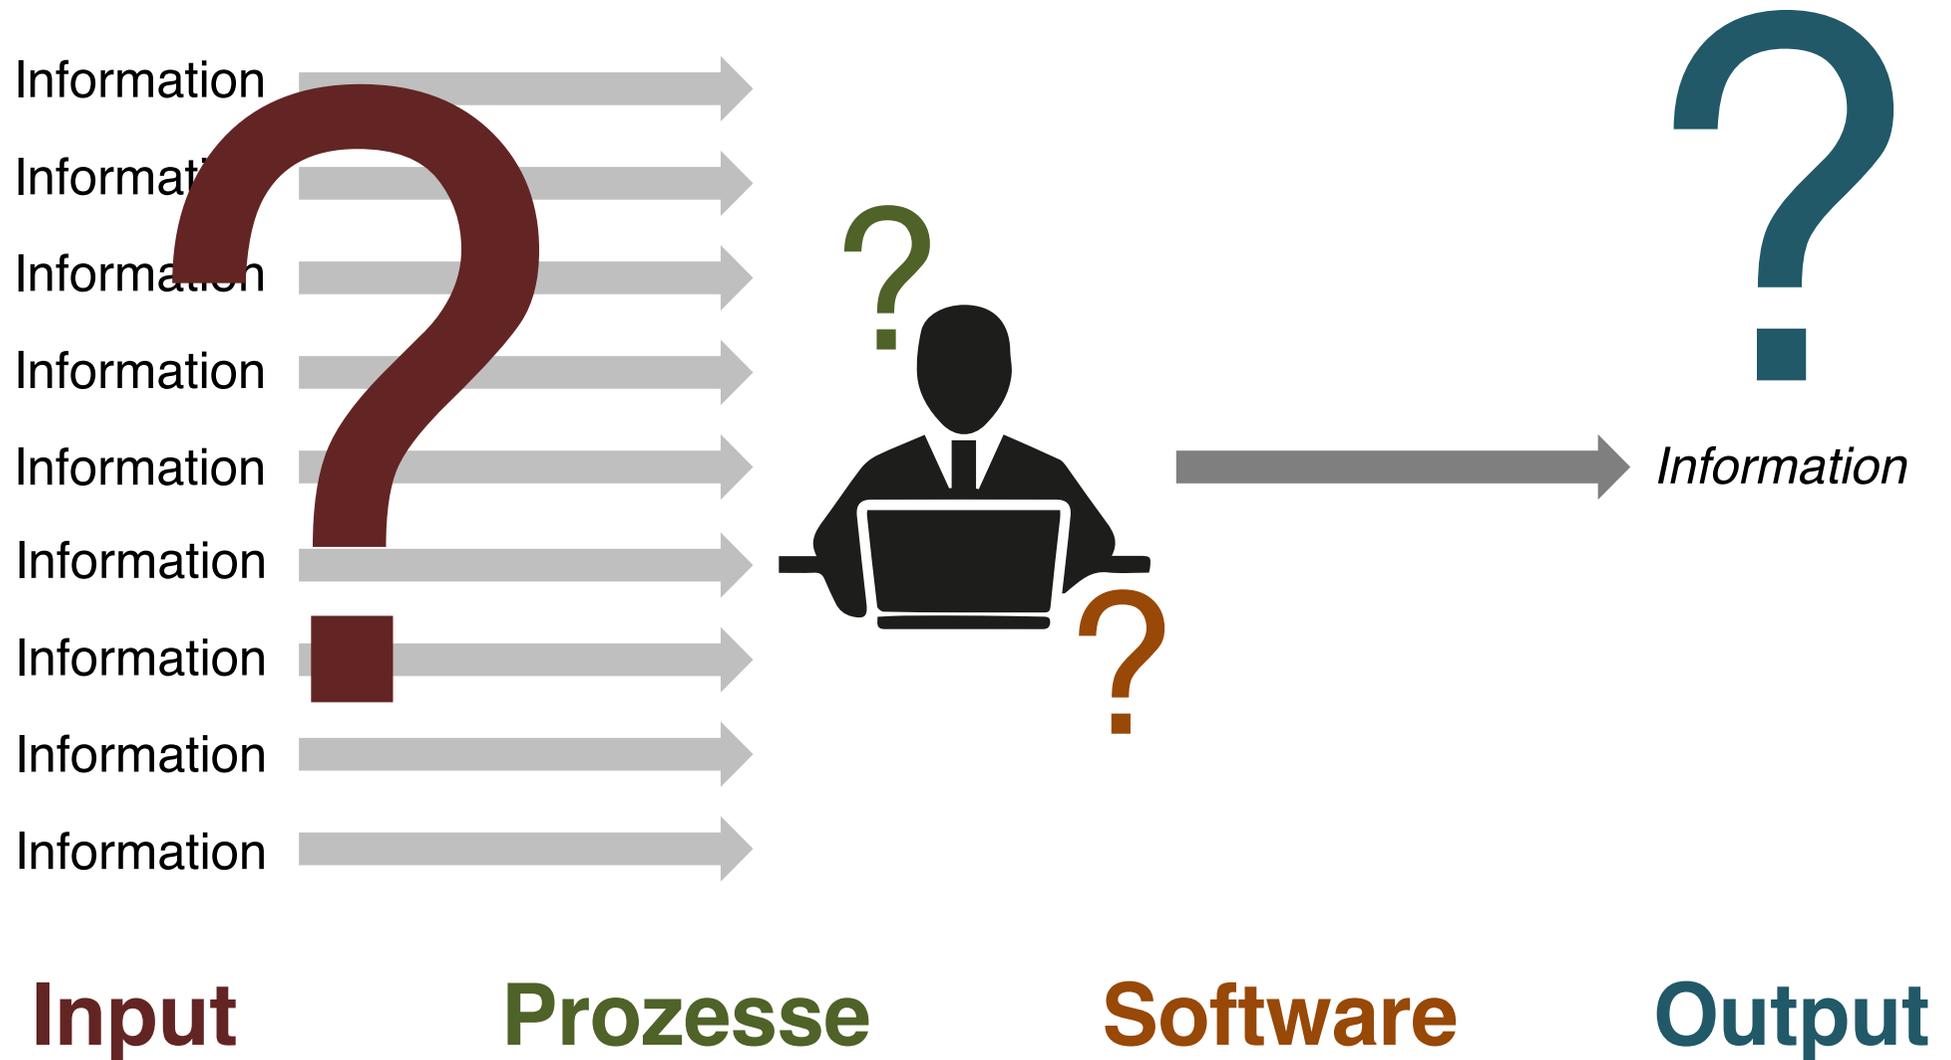
3. Herausforderung

**Digitaler Content:
Technologien für die effiziente Content-Kuratierung?**

Relevanz von Content

- Content spielt wichtige Rolle in Gesellschaft und Industrie
- In vielen Branchen herrscht Druck, regelmäßig Content zu publizieren; man spricht auch von der Content-Industrie.
- Ziel: **Smarter, effizienter Umgang mit Content**
 - Beschaffung, Konvertierung, Anreicherung, Analyse, Zusammenfassung, Übersetzung, Verknüpfung, Zusammenstellung und Publikation von Content.
 - Ausspielen von Content auf div. Kanälen inkl. Social Media.
- Riesiges Potenzial für Disruptionen in allen Branchen durch **Technologien für die Kuratierung von Content.**

Was ist digitale Kuratierung?



Branchen

Input

Tweet
Zeitungsartikel
Agenturmeldung
Facebook-Meldung
Suchergebnis
Email
SMS
Konzept
Textdateien
Video
Karte
Stockfotos
In-house Datenbank
Kalendereintrag
Spreadsheets
Archiv
etc.

Prozesse

Analysieren
Auswählen
Fokussieren
Überarbeiten
Einlesen
Schreiben
Gestalten
Recherchieren
Bewerten
Evaluieren
Ordnen
Sortieren
Strukturieren
Zusammenfassen
Kürzen
Übersetzen
Informieren
Kombinieren
Abstrahieren
Einordnen
Visualisieren
Generieren
Annotieren
Referenzieren
etc.

Software

Textverarbeitung
Präsentationen
Tabellenkalkulation
Email
Browser
Groupware
Branchenapplikationen
CMS
ECMS
CRM
Unternehmens-Software
Grafik-/Layout-Software
Telefonie
etc.

Output

Zeitungsartikel
Multimedia-Website
TV-Beitrag
Ausstellungskatalog
Mobile Applikation
Mashup (z.B. Karte)
Textbeitrag
Konzept
Zeitstrahl
Fachartikel
Studie
Präsentation
Faktensammlung
Exponatsartikel
Analysen
etc.

