Information Retrieval

Ulf Leser

Web Search Engines

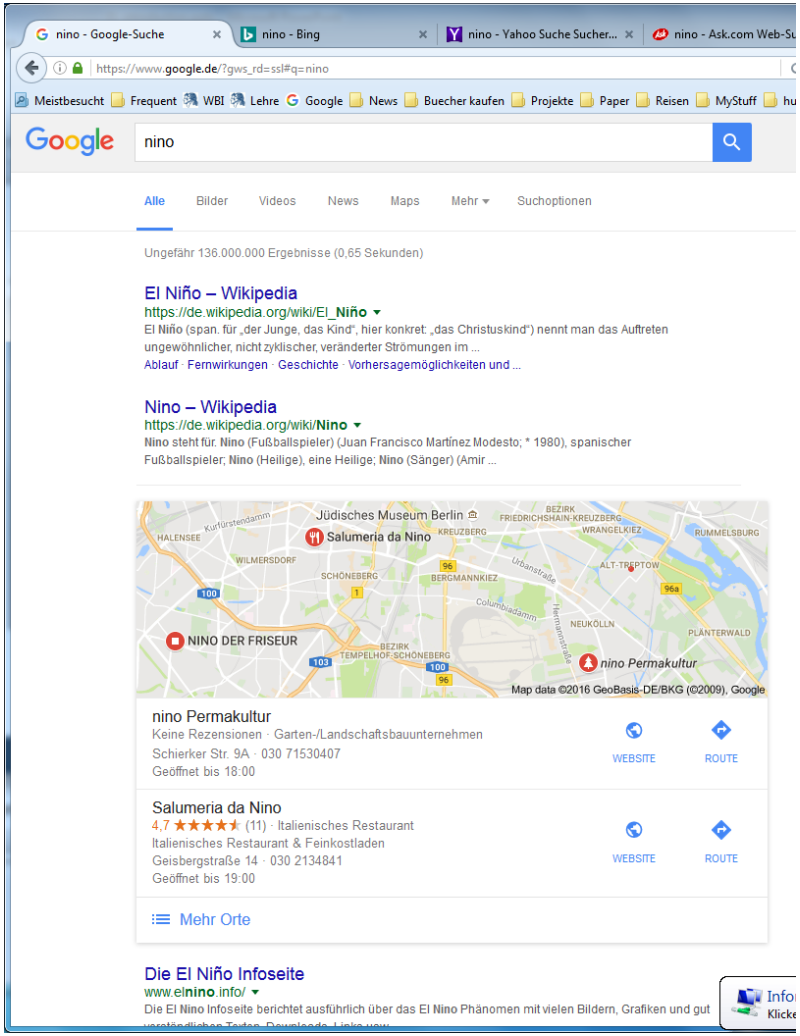

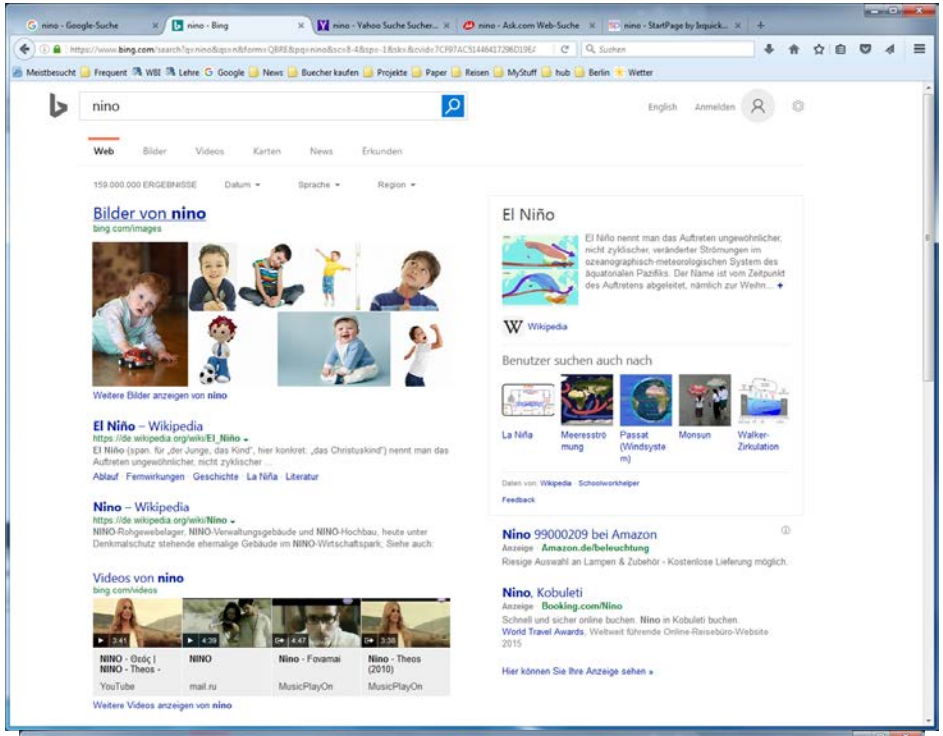

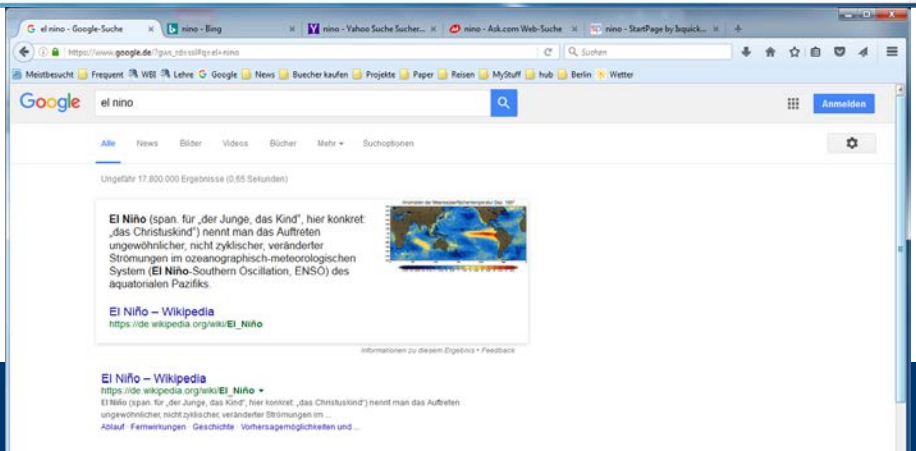

Web Search Engines

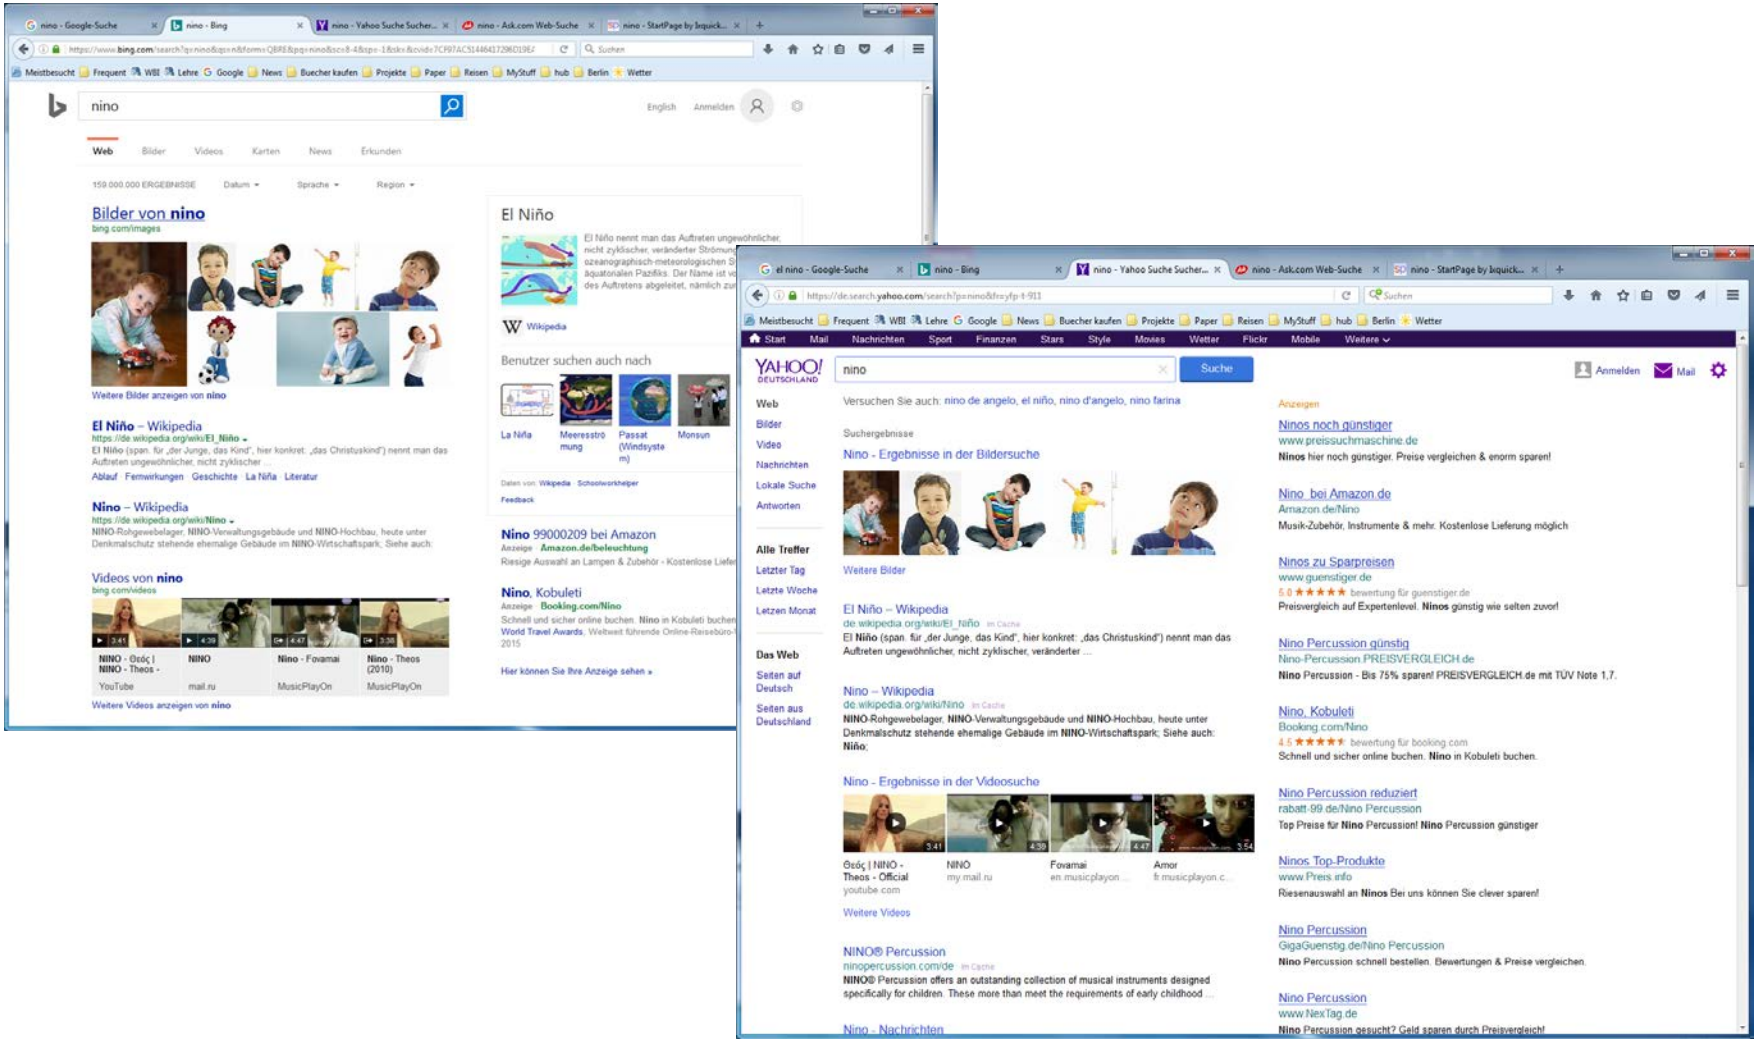

Estimated Scale [Beware: Diverging evidences]

