

Machine Reading: WWW-skalierbares automatisches Textverstehen

Seminar im Modul M-GSW-09 WiSe 2018/19

Prof. Dr. Udo Hahn

Lehrstuhl für Angewandte Germanistische Sprachwissenschaft / Computerlinguistik

Institut für Germanistische Sprachwissenschaft Friedrich-Schiller-Universität Jena

http://www.julielab.de

Allgemeine Hinweise

- Termin: Do, 16-18h (Fürst.grab. 1, SR 164)
- Materialien im Netz
- Sprechstunde: Mi, 12-13h (nA) (FG 30, R 004)
- © Email: udo.hahn@uni-jena.de
- Fachliteratur: durchgängig in Englisch

Was ist Textverstehen?

- Inhaltliche Interpretation eines Textes
- Operationalisierung des Textverstehens
 - Paraphrase

Was ist Textverstehen?

Nicht angemeldet Diskussionsseite Beiträge Benutzerkonto erstellen Anmelden



Hauptseite Themenportale Zufälliger Artikel

Mitmachen

Artikel verbessern Neuen Artikel anlegen Autorenportal Hilfe Letzte Änderungen

Spenden Werkzeuge

Kontakt

Links auf diese Seite Änderungen an verlinkten Seiten Spezialseiten Artikel Diskussion Lesen Quelltext anzeigen Versionsgeschichte Wikipedia durchsuchen Q

Friedrich Schiller

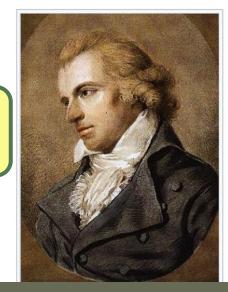


Schiller ist eine Weiterleitung auf diesen Artikel. Weitere Bedeutungen sind unter Friedrich Schiller (Begriffsklärung) und Schiller (Begriffsklärung) aufgeführt.

Johann Christoph Friedrich Schiller, ab 1802 von Schiller (* 10. November 1759 in Marbach am Neckar; † 9. Mai 1805 in Weimar), war ein Arzt, Dichter, Philosoph und Historiker. Er gilt als einer der bedeutendsten deutschen Dramatiker, Lyriker und Essayisten.

Schiller wurde als einziger Sohn eines württembergischen Militärarztes, der später den Rang eines Hauptmanns erreichte, und der Tochter eines Bäckers geboren. Mit seinen fünf Schwestern wuchs er in Schwäbisch Gmünd, Lorch und später in Ludwigsburg auf.

Viermaligem Bestenen des Evangelischen Landesexamens am 16. Januar 1773 das Studium der Rechtswissenschaften auf der Karlsschule. Drei Jahre später wechselte er zur Medizin und wurde 1780^[1] promoviert. Gleich mit seinem Theaterdebüt, dem 1782 uraufgeführten Schauspiel *Die Räuber*, gelang Schiller ein bedeutender Beitrag zum Drama des Sturm und Drang und der Weltliteratur.



Was ist Textverstehen?

- Inhaltliche Interpretation eines Textes
- Operationalisierung des Textverstehens
 - Paraphrase
 - Zusammenfassung

Was ist Textverstehen?

Nicht angemeldet Diskussionsseite Beiträge Benutzerkonto erstellen Anmelden



Hauptseite Themenportale Zufälliger Artikel

Mitmachen

Artikel verbessern Neuen Artikel anlegen Autorenportal Hilfe Letzte Änderungen Kontakt

Werkzeuge

Spenden

Links auf diese Seite Änderungen an verlinkten Seiten Spezialseiten Artikel Diskussion Lesen Quelltext anzeigen Versionsgeschichte Wikipedia durchsuchen Q

Friedrich Schiller



Schiller ist eine Weiterleitung auf diesen Artikel. Weitere Bedeutungen sind unter Friedrich Schiller (Begriffsklärung) und Schiller (Begriffsklärung) aufgeführt.