Merkmale und Dimensionen

- **Content:** Text, Ton, Bild, Video, Multimedia, AR/VR
- **Mehrsprachigkeit:** Text, Ton, ggf. mehrere Sprachen
- **Diverse Content-Typen:** U.a. Hunderte von Textsorten
- **Beteiligte:** Content wird oft in verteilten Teams kuratiert
- **Branchen:** Branchenspezifische Anforderungen
- **Workflows:** Flexible Komponierung und Konfigurierung
- **Services:** Spektrum – generisch bis branchenspezifisch
- **Geschwindigkeit und Effizienz:** Einsatz im Arbeitsalltag



Digitale
Kuratierungs-
technologien

Digitale Kuratierungstechnologien

- Digitaler Kuratierung mit Sprach- und Wissenstechnologien
- Entwicklung innovativer Prototypen mit den KMU-Partnern
- Unterstützung der Experten – „human in the loop“!
- Weiterentwicklung der DFKI-Technologien und Transfer mittels **Plattform für digitale Kuratierungstechnologien**

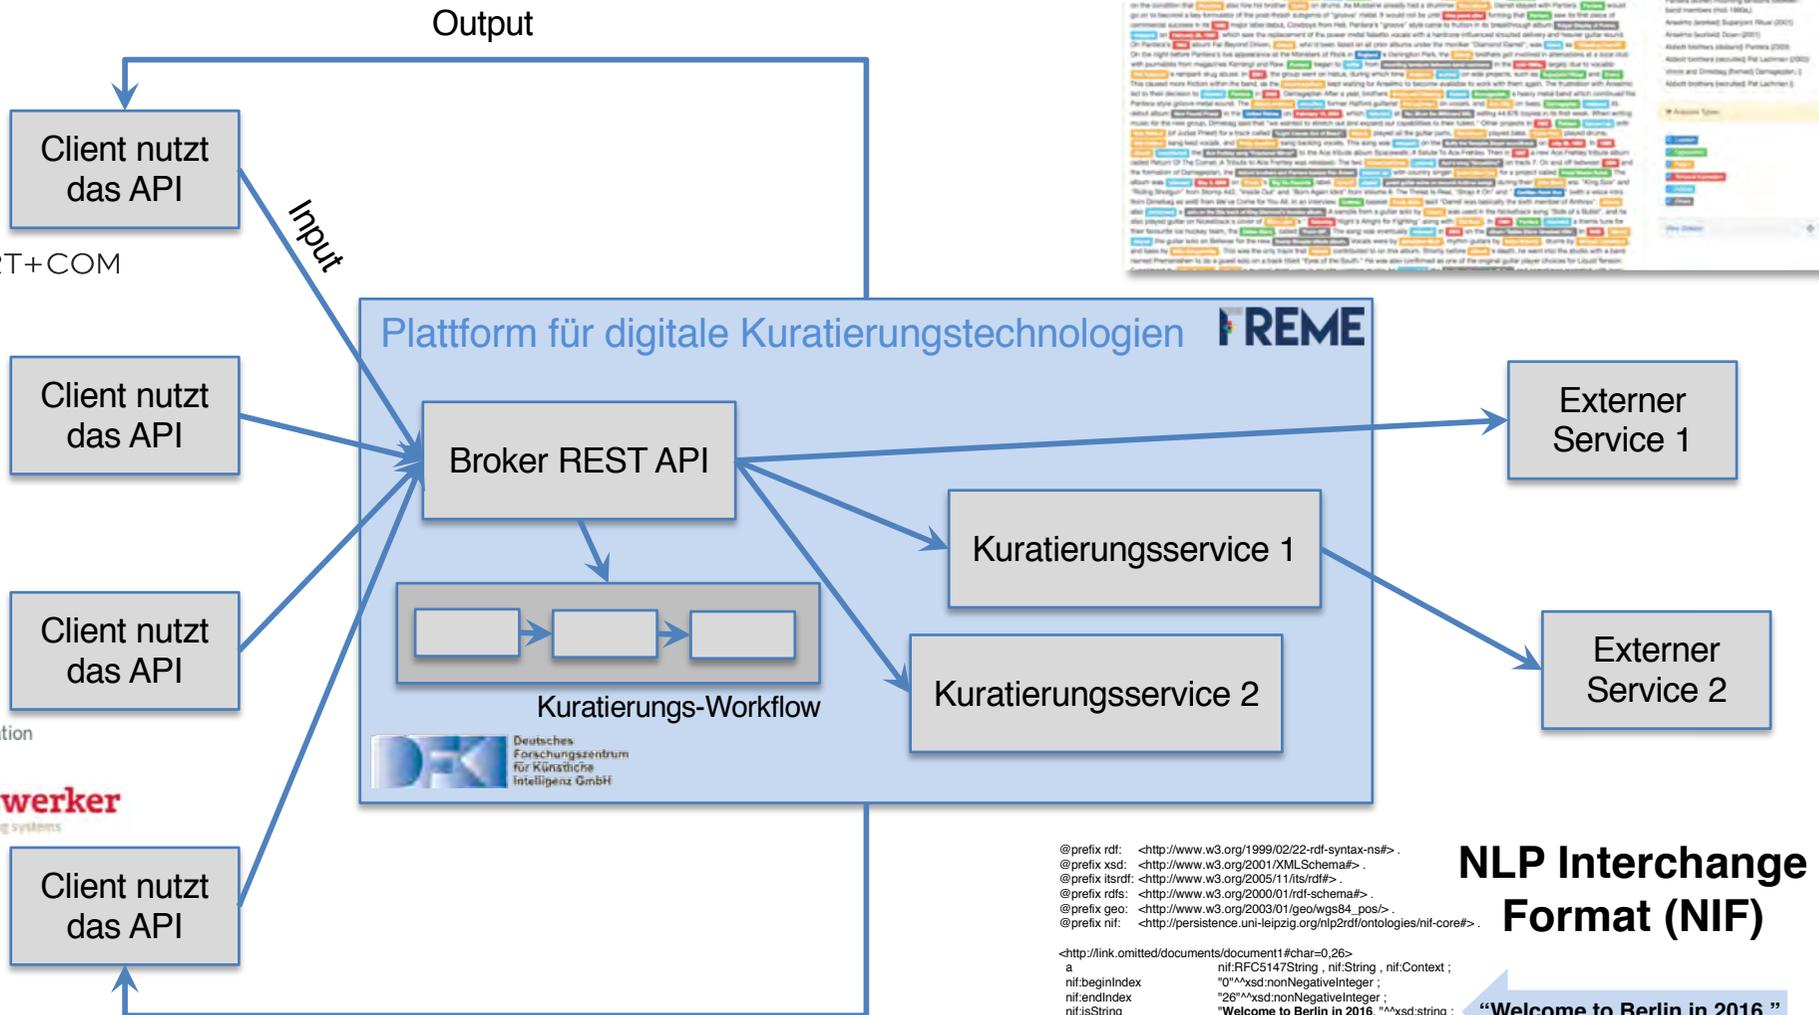


DKT Auftaktveranstaltung – 25. September 2015

Georg Rehm und Felix Sasaki. "Digital Curation Technologies." In *Proceedings of the 19th Annual Conference of the European Association for Machine Translation (EAMT 2016)*, Riga, Lettland, Mai 2016

Georg Rehm und Felix Sasaki. "Digitale Kuratierungstechnologien – Verfahren für die effiziente Verarbeitung, Erstellung und Verteilung qualitativ hochwertiger Medieninhalte." In *Proceedings der Frühjahrstagung der Gesellschaft für Sprachtechnologie und Computerlinguistik (GSCL 2015)*, S. 138-139, Duisburg, 2015

Prototypisch implementierte Plattform und Services



- Durch (Semi-)Automatisierung der Kuratierungsprozesse Reduktion zeitlicher und finanzieller Aufwände
- Flexible, robuste, skalierbare Services
- Interoperabilität durch generische APIs

Peter Bourgonje, Julian Moreno-Schneider, Jan Nehring, Georg Rehm, Felix Sasaki, and Ankit Srivastava. "Towards a Platform for Curation Technologies: Enriching Text Collections with a Semantic-Web Layer." In Harald Sack, Giuseppe Rizzo, Nadine Steinmetz, Dunja Mladenić, Sören Auer, and Christoph Lange, editors, The Semantic Web, number 9989 in LNCS, pages 65-68. Springer, June 2016. ESWC 2016 Satellite Events. Heraklion, Crete, Greece, May 29 - June 2, 2016 Revised Selected Papers.