- Queries (only google, 2016)
  - World-wide: ~150.000.000.000 queries / month
    - Per day: ~5.000.000.000
    - Per second: ~50.000
  - Germany: ~5.000.000.000 queries / month
- Web (how to count / estimate?)
  - 14.3 Trillion webpages (www.factshunt.com, 31.12.13)
  - >4.29 billion webpages (www.worldwidewebsize.com, 15.10.14)
  - >1 billion sites (www.internetlivestats.com, 15.10.14)
  - ~5 billion sites (WorldWideWebSize.com, June 2016)

Market Shares (2014)

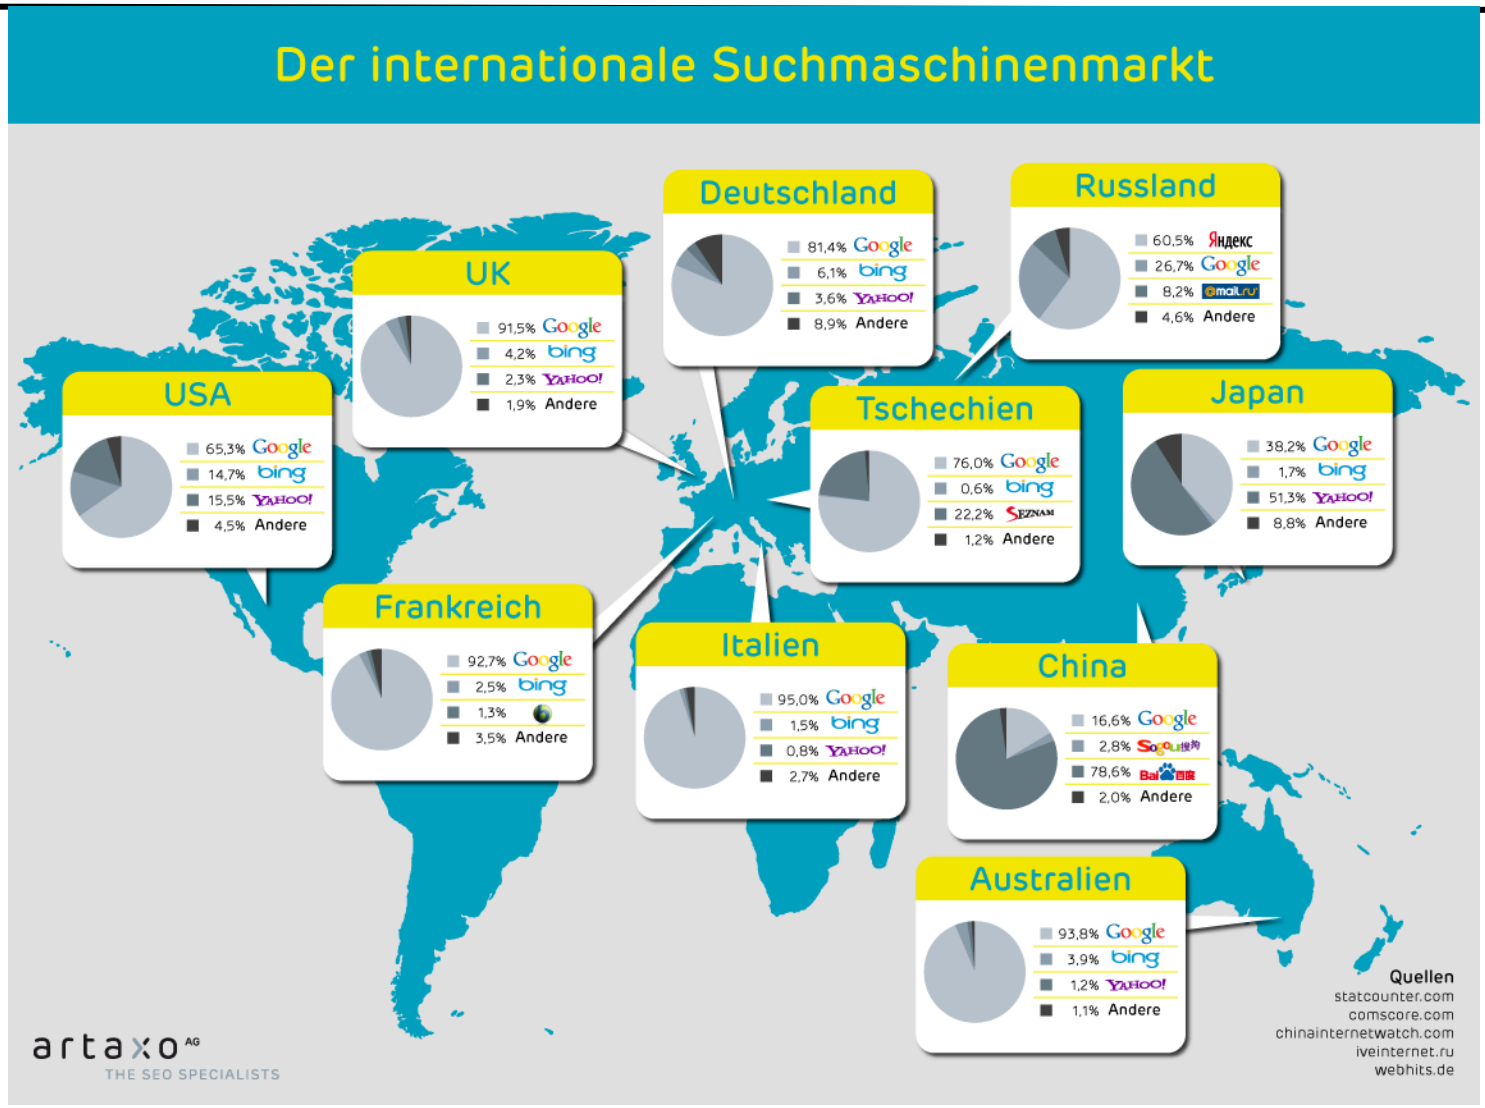

Web Basics

Server T:

\index.html
\comm\pic.jpg
\comm\product.html
...

Server S:

\index.html
\main\pic.jpg
\main\text.html
...

Client/Browser:

S: Gib „\index.html“...

```
<html>
  blabla <a href=„http:T\index.html“>blublu</a>
</html>
```

Searching the Web?

- Browser needs server name and page name (URL)
  - Mostly taken from a link
- Browser loads page from server for display
- Web consists of >1.000.000.000 sites
- How can we search 1 billion sites in milliseconds?
  - Corresponding to 100? 1000? billion web pages

Crawling

- At query time, only one server is searched – located at the search engine
- Every search engine has a (partial) copy of the web
- Created and maintained by a crawler