Johann Christoph Friedrich Schiller, ab 1802 von Schiller (* 10. November 1759 in Marbach am Neckar; † 9. Mai 1805 in Weimar), war ein Arzt, Dichter, Philosoph und Historiker. Er gilt als einer der bedeutendsten deutschen Dramatiker, Lyriker und Essayisten.

Schiller wurde als einziger Sohn eines württembergischen Militärarztes, der später den Rang eines Hauptmanns erreichte, und der Tochter eines Bäckers geboren. Mit seinen fünf Schwestern wuchs er in Schwäbisch Gmünd, Lorch und später in Ludwigsburg auf. Dort besuchte er die Lateinschule und begann nach viermaligem Bestehen des Evangelischen Landesexamens am 16. Januar 1773 das Studium der Rechtswissenschaften auf der Karlsschule. Drei Jahre später wechselte er zur Medizin und wurde 1780^[1] promoviert. Gleich mit seinem Theaterdebüt, dem 1782 uraufgeführten Schauspiel *Die Räuber*, gelang Schiller ein bedeutender Beitrag zum Drama des Sturm und Drang und der Weltliteratur.



Was ist Textverstehen?

- Inhaltliche Interpretation eines Textes
- Operationalisierung des Textverstehens
 - Paraphrase
 - Zusammenfassung
 - Fragebeantwortung

Was ist Textverstehen?

Nicht angemeldet Diskussionsseite Beiträge Benutzerkonto erstellen Anmelden



Hauptseite Themenportale Zufälliger Artikel

Mitmachen

Artikel verbessern Neuen Artikel anlegen Autorenportal Hilfe Letzte Änderungen

Kontakt Spenden

Werkzeuge

Links auf diese Seite Änderungen an verlinkten Seiten Spezialseiten Artikel Diskussion Lesen Quelltext anzeigen Versionsgeschichte Wikipedia durchsuchen Q

Friedrich Schiller



Schiller ist eine Weiterleitung auf diesen Artikel. Weitere Bedeutungen sind unter Friedrich Schiller (Begriffsklärung) und Schiller (Begriffsklärung) aufgeführt.

Johann Christoph Friedrich Schiller, ab 1802 von Schiller (* 10. November 1759 in Marbach am Neckar; † 9. Mai 180 in Weimar), war ein Arzt, Dichter, Philosoph und Historiker. Er gilt als einer der bedeutendsten deutschen Dramatiker, Lyriker und Essayisten.

Schiller wurde als einziger Sohn eines württembergischen Militärarztes, der später den Rang eines Hauptmanns erreichte, und der Tochter eines Bäckers geboren. Mit seinen fünf Schwestern wuchs er in Schwäbisch Gmünd, Lorch und später in Ludwigsburg auf. Dort besuchte er die Lateinschule und begann nach viermaligem Bestehen des Evangelischen Landesexamens am 16. Januar 1773 das Studium der Rechtswissenschaften auf der Karlsschule. Drei Jahre später wechselte er zur Medizin und wurde 1780^[1] promoviert. Gleich mit seinem Theaterdebüt, dem 1782 uraufgeführten Schauspiel *Die Räuber*, gelang Schiller ein bedeutender Beitrag zum Drama des Sturm und Drang und der Weltliteratur.



Was ist Textverstehen?

Nicht angemeldet Diskussionsseite Beiträge Benutzerkonto erstellen Anmelden



Hauptseite Themenportale Zufälliger Artikel

Mitmachen

Artikel verbessern Neuen Artikel anlegen Autorenportal Hilfe

Letzte Änderungen Kontakt

Werkzeuge

Spenden

Links auf diese Seite Änderungen an verlinkten Seiten Spezialseiten Artikel Diskussion Lesen Quelltext anzeigen Versionsgeschichte Wikipedia durchsuchen Q

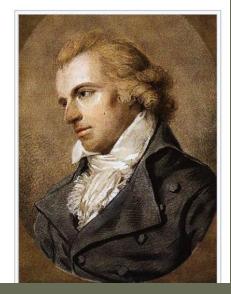
Friedrich Schiller



Schiller ist eine Weiterleitung auf diesen Artikel. Weitere Bedeutungen sind unter Friedrich Schiller (Begriffsklärung) und Schiller (Begriffsklärung) aufgeführt.