NLP Interchange Format (NIF)

```
@prefix rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>.
@prefix xsd: <http://www.w3.org/2001/XMLSchema#>.
@prefix itsrdf: <http://www.w3.org/2005/11/its/rdf/>.
@prefix rdfs: <http://www.w3.org/2000/01/rdf-schema#>.
@prefix geo: <http://www.w3.org/2003/01/geo/wgs84_pos/>.
@prefix nif: <http://persistence.uni-leipzig.org/nlp2rdf/ontologies/nif-core#>.

<http://link.omitted/documents/document1#char=0,26>
  a nif:RFC5147String, nif:String, nif:Context ;
  nif:beginIndex "0"^^xsd:nonNegativeInteger ;
  nif:endIndex "26"^^xsd:nonNegativeInteger ;
  nif:isString "Welcome to Berlin in 2016."^^xsd:string ;
  dfinif:averageLatitude "52.516666666666666"^^xsd:double ;
  dfinif:averageLongitude "13.383333333333333"^^xsd:double ;
  dfinif:stdDevLatitude "0.0"^^xsd:double ;
  dfinif:stdDevLongitude "0.0"^^xsd:double ;
  nif:meanDateRange "201601010000_20170101010000"^^xsd:string .

<http://link.omitted/documents/document1#char=21,25>
  a itsrdf:taldentRef nif:RFC5147String, nif:String ;
  itsrdf:taldentRef <http://link.omitted/ontologies/nif#date=20160101000000_20170101000000>;
  nif:anchorOf "2016"^^xsd:string ;
  nif:beginIndex "21"^^xsd:nonNegativeInteger ;
  nif:endIndex "25"^^xsd:nonNegativeInteger ;
  nif:entity <http://link.omitted/ontologies/nif#date>.

<http://link.omitted/documents/#char=11,17>
  a nif:RFC5147String, nif:String ;
  nif:anchorOf "Berlin"^^xsd:string ;
  nif:beginIndex "11"^^xsd:nonNegativeInteger ;
  nif:endIndex "17"^^xsd:nonNegativeInteger ;
  itsrdf:taClassRef <http://dbpedia.org/ontology/Location>;
  nif:referenceContext <http://link.omitted/documents/#char=0,26>;
  geo:lat "52.516666666666666"^^xsd:double ;
  geo:long "13.383333333333333"^^xsd:double ;
  itsrdf:taldentRef <http://dbpedia.org/resource/Berlin> .
```

← "Welcome to Berlin in 2016."

- RDF/OWL-basiertes Format für NLP-Anwendungen
- Ermöglicht Interoperabilität
- Durch pures RDF „natürliche“ Integration von Linked-Data-Daten
- Entwickelt von der Universität Leipzig
- Plattform unterstützt neben NIF auch Web Annotations

Exemplarische Basisdienste

NER, Linking, Geolokalisierung

- Modus 1:** Modell-basiert (für Domänen, für die annotierte Trainingsdaten verfügbar sind)
- Modus 2:** Wörterbuch-basiert (für Domänen, für die lediglich Namenslisten verfügbar sind)
- Basiert auf OpenNLP (mit NIF-Integration)

- Entity-Linking durch SPARQL-Queries auf DBpedia.
- Für Lokationen werden GPS-Koordinaten bezogen.
- Es werden Durchschnittswerte berechnet auf Dokumentebene (über alle Lokationen), um sie auf einer Karte visualisieren zu können.

...
In the Viking colony of Iceland, an extraordinary vernacular literature blossomed in the 12th through 14th centuries
 ...
The ships were scuttled there in the 11th century, to block a navigation channel and thus protect Froskilde, then Copenhagen from seaborne assault
 ...
Viking Age inscriptions have also been discovered on the Manx runestones on the Isle of Man.
 ...

Geolokalisierung als visuelles Zusammenfassen!

Plain Text NIF-Anreicherung Visualisierung

<http://api.digitale-kuration.de/api/nlp/nameEntityRecognition?analysis=ner> <http://api.digitale-kuration.de/admin/pages/geolocalization.php>

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Technologien für Digitale Medien – Georg Rehm 53

NER und Linking

A <http://api.digitale-kuration.de/api/nlp/trainModel?analysis=dict> B <http://api.digitale-kuration.de/api/nlp/trainModel?analysis=ner>

- Falls lediglich Listen von Namen oder Termen und deren URIs in einer Chronologie zur Verfügung stehen
- Falls annotierte Trainingsdaten zur Verfügung stehen

Datenbank-Dump der Mendelssohn-Briefe

- Linking per Extraktion der DBpedia-URI
- NE-Typenspezifische SPARQL-Queries für Personen (Geburtsdatum), Lokationen (Koordinaten), Organisationen (Typ)
- Wörterbuch kann URIs enthalten

statistisches NER-Modell

Mittlere Qualität Hohe Qualität

Benötigt weniger annotierte Daten Benötigt annotierte Daten

auf neuem Input nutzbar (auch gemeinsam)

C Falls – z.B. bei Spezialdomänen – weder das eine (A) noch das andere (B) vorliegt, können potenzielle Entitäten in Kollektionen berechnet werden.

- Diese Liste kann vom Wissenschaftler überprüft und anschließend als Wörterbuch (A) eingesetzt werden.

Mittlere Qualität Menschliche Intervention notwendig

Benötigt keine annotierten Daten

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Technologien für Digitale Medien – Georg Rehm 54

Zeitausdrücke

...
The ships were scuttled there in the 11th century, to block a navigation channel and thus protect Froskilde, then Copenhagen from seaborne assault
 ...
Viking Age inscriptions have also been discovered on the Manx runestones on the Isle of Man.
 ...
In the Viking colony of Iceland, an extraordinary vernacular literature blossomed in the 12th through 14th centuries
 ...

Plain-Text NIF-Anreicherung Visualisierung

<http://api.digitale-kuration.de/api/nlp/namesEntityRecognition?analysis=nerp> <http://dev.digitale-kuration.de/admin/pages/timeline.php>

- Sortiert Dokumente auf einer chronologischen Skala.
- Regelbasiertes System, um unsere Zielsprachen bestmöglich bedienen zu können (EN, DE).
- Analyse von Zeitausdrücken in einem Dokument.
- Berechnet Durchschnittswerte und Intervalle.
- Plan: Mechanismus für nutzerbasierte Regeln.
- Verwandte Arbeiten: SUTime, HeideTime, Tango, Tarsgl.

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Technologien für Digitale Medien – Georg Rehm 55

Maschinelle Übersetzung

- Robuste, adaptierbare MT-Modelle (nutzen Moses, Cdec, Giza++, SRILM etc.)
- Parallele und monolinguale Korpora: Europarl, DGT-TM, TED, UN, Newscrawl u.a.
- Kombination mit anderen DKT-Services (Summariser, NER, Temporal Analyser); ITS 2.0, NIF
- Diverse Linked-Data-Datenquellen unterstützen MT (z.B. Dbpedia, BabelNet, WordNet)

Beispiel:

Herr Modi befindet sich auf einer fünf-tägigen Reise nach Japan, um die wirtschaftlichen Beziehungen mit der drittgrößten Wirtschaftsnation der Welt zu festigen.

Mr Modi is located on a five-day trip to Japan to strengthen the economic ties with the third largest economy in the world.

Named Entity Recognition Entity Linking Temporal Expressions Metadata Processing Post-Edit Retraining

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Technologien für Digitale Medien – Georg Rehm 56

Textzusammenfassen

- Kurierungsservice rankt Sätze – basierend auf div. Features – hinsichtlich ihrer Wichtigkeit.
- Modul ist in der Entwicklung.
- Beispiel: Artikel über den fallenden Aktienkurs von RWE (Daten stammen von Condat).
- Ausblick: Integration der Analyseergebnisse anderer DKT-Services in den Algorithmus.

Im letzten Monat und den letzten 3 Monaten verlor die RWE-Aktie 3,79% bzw. 18,95% und in den letzten 3 Tagen 3,55%.

Die Aktie der RWE AG fiel am Donnerstag um 0,21% auf 19,16 EUR und schwankte am Handelstag zwischen 19,08 und 19,32 EUR. Das Handelsvolumen der Aktie lag bei 1,79 Millionen Aktien und so unter dem 52-Wochen- und 150-Tagesvolumen von 3,40 Millionen bzw. 3,96 Millionen Aktien. Im letzten Monat und den letzten 3 Monaten verlor die RWE-Aktie 3,79% bzw. 18,95% und in den letzten 3 Tagen 3,55%. Das PE und PB-Verhältnis der Unternehmensaktie liegt aktuell bei 11,44 bzw. 1,29, während die historischen PE und PB-Werte jeweils bei 11,77 bzw. 2,13 liegen.

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Technologien für Digitale Medien – Georg Rehm 57

Semantic Storytelling

- Eingabe:** Kohärente, in sich geschlossene Textkollektion
- Ausgabe:** Semantisch angereicherte Kollektion
- Idee:** Aufgabenspezifisch multiple Rezeptionspfade generieren, vorschlagen, präsentieren
- Lösung:** Identifizierung, Ranking und Empfehlung sinnvoller, überraschender Hypertextpfade
- Es gibt noch zahlreiche Herausforderungen.