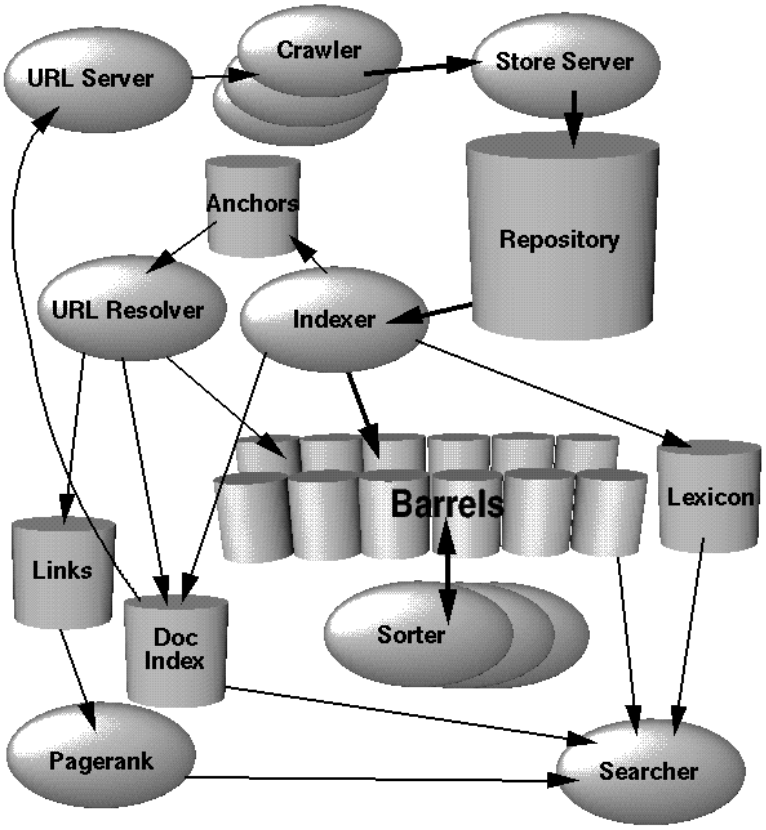

Not (easily) Indexed: The Deep Web

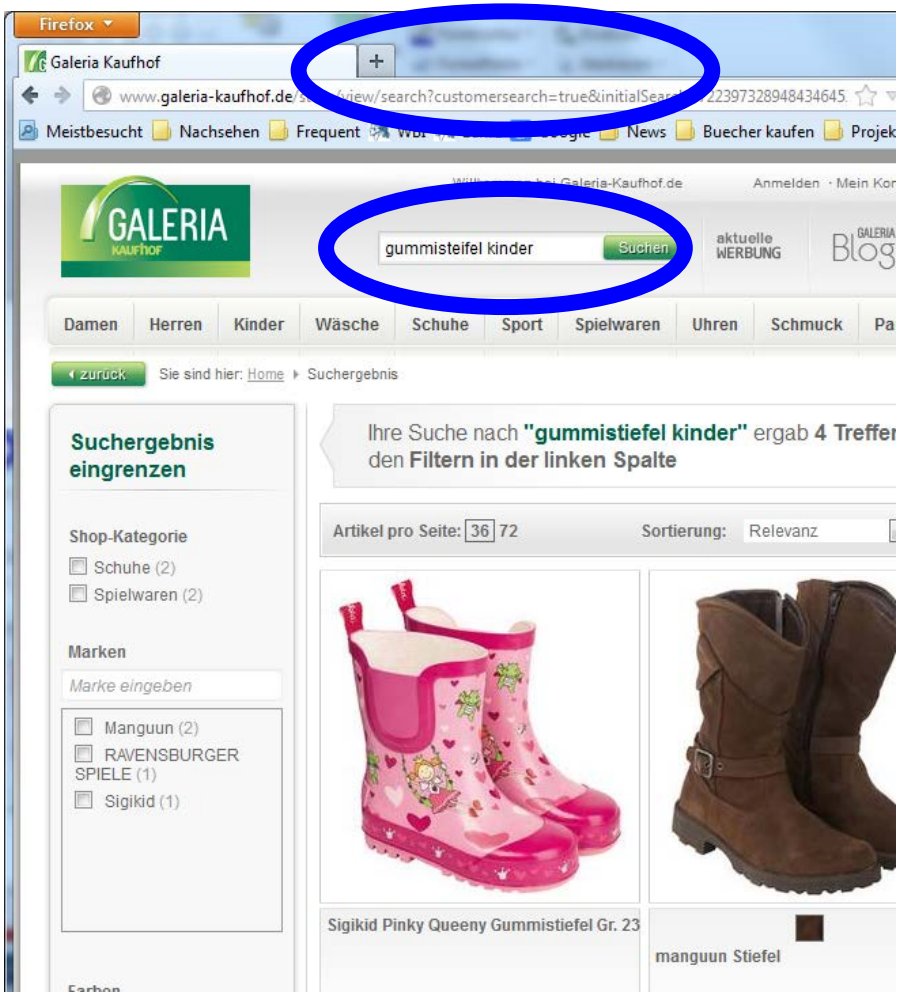

What is a good Search result?

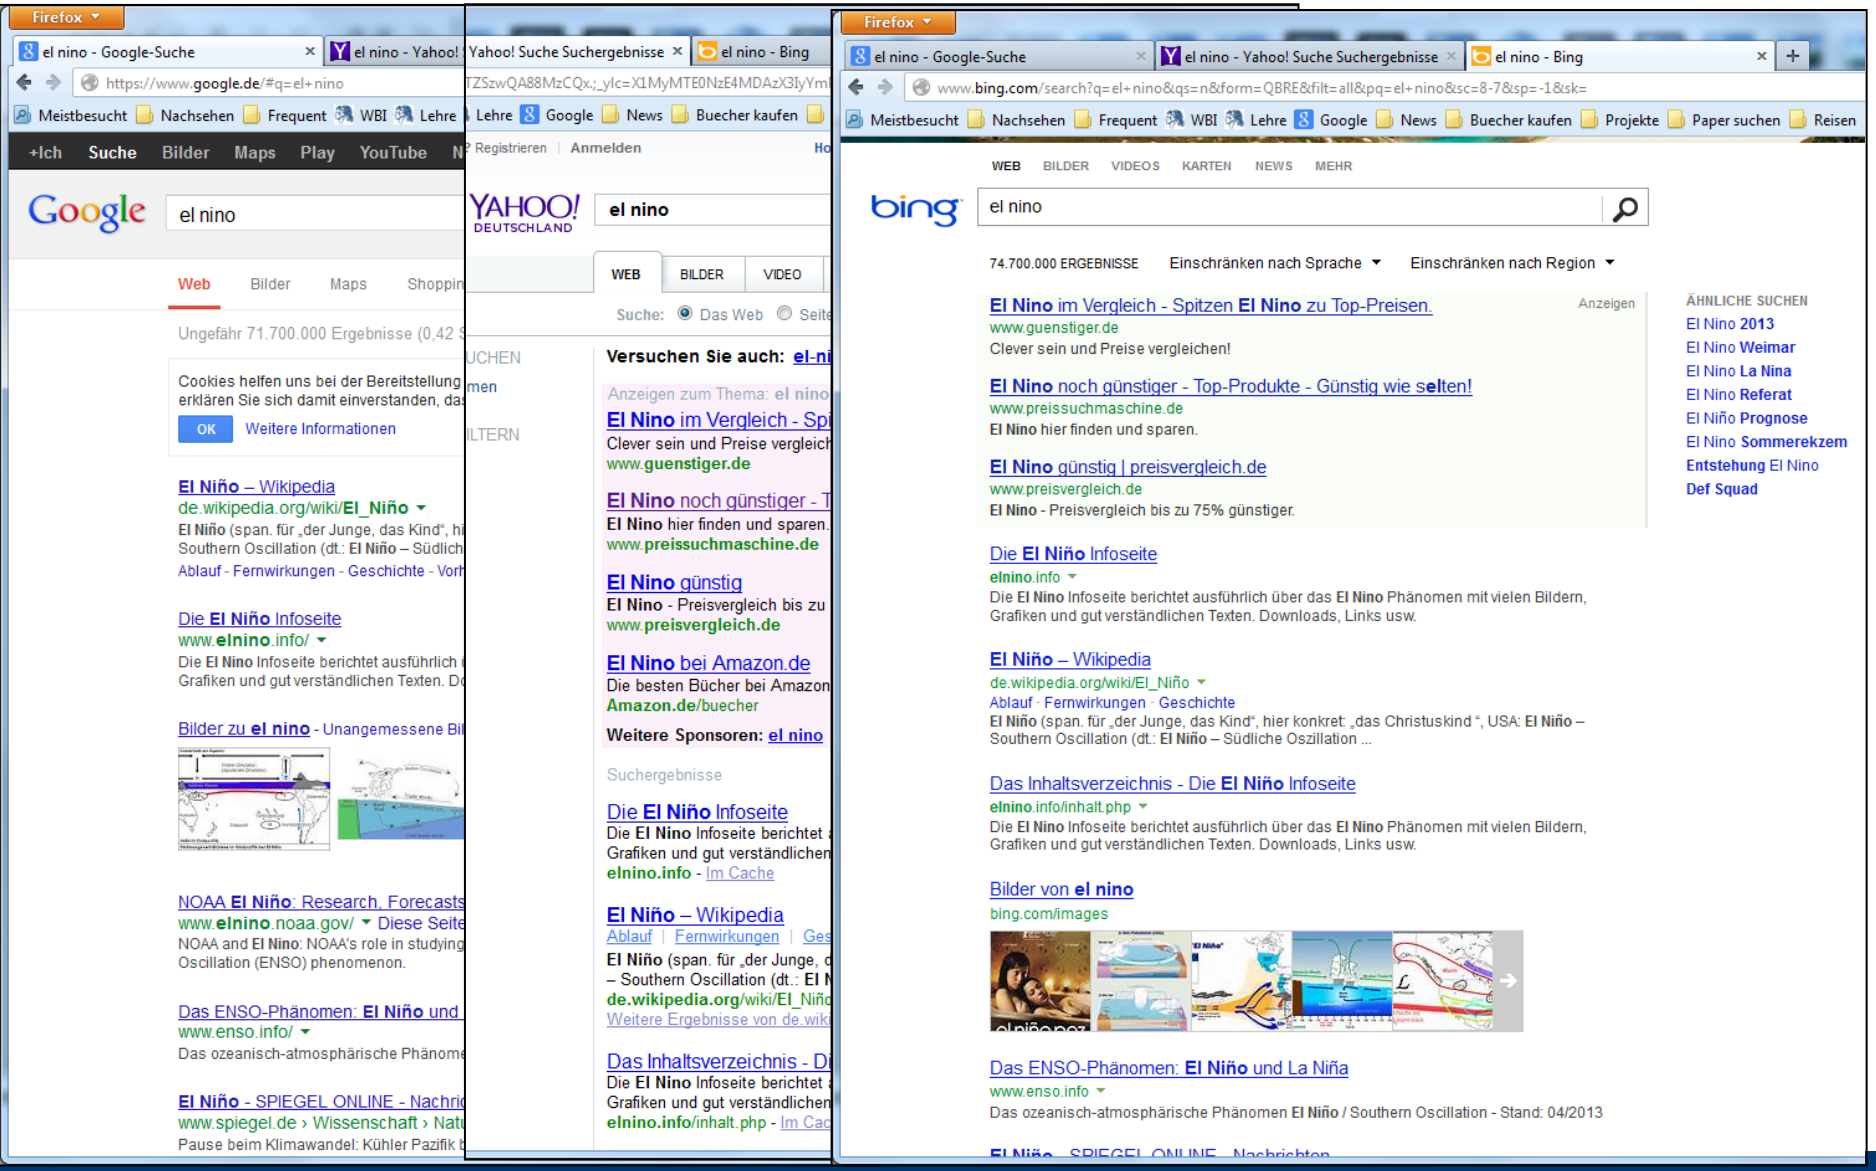

What do you Expect?

- Climate researcher: The weather phenomena
- Traveler to Peru: Implications of the weather phenomena
- Citizens of Weimar: The Restaurant
- Cineastes: The movie
- Outdoor fan: The brand
- ...

Challenges to Keyword Search

- How can we measure relevance of a page given a query?