Johann Christoph Friedrich Schiller, ab 1802 von Schiller (* 10. November 1759 in Marbach am Neckar; † 9. Mai 1805 in Weimar), war ein Arzt, Dichter, Philosoph und Historiker. Er gilt als einer der bedeutendsten deutschen Dramatiker, Lyriker und Essayisten.

Schiller wurde als einziger Sohn eines württembergischen Militärarztes, der später den Rang eines Hauptmanns erreichte, und der Tochter eines Bäckers geboren. Mit seinen fünf Schwestern wuchs er in Schwäbisch Gmünd, Lorch und später in Ludwigsburg auf. Dort besuchte er die Lateinschule und begann nach viermaligem Bestehen des Evangelischen Landesexamens am 16. Januar 1773 das Studium der Rechtswissenschaften auf der Karlsschule. Drei Jahre später wechselte er zur Medizin und wurde 1780^[1] promoviert. Gleich mit seinem Theaterdebüt, dem 1782 uraufgeführten Schauspiel Die Räuber, telang Schiller ein bedeutender Beitrag zum Drama des Sturm und Drang und der Weltliteratur.



Frage: Mit welchem Erstlingswerk feierte Friedrich Schiller den Beginn seiner Karriere als Schriftsteller und Theaterautor ?

Was ist Machine Reading?

- Textverstehen operationalisiert als Fragebeantwortung
- Vollautomatisch durch Rechner ausgeführt
- Mit Zugriff auf potenziell alle Dokumente, die im WWW (World Wide Web) verfügbar sind (Skalierbarkeit der Verfahren)

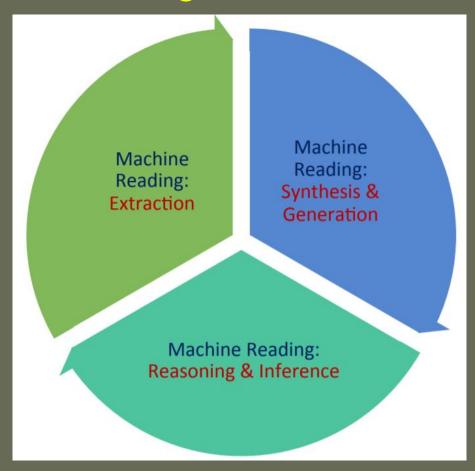
Was ist Machine Reading?

- Machine Reading (1: Furu Wei, 2017)
 - automatisches, unüberwachtes Verstehen von beliebigen Texten aus sehr großen (Web-skalierbaren) Textkollektionen
 - Explizite Antwort: direkt in den Textdaten verfügbar
 - Implizite Antwort: muss aus Textdaten oder Hintergrundwissen inferiert werden (textual entailment)
- Machine Reading (2: Burgess, 2013)
 - "A machine comprehends a passage of text if, for any question regarding that text, it can be answered correctly by a majority of native speakers.
 - The machine needs to provide a string which human readers would agree both
 - 1. Answers that question
 - 2. Does not contain information irrelevant to that question."

Was ist Machine Reading?

- Verwandte Konzepte:
 - Open-domain information extraction –
 Knowledge base population
 - Open-domain question answering
- Startpunkt: AAAI Symposium on Machine Reading (2006)
 - https://www.aaai.org/Library/Symposia/Spring/ss07-06.php
- AI-complete problem

Zentrale Aufgaben beim Machine Reading



• Quelle: Furu Wei (2017):

http://tcci.ccf.org.cn/summit/2017/dlinfo/003.pdf

Zentrale Aufgaben beim Machine Reading: Antwort-Extraktion

Passage

The Rhine (Romansh: Rein, German: Rhein, French: le Rhin, Dutch: Rijn) is a European river that begins in the Swiss canton of Graubünden in the southeastern Swiss Alps, forms part of the Swiss-Austrian, Swiss-Liechtenstein border, Swiss-German and then the Franco-German border, then flows through the Rhineland and eventually empties into the North Sea in the Netherlands. The biggest city on the river Rhine is Cologne, Germany with a population of more than 1,050,000 people. It is the second-longest river in Central and Western Europe (after the Danube), at about 1,230 km (760 mi), with an average discharge of about 2,900 m3/s (100,000 cu ft/s).