Peter Bourgeois, Julian Moreno Schneider, Georg Rehm und Felix Sasaki: Processing Document Collections by Automatically Extract Linked Data. Semantic Storytelling Technologies for Smart Curator Workflows. In Aldo Gangemi and Claire Gardent, Hrsg., Proceedings of the 2nd International Workshop on Natural Language Generation and the Semantic Web (IWNLG 2016), S. 13-16, Edinburgh, UK, Sept. 2016. Association for Comp Linguistics.

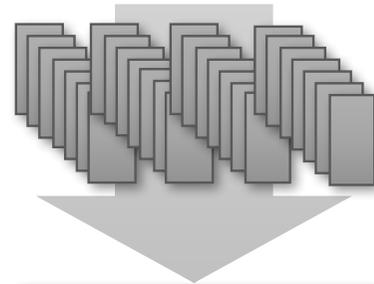
Julian Moreno Schneider, Peter Bourgeois, Jan Nehring, Georg Rehm, Felix Sasaki, and Ankit Srivastava: Towards Semantic Story Telling with Digital Curation Technologies. In Larry Birbaum, Olovano Figueira and Carlo Strapparola, Hrsg., Proceedings of Natural Language Processing meets Journalism - LCAJ16 Workshop (NLPUJ 2016), New York, Juli 2016.

Peter Bourgeois, Julian Moreno-Schneider, Jan Nehring, Georg Rehm, Felix Sasaki and Ankit Srivastava: Towards a Platform for Curation Technologies: Enriching Text Collections with a Semantic Web Layer. In Marika Sak, Giuseppe Riolo, Nadine Stammetz, Durja Mladenc, Sören Auer and Christoph Lange, Hrsg., The Semantic Web: ESWC 2016 Satellite Events, Juni 2016.

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH Technologien für Digitale Medien – Georg Rehm 58

Beispiel: Die Mendelsohn-Briefe

Experiment:
Überführung einer
Sammlung von Briefen
in einen Reisebericht



- Input: Self-contained document collection
- Example: Mendelsohn letters, 2796 documents, written in German, English, French



Semantic Storytelling Backend

Semantic Storytelling: Analysis and Annotation Steps

- Language identification (for cross-lingual processing)
- Temporal expression analysis (TimeX)
- Geographic location analysis (GeoX)
- Participants and actors analysis (Person X)
- Coreference analysis
- Event detection (cross-lingual, including German and French, through machine translation)
- Mode of transportation analysis
- Identification of Movement Action Events out of the set of identified events (filtering)

RDF DB

Authoring Environment



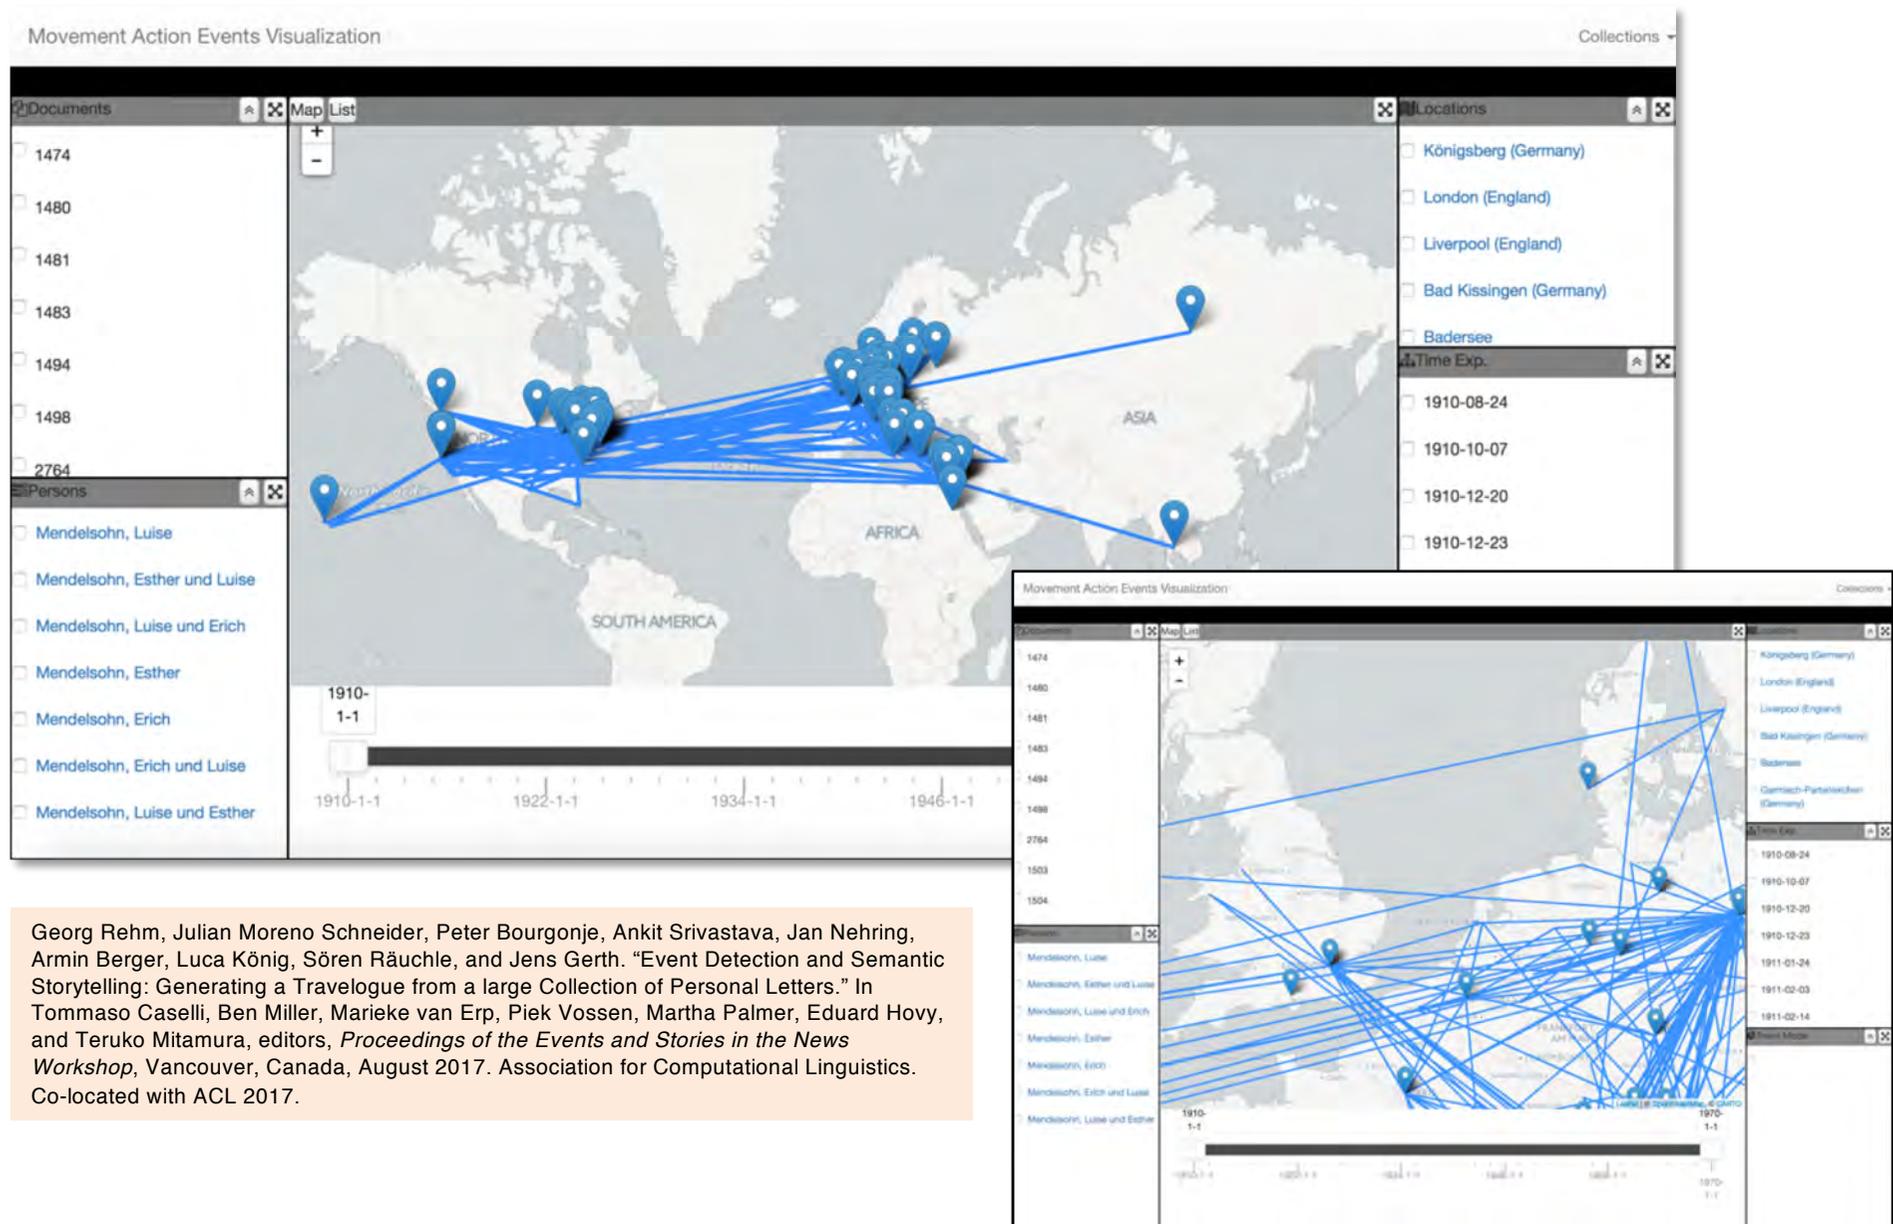
- Assists the editor in putting together stories based on the semantic analyses
- Enables the construction of new stories, for example, by (1) focussing on the specific requirements of different text types such as *biography* or *travelogue* or (2) through highlighting and recommending to the human expert specific relationships between entities
- Automatic transformation of RDF database contents into play-out formats for different channels and media