- Interpreting a query is difficult
  - Users have different intentions and understandings
  - Many words have many senses: Homonyms
    - Usually you look for only one sense
    - Usually a web side uses only one sense: One sense per discourse
  - Many things have many names: Synonyms
- One remedy: Longer queries
  - Use semantically close word to narrow down: „El nino pazifik klima“
  - But: These again have homonyms
  - Large corpus (web): Precision increases, recall doesn’t matter
  - Small corpus (library): Precision may decrease, recall increase

Boolean Keyword Search (with AND semantics)

- Naive: A page is relevant iff it contains all query token
- Disadvantages
  - <El nino> – many false positives (because homonyms – el, nino)
    - “EL nino jugaba futbol” – But who searches for “the boy”?
  - <El nino pazifik klima> – many false negatives
    - „El Nino ist ein Phänomen, dass im pazifischen Ozean auftritt und das Wetter weltweit beeinflusst“
- Web problem
  - There are anyway 100.000+ hits
  - FP are not really important, but ranking is
- Boolean information retrieval: From the 80ths
  - Does not work for lay people (Web)
  - Does not work for very large corpora (Web)

Vector Space Model

- Transform each page into a high dimensional vector

- Every unique token is a dimension
- Value can be binary, or count occurrences, or ...
- Vector as has many dimensions as there are unique tokens on the web

Example (after linguistic preprocessing)

	Text	verkauf	haus	italien	gart	miet	blüh	woll
1	Wir verkaufen Häuser in Italien	1	1	1				
2	Häuser mit Gärten zu vermieten		1		1	1		
3	Häuser: In Italien, um Italien, um Italien herum		1	1				
4	Die italienschen Gärtner sind im Garten			1	1			
5	Der Garten in unserem italienschen Haus blüht		1	1	1		1	

Comparing Vectors

- Assumption: Texts with semantically similar content will share many token
- Their vectors are similar (in some sense)

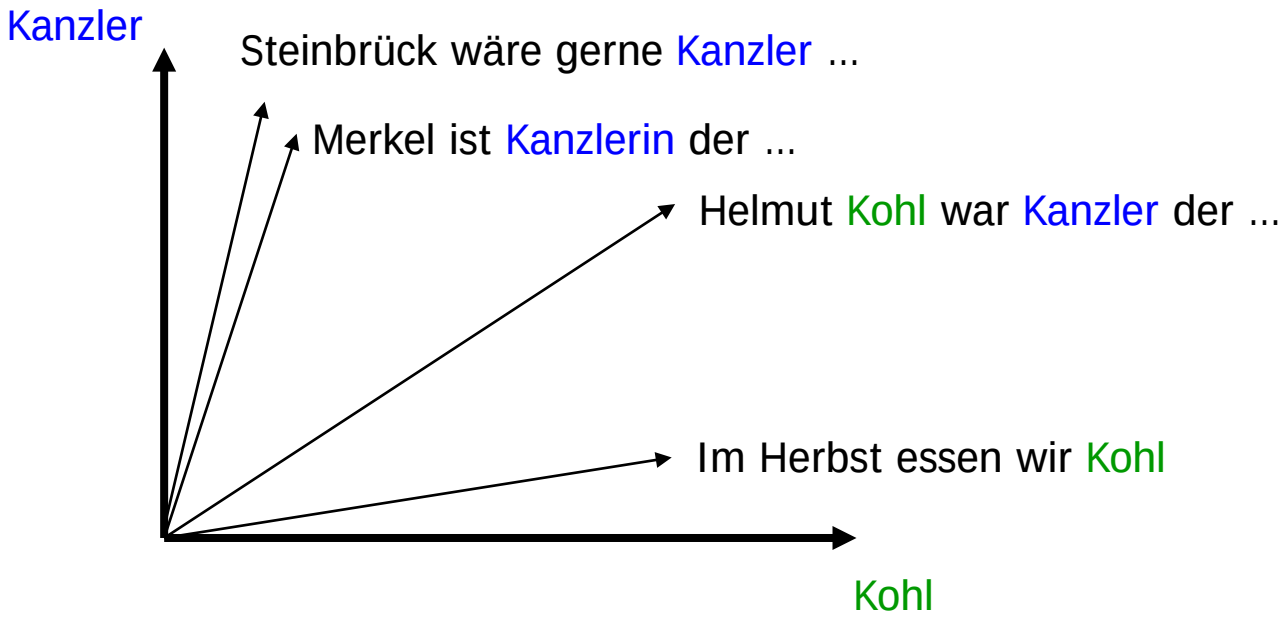

Pages and Queries

	Text	verkauf	haus	italien	gart	miet	blüh	woll
1	Wir verkaufen Häuser in Italien	1	1	1				
2	Häuser mit Gärten zu vermieten		1		1	1		
3	Häuser: In Italien, um Italien, um Italien herum		1	1				
4	Die italienschen Gärtner sind im Garten			1	1			
5	Der Garten in unserem italienschen Haus blüht		1	1	1		1	
Q	Wir wollen ein Haus mit Garten in Italien mieten		1	1	1	1		1

Using the Angle between Vectors

$$sim(d,q) = \frac{\sum \left(v_q[i] * v_d[i] \right)}{\sqrt{\sum v_d[i]^2}}$$

1	1	1	1				
2		1		1	1		
3		1	1				
4			1	1			
5		1	1	1		1	
Q		1	1	1	1		1

	Q: Wir wollen ein **Haus** mit **Garten** in **Italien mieten**
1	d_2: **Häuser** mit **Gärten** zu **vermieten**
2	d_5: Der **Garten** in unserem **italienschen Haus** blüht
3	d_4: Die **italienschen Gärtner** sind im **Garten**
	d_3: **Häuser**: In **Italien**, um **Italien**, um **Italien** herum
5	d_1: Wir verkaufen **Häuser** in **Italien**

A Solution?

- <El nino pazifik klima>

  – Problem: „El Nino ist ein Phenomen, dass im pazifischen Ozean auftritt und das Wetter weltweit beeinflusst“

  ➢ Missing words are not decisive any more – just a wider angle

  ➢ The more shared words, the smaller the angle, the better the rank

  – Problem: Ranking for short queries with very many results

  ➢ Pages having the same token in common with the query all get the same rank

  ➢ We need more ranking power: PageRank

Modul Information Retrieval

- Lecture 2 SWS
- Exercises 2 SWS
- Slides are English
- Examination: Written (Klausur)

- Contact

Ulf Leser
Raum: IV.401
Tel: (030) 2093 – 3902
eMail: leser (..) informatik . hu-berlin . de