Answer Extraction

Question What river is larger than the Rhine?

Answer Danube

* Example from the SQuAD dataset

• Quelle: Furu Wie (2017):

http://tcci.ccf.org.cn/summit/2017/dlinfo/003.pdf

Zentrale Aufgaben beim Machine Reading: Antwort-Synthese

P1: Impact on Japan's Economy. The Triple Disaster devastated Japan's economy in four ways. First, it destroyed 138,000 buildings and **cost \$360 billion in economic damage.** This is more than the \$250 billion cost estimate for Hurricane Katrina.

Passage

P2: apan's 2011 Earthquake and Tsunami: Economic Effects and Implications for the U.S. Congressional Research Service 3 construction supplies. If imports of certain products from Japan become scarce, China, South Korea, or other nations may gain at Japan's expense.

Answer Synthesis & Generation

Question What is the economic impact of the Japan earthquake

Answer Japan have \$360 billion economic damage because of earthquake.

* Example from the MS MARCO dataset

 Quelle: Furu Wie (2017): http://tcci.ccf.org.cn/summit/2017/dlinfo

Zentrale Aufgaben beim Machine Reading: Folgern & Inferieren

Passage

During the construction of the Quebec Bridge in 1907, the bridge's designer, Theodore Cooper, received word that the suspended span being built out from the bridge's cantilever was deflecting downward by a fraction of an inch (2.54 centimeters). Before he could telegraph to freeze the project, the whole cantilever arm broke off and plunged, along with seven dozen workers, into the St. Lawrence River. It was the worst bridge construction disaster in history. As a direct result of the inquiry that followed, the engineering "rules of thumb" by which thousands of bridges had been built around the world went down with the Quebec Bridge. Twentieth-century bridge engineers would thereafter depend on far more rigorous applications of mathematical analysis.

Reasoning & Inference

Question

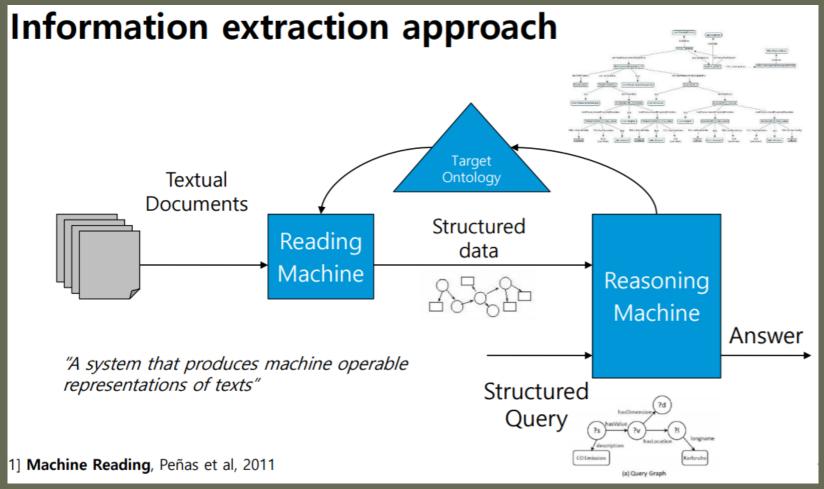
Which one of the following statements can be properly inferred from the passage?

Answer

- (A): Bridges built before about 1907 were built without thorough mathematical analysis and, therefore, were unsafe for the public to use.
- (B): Cooper's absence from the Quebec Bridge construction site resulted in the breaking off of the cantilever.
- (C): Nineteenth-century bridge engineers relied on their rules of thumb because analytical methods were inadequate to solve their design problems.
- (D): Only a more rigorous application of mathematical analysis to the design of the Quebec Bridge could have prevented its collapse.
- (E): Prior to 1907 the mathematical analysis incorporated in engineering rules of thumb was insufficient to completely assure the safety of bridges under construction.
- * Example from the LSAT dataset (Logical Reasoning & Reading Comprehension)
- Quelle: Furu Wie (2017):

http://tcci.ccf.org.cn/summit/2017/dlinfo/003.pdf

Systemarchitektur für Machine Reading



 Quelle: Julien Perez (2018): https://project.inria.fr/paiss/files/2018/07/perez-machine-reading.pd

Machine Reading besser als menschliches Textverstehen!