RDF DB

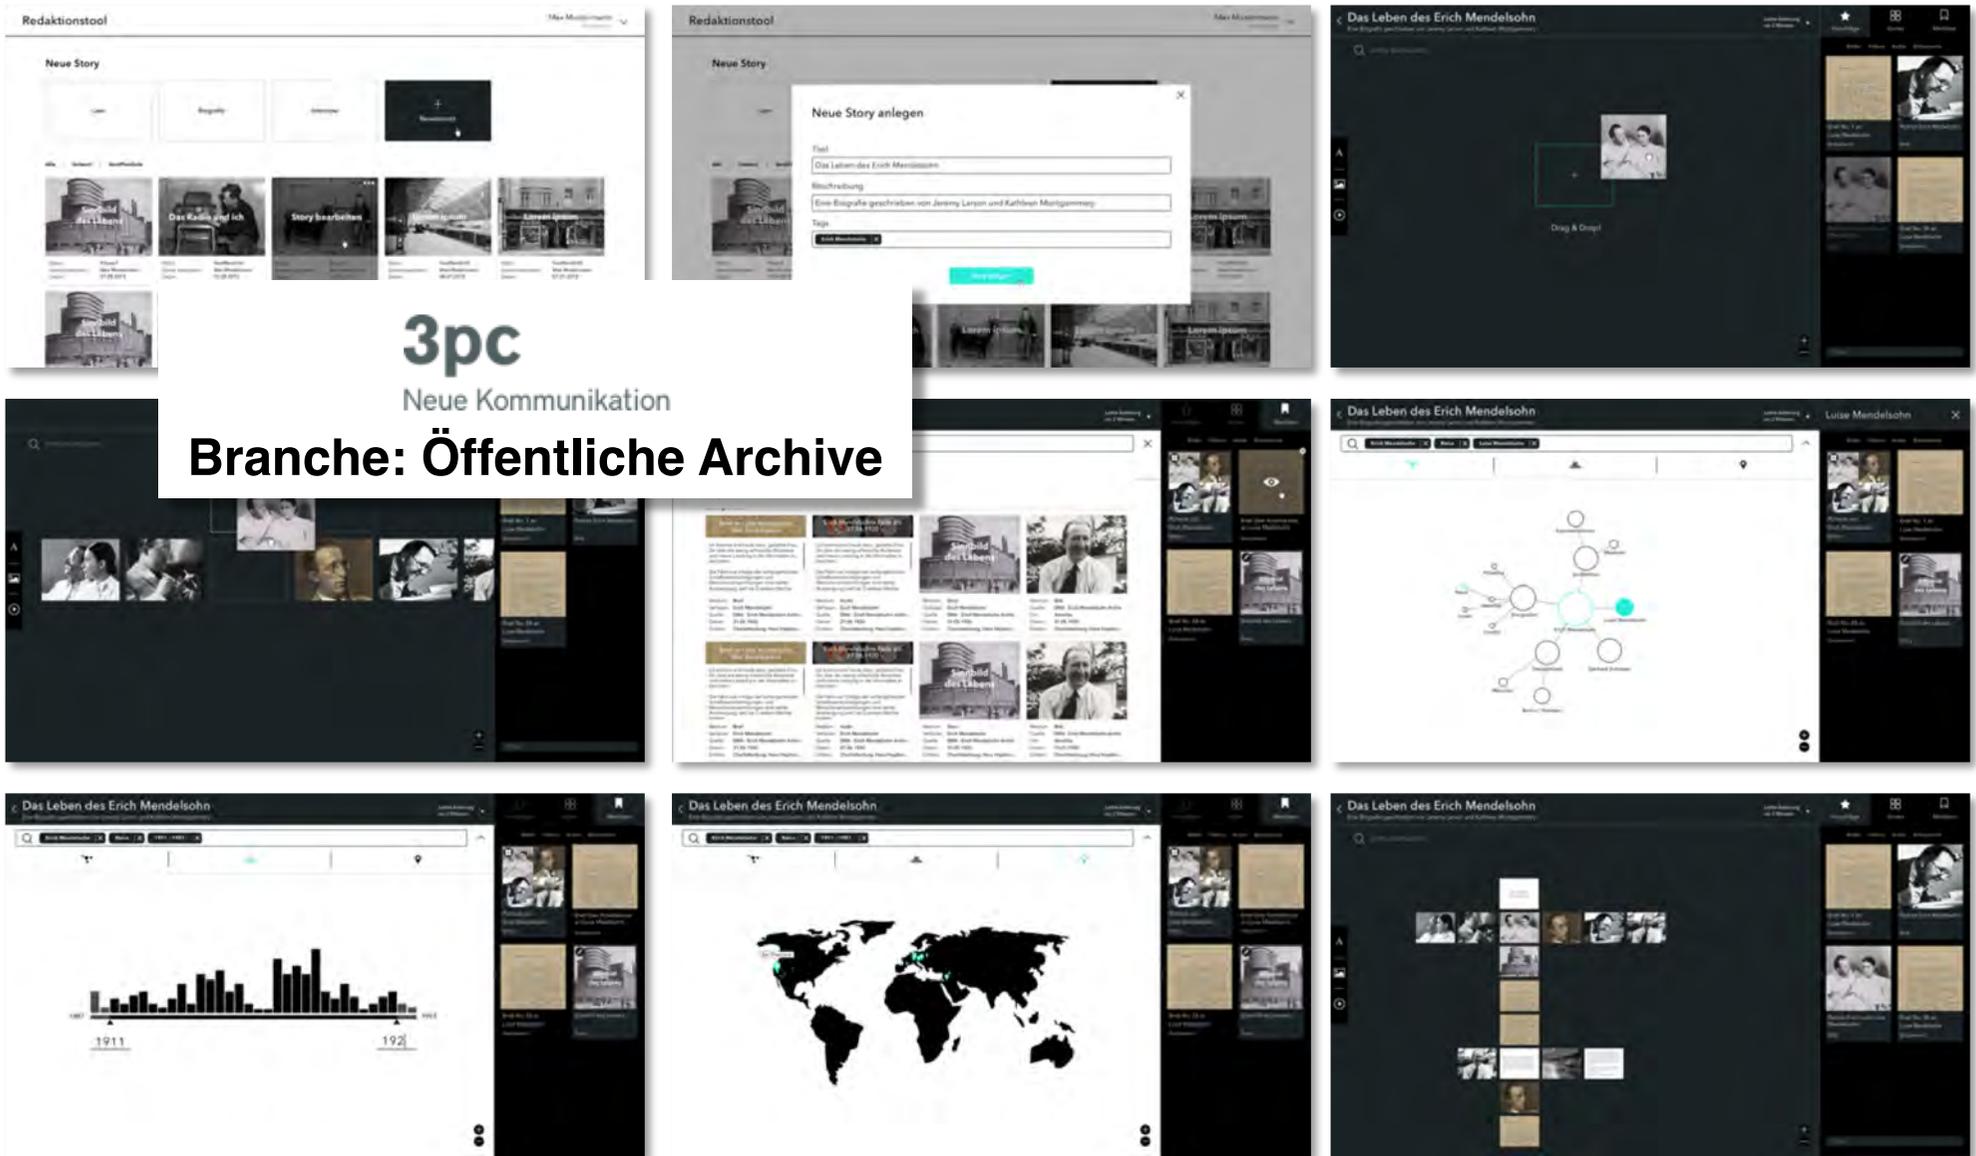
iOS App ePub HTML5 Android App ...