Literatur

- Manning, C. D., Raghavan, P. and Schütze, H. (2008). “Introduction to Information Retrieval", Cambridge UP
- Other
  - Grossmann, Frieder: „Information Retrieval“, Springer, 2004
  - Henrich (2007): „Information Retrieval 1 “, Online-Lehrbuch
  - Witten, Mofffat, Bell (1999): „Managing Gigabytes: Compressing and Indexing Documents and Images“, Morgan Kaufmann
- Also interesting
  - Lemnitzer, L. and Zinsmeister, H. (2010). "Korpuslinguistik - Eine Einführung", narr Studienbücher.
  - Lüdeling, A. (2009). "Grundkurs Sprachwissenschaft". Stuttgart, Klett Lerntraining.
  - Manning, C.D., Schütze, H. (1999). „Foundations of Statistical Natural Language Processing”, MIT Press.

Web

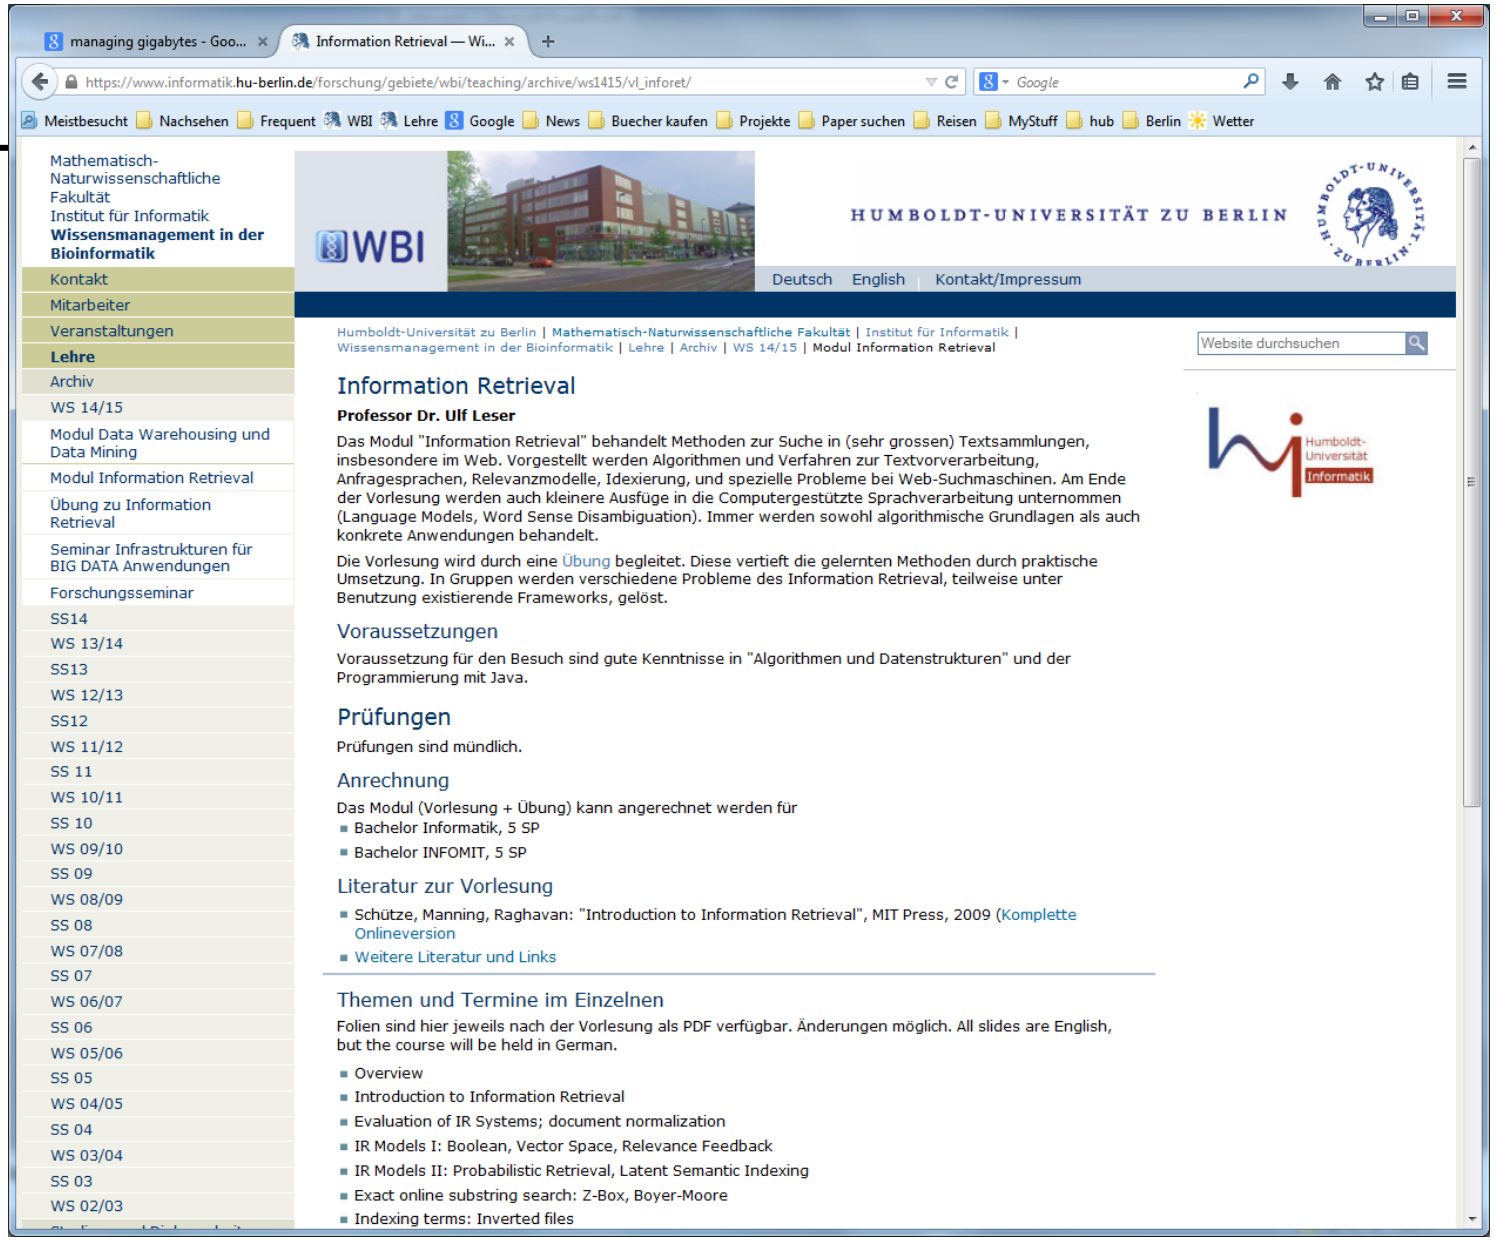
managing gigabytes - Goo...
Information Retrieval — Wi...
https://www.informatik.hu-berlin.de/forschung/gebiete/wbi/teaching/archive/ws1415/vl_inforet/
Meistbesucht Nachsehen Frequent WBI Lehre Google News Buecher kaufen Projekte Paper suchen Reisen MyStuff hub Berlin Wetter
Mathematisch-Naturwissenschaftliche Fakultät
Institut für Informatik
Wissensmanagement in der Bioinformatik
Kontakt
Mitarbeiter
Veranstaltungen
Lehre
Archiv
WS 14/15
Modul Data Warehousing und Data Mining
Modul Information Retrieval
Übung zu Information Retrieval
Seminar Infrastrukturen für BIG DATA Anwendungen
Forschungsseminar
SS14
WS 13/14
SS13
WS 12/13
SS12
WS 11/12
SS 11
WS 10/11
SS 10
WS 09/10
SS 09
WS 08/09
SS 08
WS 07/08
SS 07
WS 06/07
SS 06
WS 05/06
SS 05
WS 04/05
SS 04
WS 03/04
SS 03
WS 02/03
WBI
HUMBOLDT-UNIVERSITÄT ZU BERLIN
Deutsch English Kontakt/Impressum
Humboldt-Universität zu Berlin | Mathematisch-Naturwissenschaftliche Fakultät | Institut für Informatik | Wissensmanagement in der Bioinformatik | Lehre | Archiv | WS 14/15 | Modul Information Retrieval
Website durchsuchen
Information Retrieval
Professor Dr. Ulf Leser
Das Modul "Information Retrieval" behandelt Methoden zur Suche in (sehr grossen) Textsammlungen, insbesondere im Web. Vorgestellt werden Algorithmen und Verfahren zur Textvorverarbeitung, Anfragesprachen, Relevanzmodelle, Idexierung, und spezielle Probleme bei Web-Suchmaschinen. Am Ende der Vorlesung werden auch kleinere Ausfüge in die Computergestützte Sprachverarbeitung unternommen (Language Models, Word Sense Disambiguation). Immer werden sowohl algorithmische Grundlagen als auch konkrete Anwendungen behandelt.
Die Vorlesung wird durch eine Übung begleitet. Diese vertieft die gelernten Methoden durch praktische Umsetzung. In Gruppen werden verschiedene Probleme des Information Retrieval, teilweise unter Benutzung existierende Frameworks, gelöst.
Voraussetzungen
Voraussetzung für den Besuch sind gute Kenntnisse in "Algorithmen und Datenstrukturen" und der Programmierung mit Java.
Prüfungen
Prüfungen sind mündlich.
Anrechnung
Das Modul (Vorlesung + Übung) kann angerechnet werden für
Bachelor Informatik, 5 SP
Bachelor INFOMIT, 5 SP
Literatur zur Vorlesung
Schütze, Manning, Raghavan: "Introduction to Information Retrieval", MIT Press, 2009 (Komplette Onlineversion
Weitere Literatur und Links
Themen und Termine im Einzelnen
Folien sind hier jeweils nach der Vorlesung als PDF verfügbar. Änderungen möglich. All slides are English, but the course will be held in German.
Overview
Introduction to Information Retrieval
Evaluation of IR Systems; document normalization
IR Models I: Boolean, Vector Space, Relevance Feedback
IR Models II: Probabilistic Retrieval, Latent Semantic Indexing
Exact online substring search: Z-Box, Boyer-Moore
Indexing terms: Inverted files
Humboldt-Universität Informatik