- Szenario:
 - Stanford Question Answer Dataset besteht aus 10.000 Fragen zu ca. 500 Wikipedia-Artikeln. Die Antworten sind Textsegmente (text spans) aus diesen Artikeln
- Menschliches Textverstehen auf SQuAD:

• **-**: 82,30%

• Automatisches Textverstehen auf SQuAD:

• Alibaba: 82,44%

• Microsoft: 82,65%

Datensätze für das Machine Reading: SQuAD



SQuAD: 100,000+ Questions for Machine Comprehension of Text

Best Resource Paper in EMNLP 2016

Pranav Rajpurkar and Jian Zhang and Konstantin Lopyrev and Percy Liang
{pranavsr,zjian,klopyrev,pliang}@cs.stanford.edu
Computer Science Department
Stanford University

passage ——	In meteorology, precipitation is any product of the condensation of atmospheric water vapor that falls under gravity. The main forms of precipitation include drizzle, rain, sleet, snow, graupel and hail Precipitation forms as smaller droplets coalesce via collision with other rain drops or ice crystals within a cloud. Short, intense periods of rain in scattered locations are called "showers".
query —— answer ——	What causes precipitation to fall? gravity
	What is another main form of precipitation besides drizzle, rain, snow, sleet and hail? graupel
	Where do water droplets collide with ice crystals to form precipitation?

Dataset	# of questions
Training	87,599
Dev	10,570
Test (not available for participants)	~10K

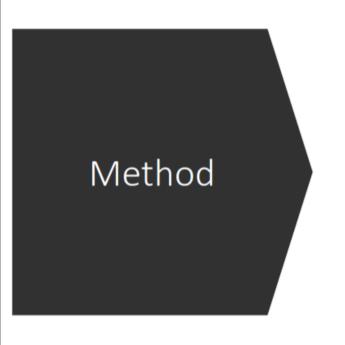
ImageNet-style competition for machine reading comprehension

Quelle: Furu Wei (2017):

within a cloud

http://tcci.ccf.org.cn/summit/2017/dlinfo/003.pdf

Methoden des Machine Reading



Before 2015:

- Lexical matching
- Logistic regression

Sachan et al., ACL 2015

Wang et al., ACL 2015

Chen et al., ACL 2016

After 2015:

Attentive Reader

Memory Networks

Gated-attention Reader

ReasoNet

Match-LSTM

Attention Sum Reader

Attention-over-Attention Reader

Iterative Attentive Reader

Dynamic **coattention** networks

Bi-directional **Attention** Flow Network

Multi-Perspective Context Matching

. .

* Source: "Towards the Machine Comprehension of Text" by Danqi Chen, 2017.

Quelle: Furu Wei (2017):
 http://teci.cef.org.cn/sum

Prototypische Systeme

Snowball

Agichtein, Eugene, & Gravano, Luis (2000). Snowball: Extracting relations from large plain-text collections.
 In: Digital Libraries '00 - Proceedings of the 5th ACM International Conference on Digital Libraries. San Antonio, TX, USA, June 2-7, 2000, pp. 85–94.

KnowItAll

 Etzioni, Oren, & Cafarella, Michael J., & Downey, Doug, & Popescu, Ana-Maria, & Shaked, Tal, & Soderland, Stephen G., & Weld, Daniel S., & Yates, Alexander (2005). Unsupervised named-entity extraction from the Web: an experimental study. In: Artificial Intelligence, 165(1):91–134.

TextRunner

Yates, Alexander, & Cafarella, Michael J., & Banko, Michele, & Etzioni, Oren, & Broadhead, Matthew, & Soderland, Stephen G. (2007). TextRunner: Open information extraction on the Web. In: NAACL-HLT 2007 – Proceedings of Demonstrations. Rochester, New York, USA, 23–25 April 2007, pp. 25–26.