Georg Rehm, Julian Moreno Schneider, Peter Bourgonje, Ankit Srivastava, Jan Nehring, Armin Berger, Luca König, Sören Räuchle, and Jens Gerth. "Event Detection and Semantic Storytelling: Generating a Travelogue from a large Collection of Personal Letters." In Tommaso Caselli, Ben Miller, Marieke van Erp, Piek Vossen, Martha Palmer, Eduard Hovy, and Teruko Mitamura, editors, *Proceedings of the Events and Stories in the News Workshop*, Vancouver, Canada, August 2017. Association for Computational Linguistics. Co-located with ACL 2017.

Beispiel: Die Mendelsohn-Briefe



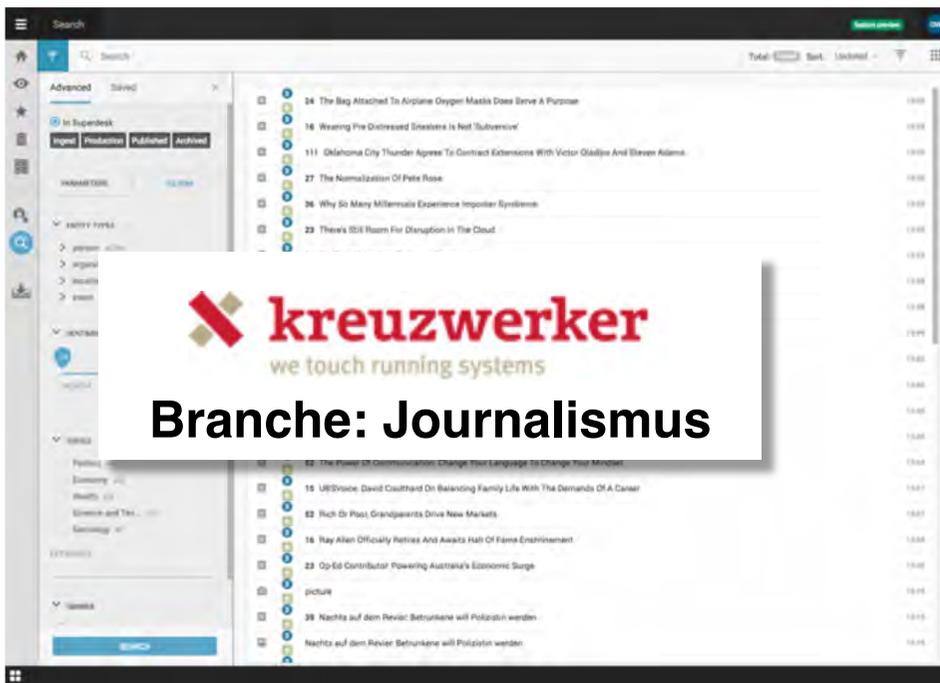
Georg Rehm, Julian Moreno Schneider, Peter Bourgonje, Ankit Srivastava, Jan Nehring, Armin Berger, Luca König, Sören Rächle, and Jens Gerth. "Event Detection and Semantic Storytelling: Generating a Travelogue from a large Collection of Personal Letters." In Tommaso Caselli, Ben Miller, Marieke van Erp, Piek Vossen, Martha Palmer, Eduard Hovy, and Teruko Mitamura, editors, *Proceedings of the Events and Stories in the News Workshop*, Vancouver, Canada, August 2017. Association for Computational Linguistics. Co-located with ACL 2017.



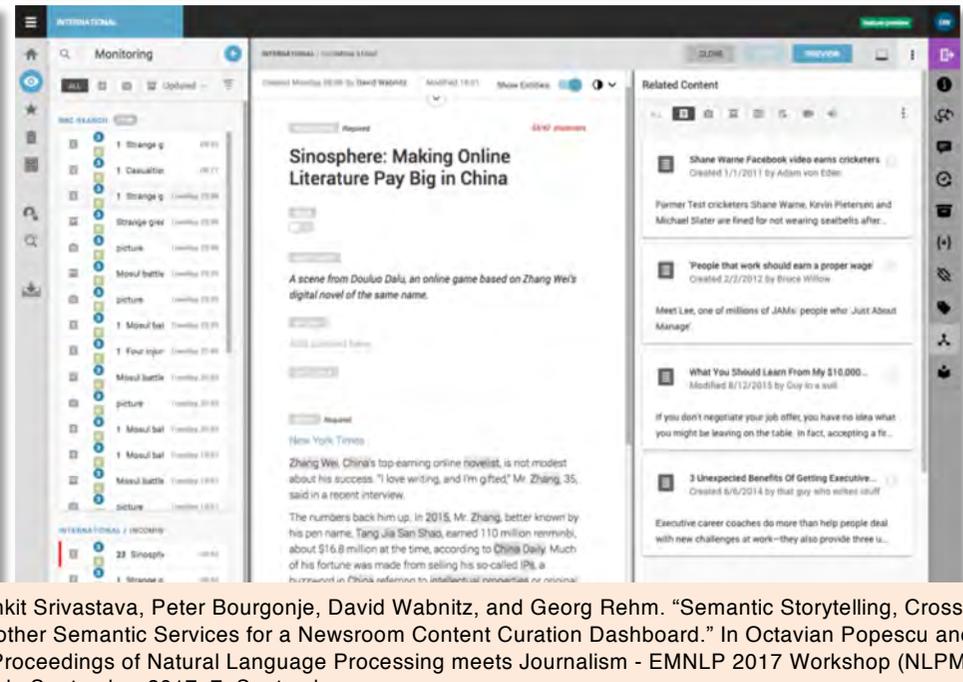
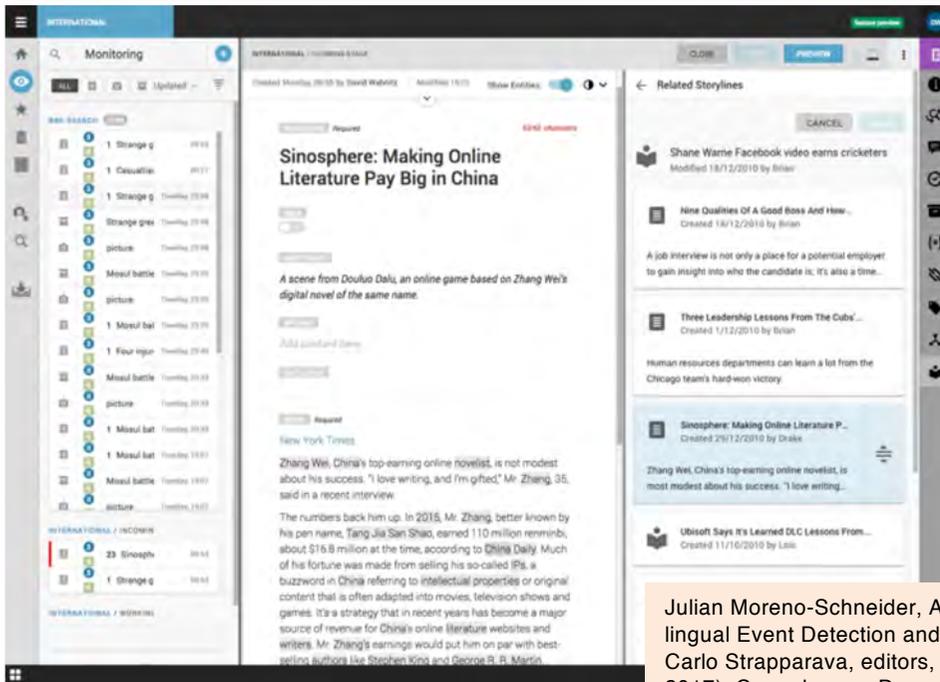
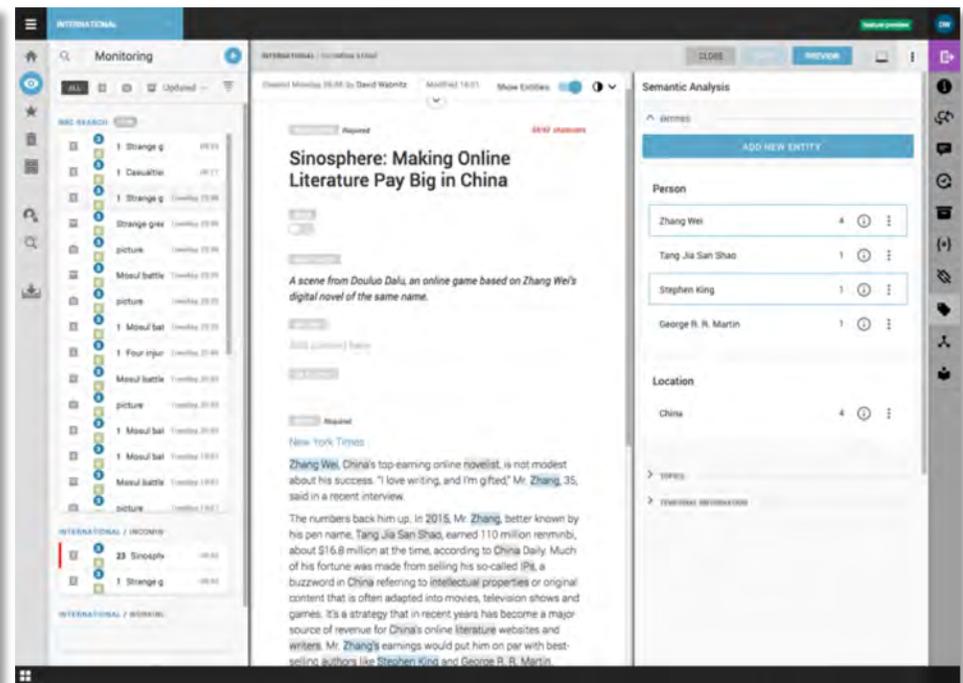
3pc
 Neue Kommunikation
 Branche: Öffentliche Archive