Topics we Shall Discuss

- Evaluating IR systems
- Relevance models: Semantics of queries (IR model)
- User feedback (relevance feedback)
- Searching strings (exact, token-based, substring, ...)
- Building efficient search indexes
- Search on the web / PageRank
- Language models
- Word colocations

Related Topics we shall not Discuss

- Information Extraction, Named Entity Recognition
- Entity Search
- Personalized, social-media based, local, mobile, ... search
- Search Engine Optimization
- Detecting similar texts (plagiarism)
- Computational Linguistics
- Text classification
- Text clustering

- See lecture „Computational Natural Language Processing“
  - Maschinelle Sprachverarbeitung

Exercises

- We will form teams
- Five exercises, all must be passed
  - IMDB crawler
  - Boolean Information Retrieval the hard way
  - Information Retrieval with Lucene
  - Synonym expansion with Lucene and Wordnet
  - Significant co-occurrences
- There will be a competition
- First exercise: 23.4.2018

Questions

- Diplominformatiker?
- Bachelor?
- Semester?

- Special expectations, experiences, questions?

Feedback 2016/2017

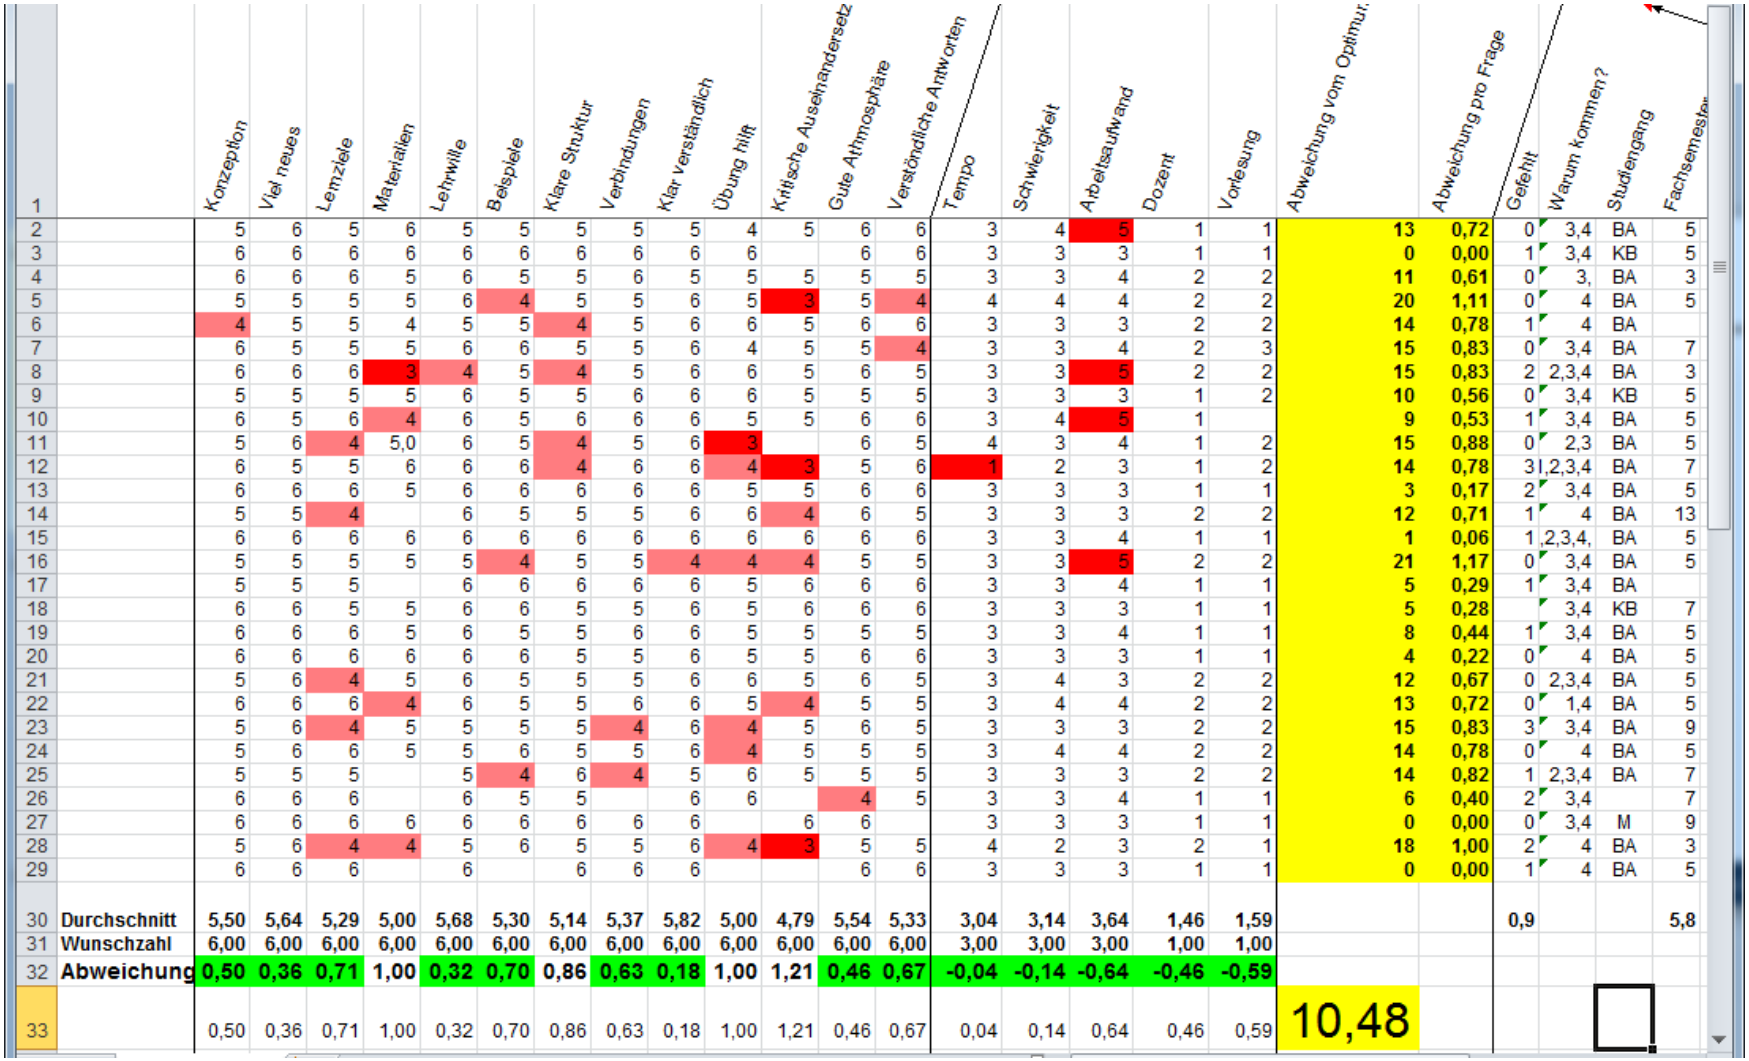

		Konzeption	Viel neues	Lernziele	Materialien	Lehrwille	Beispiele	Klare Struktur	Verbindungen	Klar verständlich	Übung hilft	Kritische Auseinandersetz	Gute Athmosphäre	Verständliche Antworten	Tempo	Schwierigkeit	Arbeitsaufwand	Dozent	Vorlesung	Abweichung vom Optimur.	Abweichung pro Frage	Gefehlt	Warum kommen?	Studiengang	Fachsemester
2		5	6	5	6	5	5	5	5	5	4	5	6	6	3	4	5	1	1	13	0,72	0	3,4	BA	5
3		6	6	6	6	6	6	6	6	6	6		6	6	3	3	3	1	1	0	0,00	1	3,4	KB	5
4		6	6	6	5	6	5	5	6	5	5	5	5	5	3	3	4	2	2	11	0,61	0	3,	BA	3
5		5	5	5	5	6	4	5	5	6	5	3	5	4	4	4	4	2	2	20	1,11	0	4	BA	5
6		4	5	5	4	5	5	4	5	6	6	5	6	6	3	3	3	2	2	14	0,78	1	4	BA	
7		6	5	5	5	6	6	5	5	6	4	5	5	4	3	3	4	2	3	15	0,83	0	3,4	BA	7
8		6	6	6	3	4	5	4	5	6	6	5	6	5	3	3	5	2	2	15	0,83	2	2,3,4	BA	3
9		5	5	5	5	6	5	5	6	6	6	5	5	5	3	3	3	1	2	10	0,56	0	3,4	KB	5
10		6	5	6	4	6	5	6	6	6	5	5	6	6	3	4	5	1		9	0,53	1	3,4	BA	5
11		5	6	4	5,0	6	5	4	5	6	3		6	5	4	3	4	1	2	15	0,88	0	2,3	BA	5
12		6	5	5	6	6	6	4	6	6	4	3	5	6	1	2	3	1	2	14	0,78	3	1,2,3,4	BA	7
13		6	6	6	5	6	6	6	6	6	5	5	6	6	3	3	3	1	1	3	0,17	2	3,4	BA	5
14		5	5	4		6	5	5	5	6	6	4	6	5	3	3	3	2	2	12	0,71	1	4	BA	13
15		6	6	6	6	6	6	6	6	6	6	6	6	6	3	3	4	1	1	1	0,06	1	1,2,3,4,	BA	5
16		5	5	5	5	5	4	5	5	4	4	4	5	5	3	3	5	2	2	21	1,17	0	3,4	BA	5
17		5	5	5		6	6	6	6	6	5	6	6	6	3	3	4	1	1	5	0,29	1	3,4	BA	
18		6	6	5	5	6	6	5	5	6	5	6	6	6	3	3	3	1	1	5	0,28		3,4	KB	7
19		6	6	6	5	6	5	5	6	6	5	5	5	5	3	3	4	1	1	8	0,44	1	3,4	BA	5
20		6	6	6	6	6	6	5	5	6	5	5	6	6	3	3	3	1	1	4	0,22	0	4	BA	5
21		5	6	4	5	6	5	5	5	6	6	5	6	5	3	4	3	2	2	12	0,67	0	2,3,4	BA	5
22		6	6	6	4	6	5	5	6	6	5	4	5	5	3	4	4	2	2	13	0,72	0	1,4	BA	5
23		5	6	4	5	5	5	5	4	6	4	5	6	5	3	3	3	2	2	15	0,83	3	3,4	BA	9
24		5	6	6	5	5	6	5	5	6	4	5	5	5	3	4	4	2	2	14	0,78	0	4	BA	5
25		5	5	5		5	4	6	4	5	6	5	5	5	3	3	3	2	2	14	0,82	1	2,3,4	BA	7
26		6	6	6		6	5	5		6	6		4	5	3	3	4	1	1	6	0,40	2	3,4		7
27		6	6	6	6	6	6	6	6	6		6	6		3	3	3	1	1	0	0,00	0	3,4	M	9
28		5	6	4	4	5	6	5	5	6	4	3	5	5	4	2	3	2	1	18	1,00	2	4	BA	3
29		6	6	6		6		6	6	6			6	6	3	3	3	1	1	0	0,00	1	4	BA	5
30	**Durchschnitt**	**5,50**	**5,64**	**5,29**	**5,00**	**5,68**	**5,30**	**5,14**	**5,37**	**5,82**	**5,00**	**4,79**	**5,54**	**5,33**	**3,04**	**3,14**	**3,64**	**1,46**	**1,59**			**0,9**			**5,8**
31	**Wunschzahl**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**6,00**	**3,00**	**3,00**	**3,00**	**1,00**	**1,00**						
32	**Abweichung**	**0,50**	**0,36**	**0,71**	**1,00**	**0,32**	**0,70**	**0,86**	**0,63**	**0,18**	**1,00**	**1,21**	**0,46**	**0,67**	**-0,04**	**-0,14**	**-0,64**	**-0,46**	**-0,59**						
33		0,50	0,36	0,71	1,00	0,32	0,70	0,86	0,63	0,18	1,00	1,21	0,46	0,67	0,04	0,14	0,64	0,46	0,59	10,48					

Free Text Feedback – Room for Improvement

- Nicht so gut
  - Auf Folien mit vielen Variablen deren Bedeutung irgendwo angeben
  - Folien Englisch, Sprache Deutsch
  - Ich kann Google nicht mehr benutzen (?)
  - Fehler in Folien (aber korrigiert)
  - Verbindung VL - UE nur schwach ausgeprägt (aber Übung ist gut)
- Zu wenig
  - Aktuelle IR Forschung
- Zu viel
  - Zu viel Politik, Zeit fehlte später
  - 4 Aufwand für Übungen
  - Zu viel biomedizinische Beispiele
- Weitere Anregungen
  - Themenreihenfolge unklar
  - 2 Auf 4SWS ausbauen