NELL (Never-Ending Language Learner)

• Mitchell, Tom M., & Cohen, William W., & Hruschka Jr., Estevam R., & Talukdar, Partha Pratim, & Betteridge, Justin, & Carlson, Andrew, & Mishra, Bhavana Dalvi, & Gardner, Matthew, & Kisiel, Bryan, & Krishnamurthy, Jayant, & Lao, Ni, & Mazaitis, Kathryn, & Mohamed, Thahir, & Nakashole, Ndapandula, & Platanios, Emmanouil Antonios, & Ritter, Alan, & Samadi, Mehdi, & Settles, Burr, & Wang, Richard, & Wijaya, Derry Tanti, & Gupta, Abhinav, & Chen, Xinlei, & Saparov, Abulhair, & Greaves, Malcolm, & Welling, Joel (2015). Never-ending learning. in: AAAI '15 – Proceedings of the 29th AAAI Conference on Artificial Intelligence. Austin, Texas, USA, January 25-30, 2015, 2302–2310

Jack the Reader

Weissenborn, Dirk, & Minervini, Pasquale, & Dettmers, Tim, & Augenstein, Isabelle, & Welbl, Johannes, & Rocktäschel, Tim, & Bošnjak, Matko, & Mitchell, Jeff, & Demeester, Thomas, & Stenetorp, Pontus, & Riedel, Sebastian (2018). Jack the Reader: a machine reading framework. in: ACL 2018 – Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics: System Demonstrations. Melbourne, Victoria, Australia, July 15-20, 2018, 25–30.

Referatthemen

- DARPA Machine Reading Programme
- Basisaufgaben
 - Informationsextraktion
 - Fragebeantwortung, Antwortsynthese
 - Schlussfolgern, Inferieren (textual entailment)
- Ressourcen
 - Korpora (SQuAD, etc.)
- Prototypische Systeme (und damit Methoden):
 - Frühere Systeme:
 - Snowball, KnowItAll, TextRunner
 - Neuere Systeme:
 - NELL
 - Neuronale Systeme:
 - Deep Reader, Jack the Reader
- Evaluation: QA4MRE @ CLEF

Seminarleistungen

- Vortrag (mündlich)
 - 1-stündig
 - Elektronische Version (PDF, PPT) verfügbar machen
- Referat (schriftlich)
 - 15-20 Seiten Kerntext (mit Standardformaten)
 - Elektronische Version (PDF, DOC) verfügbar machen
 - Eidesstattliche Erklärung zur Eigenautorenschaft
 - Wir prüfen mit Plagiatserkennungs-Software
 - Abgabe: Anfang März 2019

Bemerkungen zu Referaten

• Aufbaumuster:

- Deck- bzw. Titelblatt mit vollständigen Angaben
- Inhaltsverzeichnis
- Einführung ins Thema, Motivation
- Themenabhandlung: grundlegende Formalisierungen, Verfahrensbeschreibungen (Algorithmen), Systemfunktionalitäten, Ressourcenmerkmale, Experimente/Evaluationen usw.
- Fazit mit kritischer Würdigung, offene Probleme ansprechen
- Bibliographie

• Zitationen:

- Alle verwendeten Quellen zitieren
 - Mit einem bibliographisch korrektem Zitat die jeweilige Quelle eindeutig beschreiben
 - Fachartikel <u>nicht</u> mit http://...foo.pdf-Link zitieren
 - Online-Quellen mit URLs und Datum des letztem Zugriffs
- Wikipedia ist keine zitierfähige wissenschaftliche Quelle!
- Eigenleistungen (Literatur, Beschäftigung mit konkreten Ressourcen/Systemen usw.) sind sehr erwünscht→unabdingbar!