Georg Rehm, Julian Moreno Schneider, Peter Bourgonje, Ankit Srivastava, Jan Nehring, Armin Berger, Luca König, Sören Räuchle, and Jens Gerth. "Event Detection and Semantic Storytelling: Generating a Travelogue from a large Collection of Personal Letters". In Tommaso Caselli, Ben Miller, Marieke van Erp, Piek Vossen, Martha Palmer, Eduard Hovy, and Teruko Mitamura, editors, *Proceedings of the Events and Stories in the News Workshop*, Vancouver, Canada, August 2017. Association for Computational Linguistics. Co-located with ACL 2017.

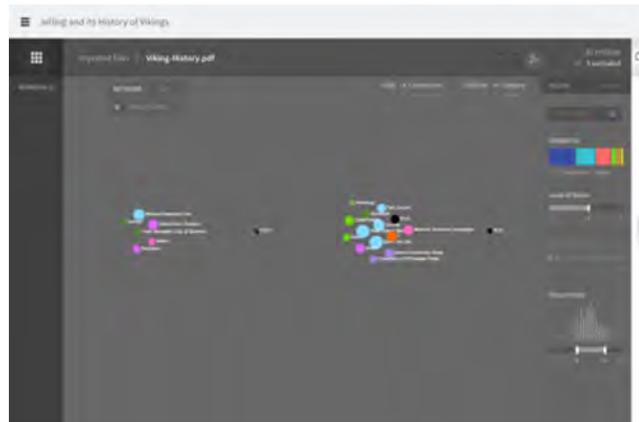
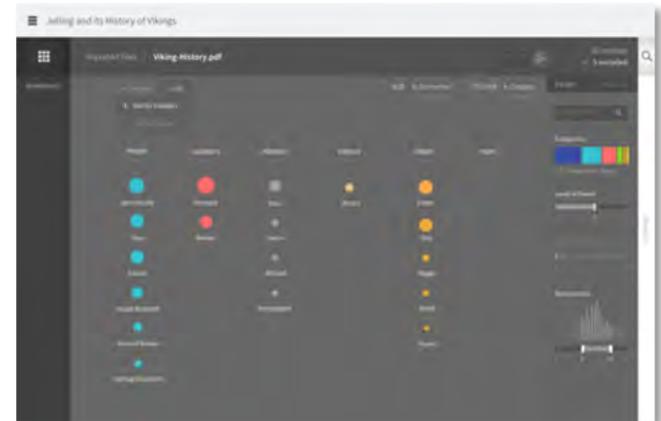
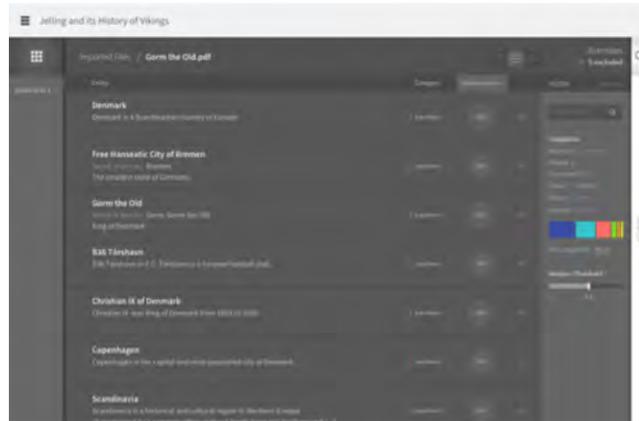
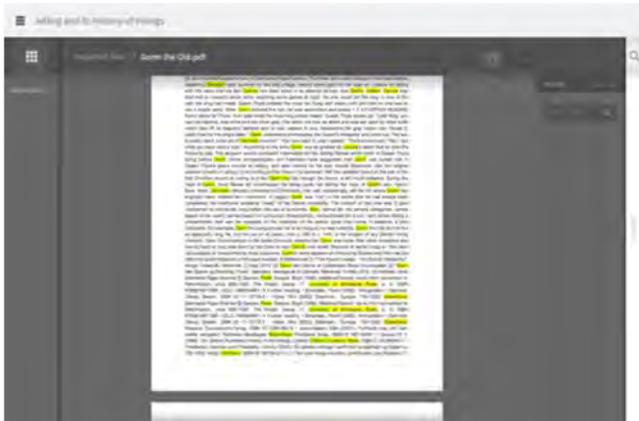
Georg Rehm, Julián Moreno Schneider, Peter Bourgonje, Ankit Srivastava, Rolf Fricke, Jan Thomsen, Jing He, Joachim Quantz, Armin Berger, Luca König, Sören Räuchle, Jens Gerth, and David Wabnitz. "Different Types of Automated and Semi-Automated Semantic Storytelling: Curation Technologies for Different Sectors". In Georg Rehm and Thierry Declerck, editors, *Language Technologies for the Challenges of the Digital Age: 27th International Conference, GSCL 2017, Berlin, Germany, September 13-14, 2017, Proceedings*, number 10713 in *Lecture Notes in Artificial Intelligence (LNAI)*, pages 232-247, Cham, Switzerland, January 2018. Gesellschaft für Sprachtechnologie und Computerlinguistik e.V., Springer. 13/14 September 2017.



kreuzwerker
we touch running systems
Branche: Journalismus



Julian Moreno-Schneider, Ankit Srivastava, Peter Bourgonje, David Wabnitz, and Georg Rehm. "Semantic Storytelling, Cross-lingual Event Detection and other Semantic Services for a Newsroom Content Curation Dashboard." In Octavian Popescu and Carlo Strapparava, editors, Proceedings of Natural Language Processing meets Journalism - EMNLP 2017 Workshop (NLPJM 2017), Copenhagen, Denmark, September 2017. 7. September.



**Branche: Museen,
Showrooms, Ausstellungen**

Georg Rehm, Jing He, Julian Moreno Schneider, Jan Nehring, and Joachim Quantz. *Designing User Interfaces for Curation Technologies*. In Sakae Yamamoto, editor, *Human Interface and the Management of Information: Information, Knowledge and Interaction Design, 19th International Conference, HCI International 2017*, number 10273 in Lecture Notes in Computer Science (LNCS), pages 388-406, Vancouver, Canada, July 2017. Springer.

Georg Rehm, Julián Moreno Schneider, Peter Bourgonje, Ankit Srivastava, Rolf Fricke, Jan Thomsen, Jing He, Joachim Quantz, Armin Berger, Luca König, Sören Rächle, Jens Gerth, and David Wabnitz. "Different Types of Automated and Semi-Automated Semantic Storytelling: Curation Technologies for Different Sectors". In Georg Rehm and Thierry Declerck, editors, Language Technologies for the Challenges of the Digital Age: 27th International Conference, GSCL 2017, Berlin, Germany, September 13-14, 2017, Proceedings, number 10713 in Lecture Notes in Artificial Intelligence (LNAI), pages 232-247, Cham, Switzerland, January 2018. Gesellschaft für Sprachtechnologie und Computerlinguistik e.V., Springer. 13/14 September 2017.