Beyond Information Retrieval

Entities

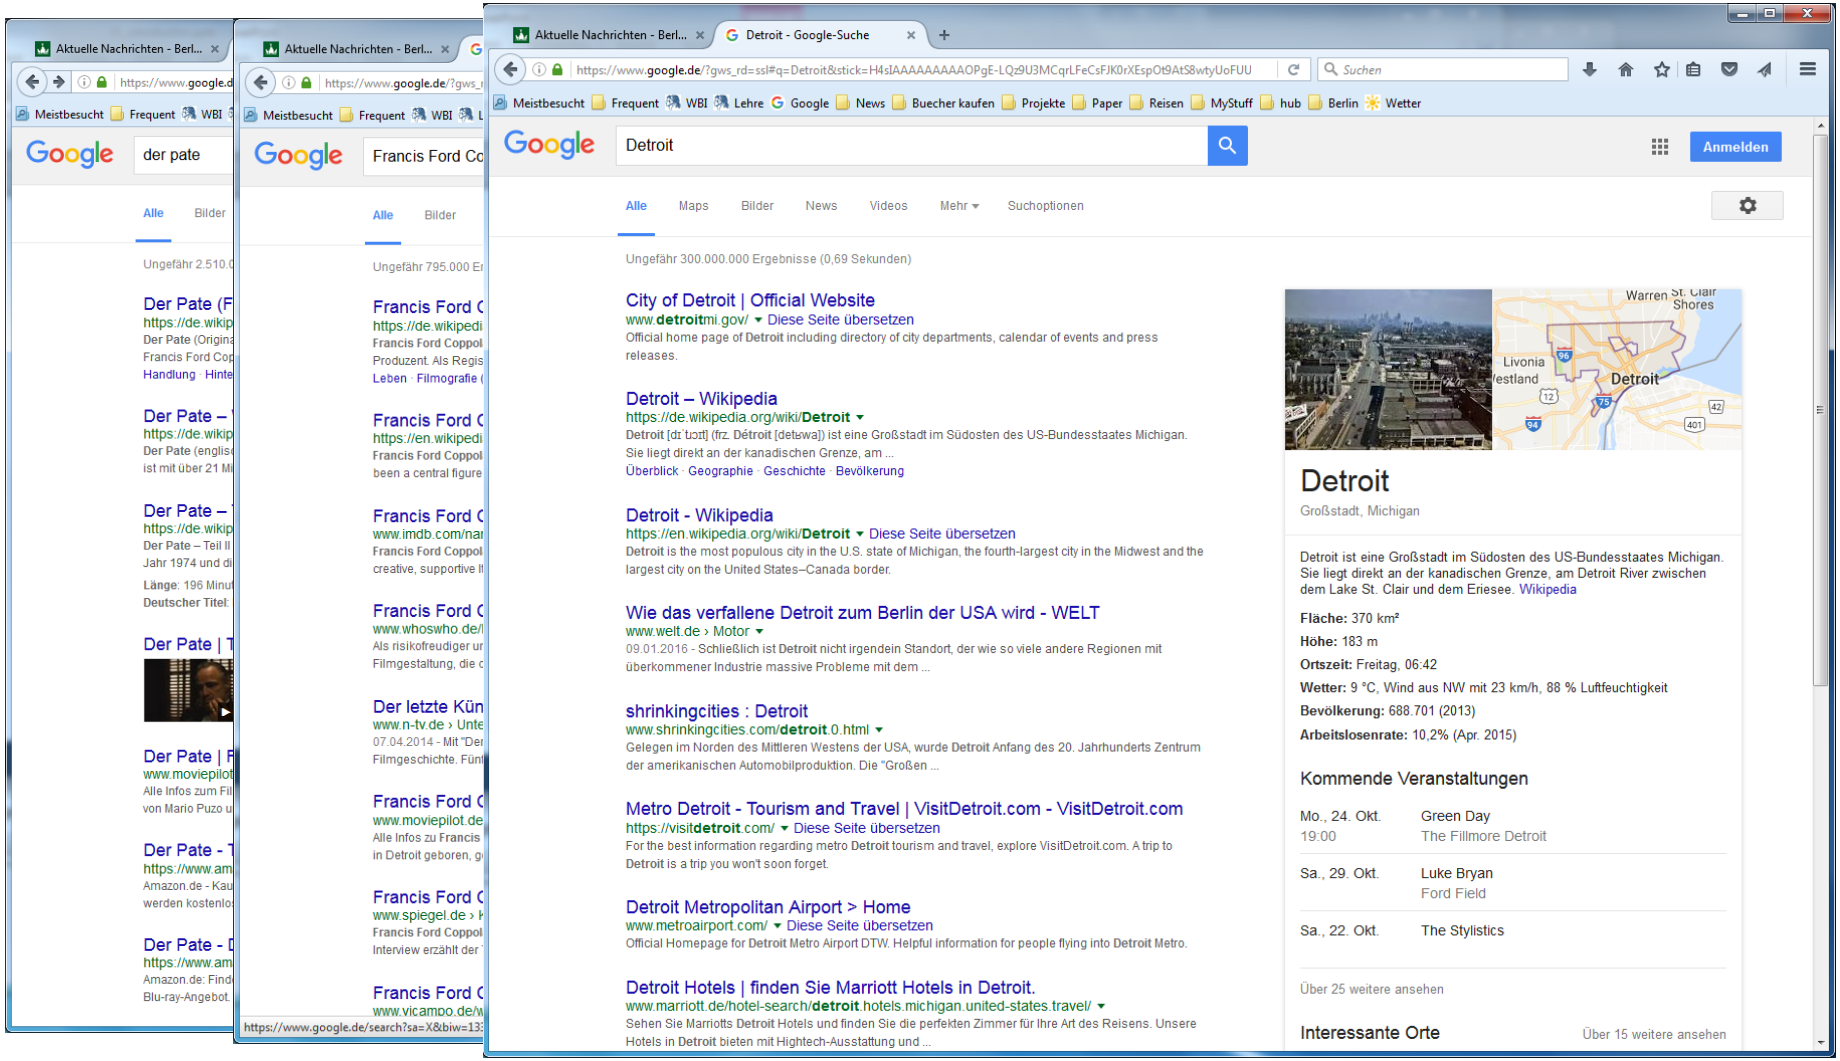
Aktuelle Nachrichten - Berl...
Detroit - Google-Suche
Google
Detroit
Anmelden
Alle
Maps
Bilder
News
Videos
Mehr
Suchoptionen
Ungefähr 300.000.000 Ergebnisse (0,69 Sekunden)
City of Detroit | Official Website
www.detroitmi.gov/ Diese Seite übersetzen
Official home page of Detroit including directory of city departments, calendar of events and press releases.
Detroit – Wikipedia
https://de.wikipedia.org/wiki/Detroit
Detroit [dɪˈtɔɪt] (frz. Détroit [detʁwa]) ist eine Großstadt im Südosten des US-Bundesstaates Michigan. Sie liegt direkt an der kanadischen Grenze, am ...
Überblick · Geographie · Geschichte · Bevölkerung
Detroit - Wikipedia
https://en.wikipedia.org/wiki/Detroit Diese Seite übersetzen
Detroit is the most populous city in the U.S. state of Michigan, the fourth-largest city in the Midwest and the largest city on the United States–Canada border.
Wie das verfallene Detroit zum Berlin der USA wird - WELT
www.welt.de › Motor
09.01.2016 - Schließlich ist Detroit nicht irgendein Standort, der wie so viele andere Regionen mit überkommener Industrie massive Probleme mit dem ...
shrinkingcities : Detroit
www.shrinkingcities.com/detroit.0.html
Gelegen im Norden des Mittleren Westens der USA, wurde Detroit Anfang des 20. Jahrhunderts Zentrum der amerikanischen Automobilproduktion. Die "Großen ...
Metro Detroit - Tourism and Travel | VisitDetroit.com - VisitDetroit.com
https://visitdetroit.com/ Diese Seite übersetzen
For the best information regarding metro Detroit tourism and travel, explore VisitDetroit.com. A trip to Detroit is a trip you won't soon forget.
Detroit Metropolitan Airport > Home
www.metroairport.com/ Diese Seite übersetzen
Official Homepage for Detroit Metro Airport DTW. Helpful information for people flying into Detroit Metro.
Detroit Hotels | finden Sie Marriott Hotels in Detroit.
www.marriott.de/hotel-search/detroit.hotels.michigan.united-states.travel/
Sehen Sie Marriotts Detroit Hotels und finden Sie die perfekten Zimmer für Ihre Art des Reisens. Unsere Hotels in Detroit bieten mit Hightech-Ausstattung und ...
Detroit
Großstadt, Michigan
Detroit ist eine Großstadt im Südosten des US-Bundesstaates Michigan. Sie liegt direkt an der kanadischen Grenze, am Detroit River zwischen dem Lake St. Clair und dem Eriesee. Wikipedia
Fläche: 370 km²
Höhe: 183 m
Ortszeit: Freitag, 06:42
Wetter: 9 °C, Wind aus NW mit 23 km/h, 88 % Luftfeuchtigkeit
Bevölkerung: 688.701 (2013)
Arbeitslosenrate: 10,2% (Apr. 2015)
Kommende Veranstaltungen
Mo., 24. Okt. 19:00 Green Day The Fillmore Detroit
Sa., 29. Okt. Luke Bryan Ford Field
Sa., 22. Okt. The Stylistics
Über 25 weitere ansehen
Interessante Orte
Über 15 weitere ansehen

Entity Search

- Very often people search information about an entity
  - Location, person, movie, product, football player, pop singer, ...
- Entity search
  - Detect entities in text and build a structured knowledge base
    - Despite homonyms, synonyms, colocations, abbreviations, spelling variants and spelling mistakes ...)
    - Extract related facts (Wikipedia, Freebase, ...)
    - Person age, address, spouse, income, place of birth, ...
  - Detect entities in queries
  - Answer with extracted data (not “just” a page page)
- Which entities?
  - Today: Wikipedia

Applications in Business

- Given an incoming complaint mail: Which product (line) is affected?
  - Recognize and normalize product; forward mail or link to FAQ
- Given twitter etc.: What problems are most frequently reported by our customers?
  - Recognize and normalize “problems”; assign to product (lines)
- Improved customer self service
  - Entity Search for product and problem
  - Precise routing and prioritization of requests

WBI Research in Text Mining

- Entity recognition and search in biomedical texts
  - Genes, diseases, mutations, species, drugs, ...
- Relationships: Gene regulation, protein-protein-interaction, disease-drug-mutation ...
- Text classification: Molecular ... cancer ... colon ...
- Table similarity search
- We mostly work on scientific literature
  - But also web crawls, patent search, ...

High-Accuracy BTM: GeneView
(Thomas et al., 2012)