Wege zum Vortrag und Referat

- Email: Anmeldung von drei nach fallender
 Priorität geordneten Themenwünschen
 - First-come, first-served
- Email: Themenvergabe durch Dozenten
- Erste Literaturhinweise als "Saat" nach Bestätigung der Themenauswahl
- Themenbearbeitung durch Referenten
 - Mündlicher Vortrag zum vereinbarten Termin
 - Schriftliches Referat (unter Einhaltung der organisatorischen Verabredungen) zum vereinbarten Termin

Grundlegende Literatur

- Etzioni, Oren, & Banko, Michele, & Cafarella, Michael J. (2006). Machine reading. In: AAAI '06 Proceedings of the 21st National Conference on Artificial Intelligence. Boston, MA, USA, July 16–20, 2006, pp. 1517–1519.
- Etzioni, Oren, & Banko, Michele, & Soderland, Stephen G., & Weld, Daniel S. (2008). Open information extraction from the Web. In: *Communications of the ACM*, 51(12):68–74.
- Hermann, Karl Moritz, & Ko?iský, Tomáš, & Grefenstette, Edward, & Espeholt, Lasse, & Kay, Will, & Suleyman, Mustafa, & Blunsom, Phil (2015). Teaching machines to read and comprehend. In:
 Advances in Neural Information Processing Systems 28 NIPS 2015. Proceedings of the 29th Annual Conference on Neural Information Processing Systems. Montréal, Québec, Canada, December 7-12, 2015, pp. 1693–1701.
- Peñas, Anselmo, & Hovy, Eduard H., & Forner, Pamela, & Rodrigo, Álvaro, & Sutcliffe, Richard F. E., & For?scu, Corina, & Sporleder, Caroline (2012). Evaluating machine reading systems through comprehension tests. In: LREC 2012 Proceedings of the 8th International Conference on Language Resources and Evaluation. Istanbul, Turkey, May 21-27, 2012, pp. 1143-1147.
- Strassel, Stephanie M., & Adams, Dan, & Goldberg, Henry, & Herr, Jonathan, & Keesing, Ron, & Oblinger, Daniel, & Simpson, Heather, & Schrag, Robert, & Wright, Jonathan D. (2010). The DARPA Machine Reading Program: encouraging linguistic and reasoning research with a series of reading tasks. In: LREC 2010 Proceedings of the 7th International Conference on Language Resources and Evaluation. La Valletta, Malta, May 17-23, 2010, 986-993.
- Peñas, Anselmo, & Hovy, Eduard H., & Forner, Pamela, & Rodrigo, Álvaro, & Sutcliffe, Richard F. E., & Morante, Roser (2013). QA4MRE 2011-2013: Overview of Question Answering for Machine Reading Evaluation. In: Information Access Evaluation. Multilinguality, Multimodality, and Visualization. CLEF 2013 Proceedings of the 4th International Conference of the CLEF Initiative. Valencia, Spain, September 23-26, 2013, pp. 303-320.

Online-Tutorials

- Furu Wei (2017)
 - http://tcci.ccf.org.cn/summit/2017/dlinfo/003.pdf
- Julien Perez (2018)
 - https://project.inria.fr/paiss/files/2018/07/perez-machinereading.pdf
- Christopher Manning (2016)
 - https://nlp.stanford.edu/manning/talks/SIGIR2016-Deep-Learning-NLI.pdf

Wichtige Forschungsgruppen

- KnowItAll (U Washington)
 - http://projectsweb.cs.washington.edu/research/knowitall/
- Read the Web (Carnegie-Mellon U CMU)
 - http://rtw.ml.cmu.edu/rtw/
- Machine Reading (University College London UCL)
 - https://mr.cs.ucl.ac.uk/

Wichtige Konferenzen

- Papers from the AAAI Spring Symposium. Oren Etzioni, Chair. Technical Report SS-07-06, 104 pp.
 DARPA Machine Reading Program
- Workshop on Machine Reading @ K-Cap 2017. December 4, 2017

Ablaufplan

```
18.10.
           Hahn
25.10.
           Hahn – Themenvergabe
01.11.
08.11.
            Gesprächstermin
15.11.
22.11.
29.11.
06.12.
13.12.
20.12.
10.01.
17.01.
24.01.
31.01.
07.02.
```