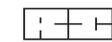
The screenshot shows the DKT Lab website. At the top left is the DKT logo (a stylized tree) and the 'condat' logo. The main header area includes the text 'DKT Lab' and a search bar with the word 'Suche' (Search) in a blue button. Below the search bar are navigation tabs: 'Beiträge', 'Perlentäucher', 'Serendipities', 'Summarization', and 'Timelining'. The main content area displays a list of news items on the left and a detailed article on the right. The article text is partially visible, mentioning 'Die Stadt Luckau übernimmt heute...' and 'Brandenburgs Finanzminister Görke...'. The article text is highlighted with red boxes.

This screenshot shows the same DKT Lab website but with a detailed view of a news article. The article title is 'Ankara geht gegen die Terrormiliz Islamischer Staat in Syrien vor'. The text is filled with red boxes highlighting various entities and locations, such as 'Ankara', 'Islamischer Staat', 'Syrien', 'Türkei', 'NATO', 'USA', 'Washington', 'Erdogan', 'PKK', 'Rebellen', 'Terrorismus', 'Friedensprozess', 'HDP', and 'Pkk'. The article text is highlighted with red boxes. The navigation tabs at the top are the same as in the previous screenshot.

Branche: TV, Web-TV, Medien

- **BMBF-Projekt Digitale Kuratierungstechnologien:**

- Museen, Showrooms, Ausstellungen
- TV, Web-TV, Medien
- Öffentliche Archive
- Journalismus

 ART+COM



3pc
Neue Kommunikation

 **kreuzwerker**
we touch running systems



Digitale
Kuratierungs-
technologien

- **Außerdem Kuratierungstechnologien konzipiert für:**

- Bibliothekswissenschaft und Digital Libraries
- Customer-Relationship-Management
- Film- und Kinobranche
- Digital Humanities

Georg Rehm. "KI für die Kundenkommunikation: Der Markt der Zukunft." Rethink! Connected Customer 360°. Hamburg, June 22/23, 2017.

Georg Rehm. "Artificial Intelligence for the Film Industry." FilmTech Meetup Berlin, July 25, 2017.

Clemens Neudecker und Georg Rehm. "Digitale Kuratierungstechnologien für Bibliotheken". *Zeitschrift für Bibliothekskultur* 027.7, Open Access. Nov. 2016.

Georg Rehm. *Der Mensch bleibt im Mittelpunkt – Smarte Technologien für alle Branchen*. Vitako Aktuell. Zeitschrift der Bundes-Arbeitsgemeinschaft der Kommunalen IT-Dienstleister e.V., 2-2016:26-27, 2016.

Peter Bourgonje, Julian Moreno Schneider, and Georg Rehm. "Domain-specific Entity Spotting: Curation Technologies for Digital Humanities and Text Analytics." In Nils Reiter and Gerhard Kremer, editors, CUTE Workshop 2017 – CRETA Unshared Task zu Entitätenreferenzen. Workshop bei DHd2017, Berne, Feb. 2017.

Generierte Folgeprojekte



- **Digitale Kuratierung von Archivmaterialien zur deutschen Wiedervereinigung** (Kooperation mit der FU Berlin, 2018/2019)
- **Kuratierungstechnologien für Forschungsdaten aus den Bereichen Sprache, Text und Digital Humanities** (Kooperation mit der TU Berlin, 2018/2019)
- **QURATOR – Curation Technologies** (BMBF, 2018-2021)
- **Interfaces to Data for Historical Social Network Analysis and Research (SoNAR)** (DFG, Start ca. März/April 2019)



Zielsetzung

- Schaffung eines **Ökosystems** für **Kuratierungstechnologien**
– wir haben dieses neue Schlagwort seit 2015 maßgeblich geprägt
- Metropolregion **Berlin-Brandenburg** als **Exzellenzstandort** für deren Entwicklung und industrielle Anwendung etablieren



Branchenlösungen

- Medical Content Curator
- Smarte Exponate
- Medien-Kurator
- Intelligente Navigation
- Risiko-Monitoring
- Next Reality Storytelling



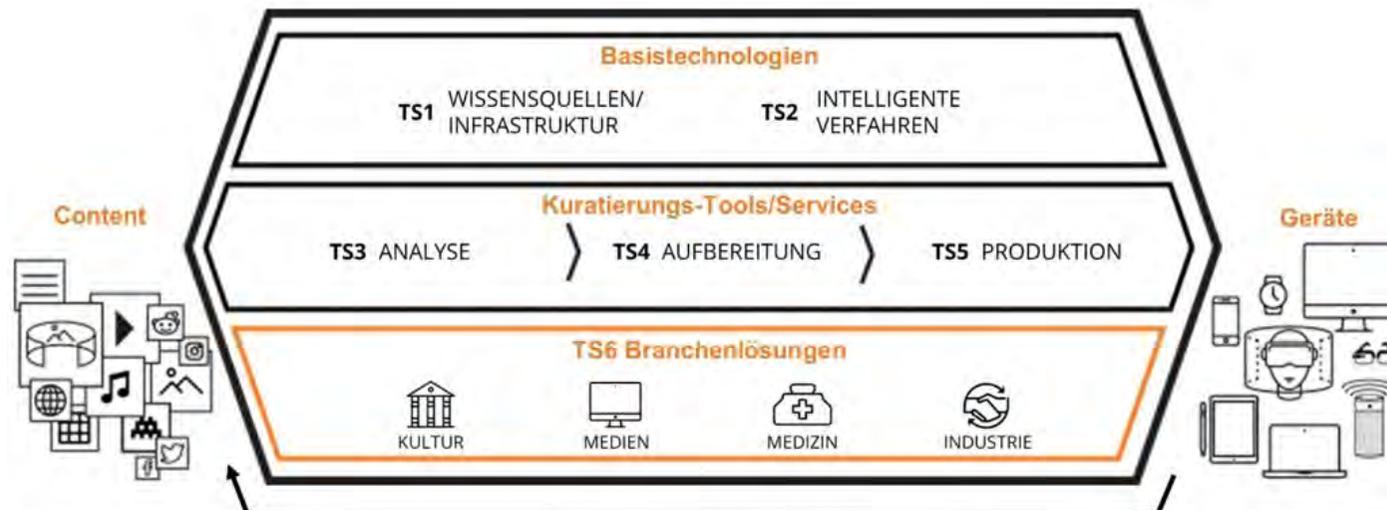
Weitere Showcases

- Content Curation Engine
- Corporate Smart Insights
- Speech-to-Text API
Video Action API
- Semantische Anreicherung
- Basistechnologien



QURATOR im Überblick

- 12 Teilprojekte – ein Verbundprojekt (Koordinator: DFKI)
- Sechs Themenschwerpunkte in drei Ebenen
- Technologieplattform folgt dem **Baukastenprinzip**
- In Teilprojekten entwickelte Verfahren sind individuell nutzbar – sie bilden die **flexibel kombinierbaren Bestandteile** und **Services** der **QURATOR-Plattform**



1. Herausforderung

Das mehrsprachige Europa:

Sprachtechnologien für alle europäischen Sprachen?

- Sehr großer Bedarf! Von einer langfristigen Investition sind zahlreiche wissenschaftliche, wirtschaftliche & gesellschaftliche Effekte zu erwarten.
- ELG für erstes Deployment. Ab 2021: Human Language Project?

2. Herausforderung

Online-Desinformationskampagnen:

Technische Lösungsansätze gegen „Fake News“?

- Automatische Klassifikation nur für drastische Inhalte/Flagging geeignet.
- Technologien können Nutzern kritischere Medienrezeption ermöglichen.

3. Herausforderung

Digitaler Content:

Technologien für die effiziente Content-Kuratierung?

- Wissensarbeiter können durch branchenspezifische Technologien bei der Kuratierung von Content sinnvoll und effektiv unterstützt werden.
- Vorteil: Die US-Tech-Riesen bedienen weder Branchen noch Nischen.

Herzlichen Dank für die Aufmerksamkeit!



META=NET

=ELG

HLP Prep =



QURATOR CURATION TECHNOLOGIES



W3C[®] WORLD WIDE WEB consortium
Deutsch-Österr. Büro

Dr. Georg Rehm
georg.rehm@dfki.de

Vielen herzlichen Dank an:
Peter Bourgonje, Aljoscha Burchardt, Thierry Declerck, Kathrin Eichler, Antske Fokkens, Josef van Genabith, Stefanie Hegele, Brigitte Jörg, Tina Klüwer, Sebastian Krause, Arle Lommel, Sebastian Möller, Julian Moreno Schneider, Jan Nehring, Roland Roller, Nieves Sande, Felix Sasaki, Ankit Srivastava, Hans Uszkoreit, Wolfgang Wahlster, Sarah Weichert.