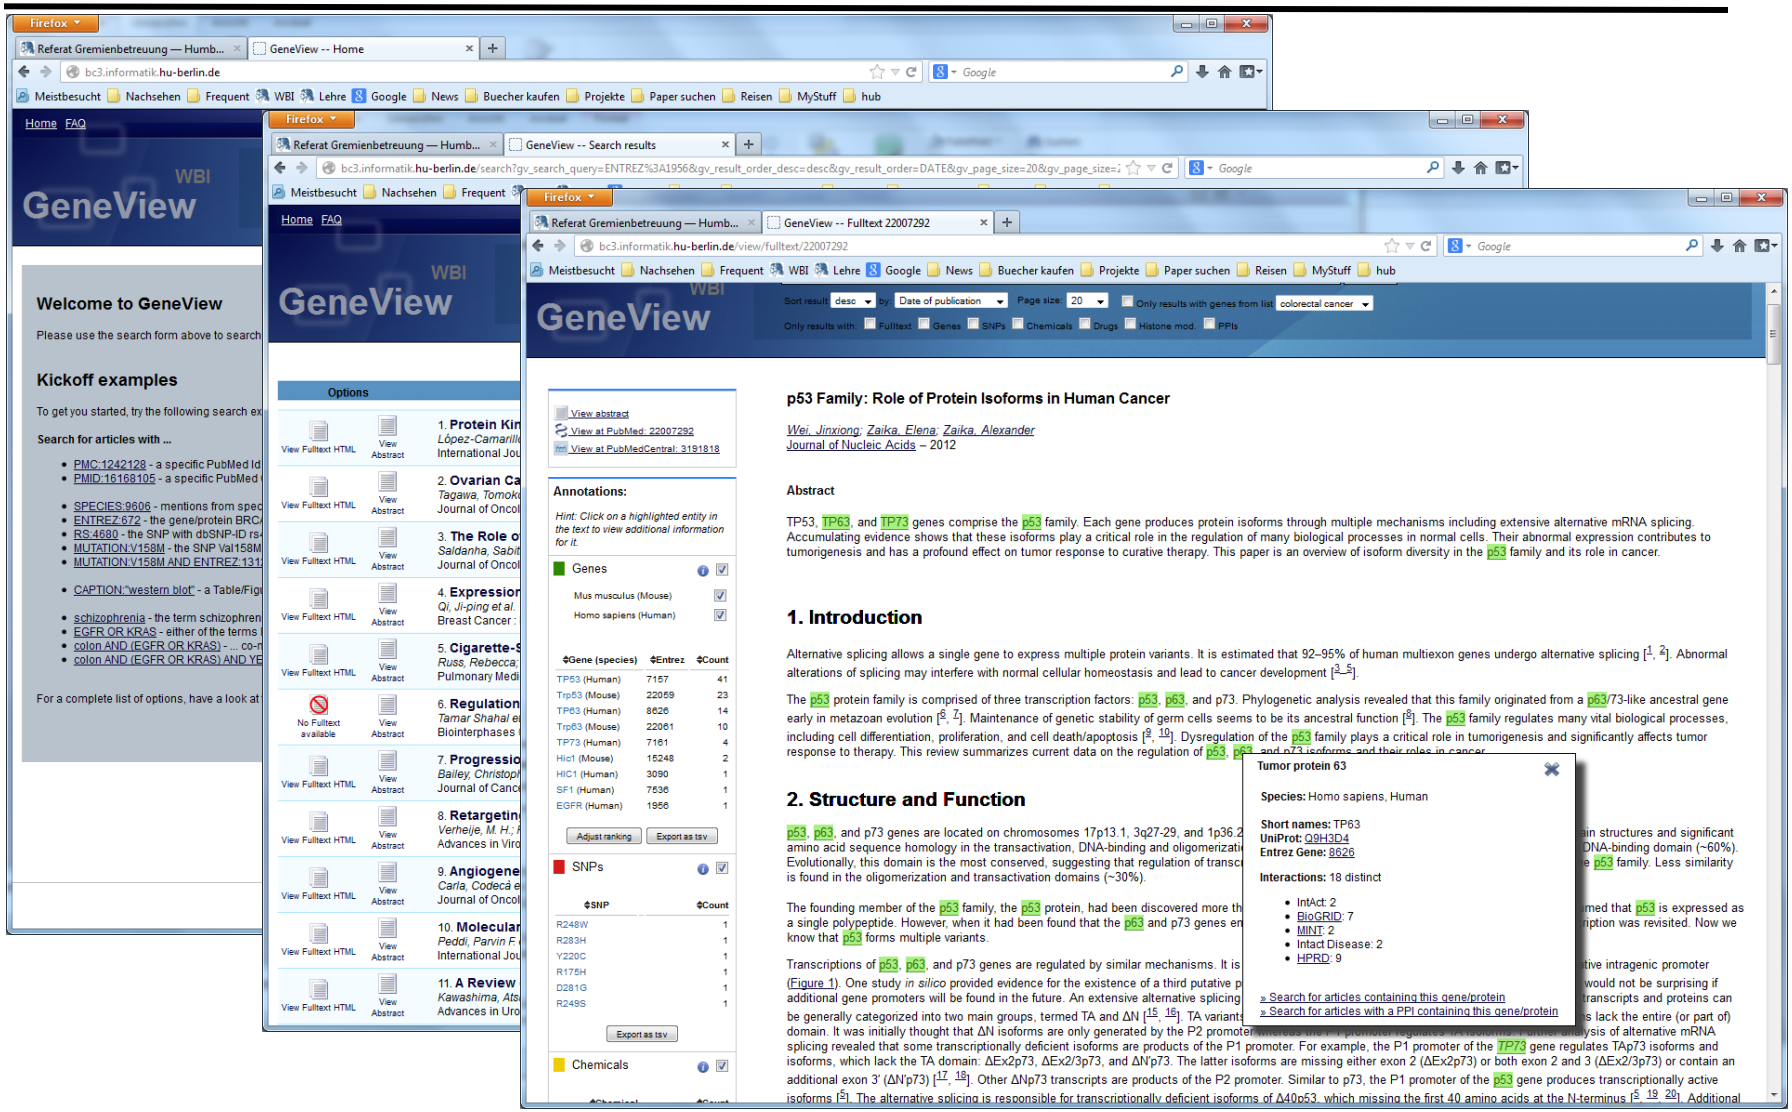

Detecting Gene Names

The human T cell leukemia lymphotropic virus type 1 Tax protein represses MyoD-dependent transcription by inhibiting MyoD-binding to the KIX domain of p300.

Detecting Gene Names

The human T cell leukemia lymphotropic virus type 1 Tax protein represses MyoD-dependent transcription by inhibiting MyoD-binding to the KIX domain of p300.

- Typical problems
  - Multi-token entities with ill-defined boundaries
  - Abbreviations
  - Synonyms, homonyms, polysemy
  - Irregular spelling, naming variations
  - ...

Beyond Entities: Understanding Text is Difficult (even for us)

„The PAX1 protein represses MyoD-dependent transcription by inhibiting MyoD-binding to the KIX domain of p300.“

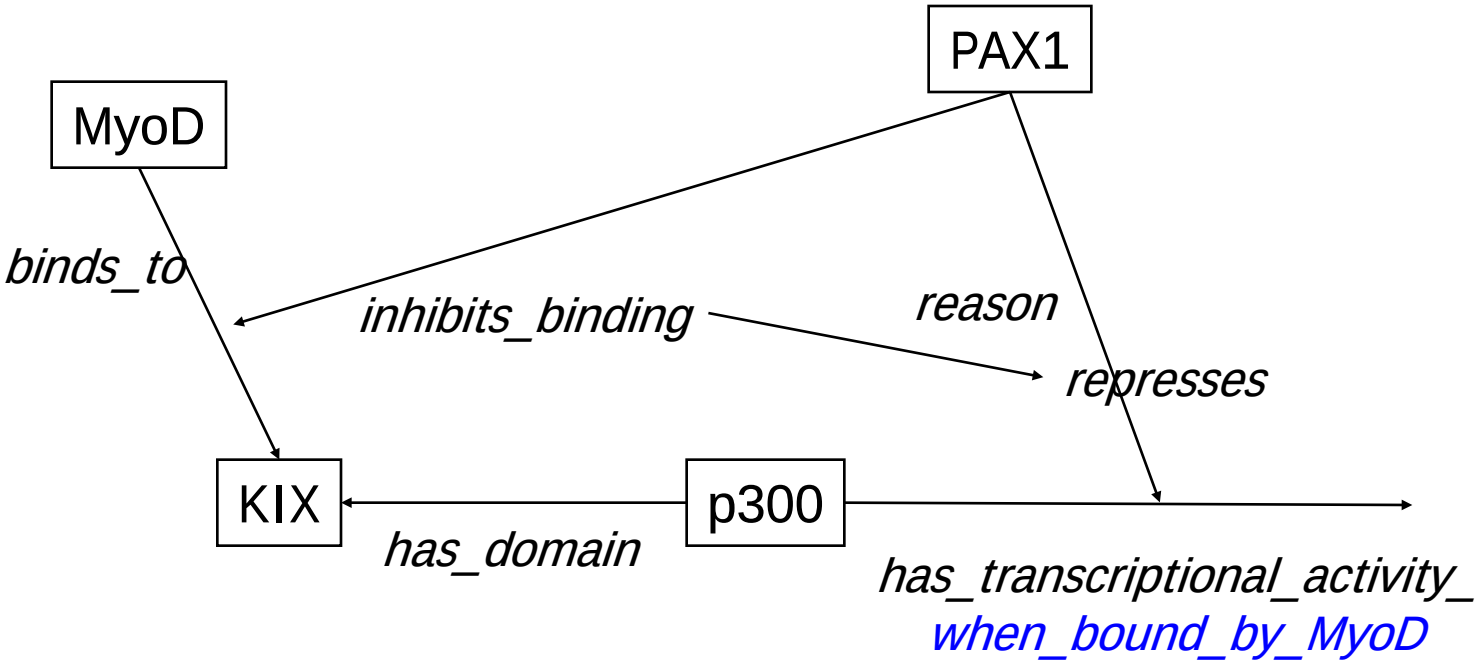

Biomedical Web

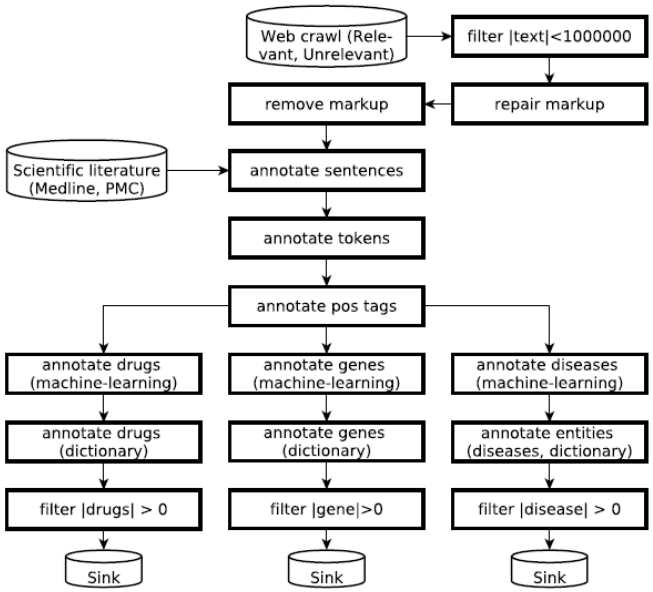

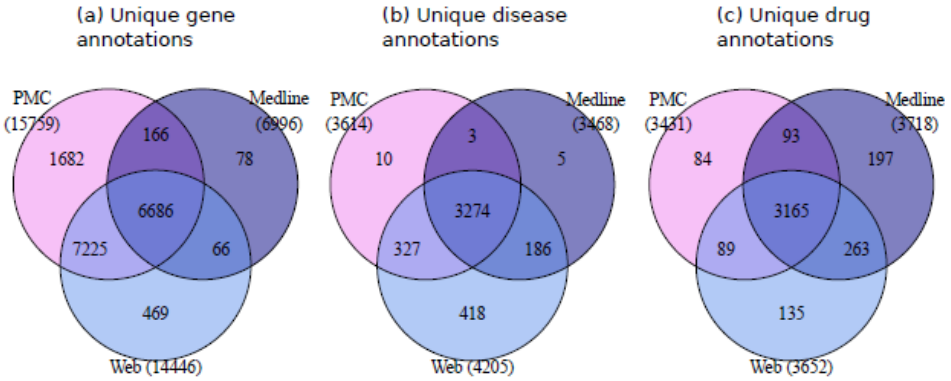

rank	Drug ID, Drug name	#PMC	#Web	Log_2Fold	Indication
1	DB01619 Nolahist D27.505.519.625.375.425.400	0	143	-Inf	allergies and the common cold
2	D05.750.716.579.159 Cuemid D27.505.519.186.071.202	0	86	-Inf	hypercholesterolemia
3	DB00237 Butalan D27.505.954.427.210.350	0	59	-Inf	insomnia, anxiety disorders
4	D04.615.181.384.535 D27.505.954.427.700.122.055 Pamelor (Nortriptyline)	3	214	-6.52	depression, chronic pain, ...
5	D03.066.515.530 D27.505.696.377.605.600.708 Nicobion	1	65	-6.38	Nicotinamid deficiency (vitamin)
6	D03.383.129.308.207 Krebiozen (Creatine)	1	61	-6.29	nutritional supplementation
7	DB00729 Prantal	1	53	-6.09	peptic ulcer, gastric hyperacidity, hyperhidrosis
8	DB01178 Chlormezanon D27.505.954.427.210.950.015	40	1838	-5.88	anxiety, muscle spasm
9	D03.383.097.217.900 D27.505.519.124.035 Triaziquone	2	82	-5.72	chemotherapy
10	DB00241 Butalbital	3	119	-5.67	headaches, migraines, and pain
11	DB00653 Bitter salt D27.505.696.663.850.014	11	395	-5.53	magnesium deficiency, acute nephritis in children, ...

rank	Drug ID, Drug name	#PMC	#Web	Log_2Fold	Indication
1	D03.132.760.864 D27.505.954.122.136 Tomatine	64	2	4.64	fluorescein photoactive dye
2	D04.615.885.347.300 Phloxin-B	50	2	4.28	red-colored dye
3	D04.345.891.900 Trichodermin	49	2	4.25	acts as an antifungal and protein synthesis inhibitor
4	D04.345.891.870 Fusariotoxin	90	5	3.81	trichothecene mycotoxin
5	DB02859 Soraphen A	57	4	3.47	inhibitor of acetyl CoA carboxylase activity
6	D03.383.129.708.867 Thiadiazoles	109	9	3.24	oxidation inhibitors, cyanine dyes, metal chelating agents
7	DB02929 K201	441	39	3.14	anti-arrhythmic potential
8	D03.383.533 Oxazines	70	8	2.77	heterocyclic compounds (used as fluorescent dyes)
9	D05.750.716.822.300 Bone Cement	83	11	2.55	anchor artificial joints
10	D05.500.249.600 Phycobilisomes	83	11	2.55	light harvesting antennae from e.g. algae (used as fluorescent dyes)
11	DB00503 ABT-538	86	12	2.48	HIV