



*The Tower of Babel*

Pieter Bruegel the Elder (about 1525 - 1569)

---

# Automatische Verarbeitung medizinischer Sprache

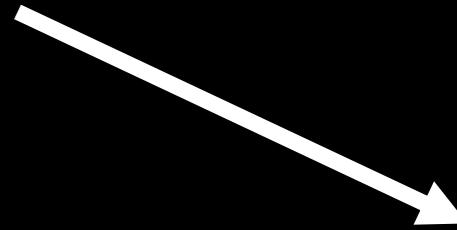
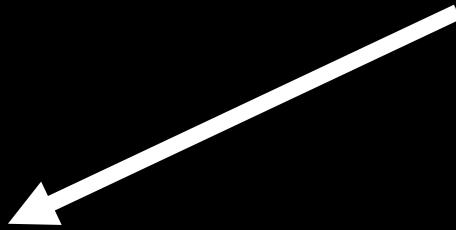
Stefan Schulz

Abteilung Medizinische Informatik

Universitätsklinikum Freiburg

---

Medizinische  
Inhalte



**Natürliche  
Sprache**

**Strukturierte  
Daten**



**Natürliche  
Sprache**

Datum	Uhrz.	Pflegebericht – Verlaufsbeschreibung Krankenbeobachtung	Hz.
21.4.	13 <sup>30</sup>	Pat. kam mit einer Harninfektion, hat keine Schmerzen, was schon zur Toilette und hat sich selbstständig gewaschen	SH
22.4.	5 <sup>30</sup>	Pat. hat in d. Nacht kein Wasser geurteilt, sie gab aber <del>ein</del> Beruhigungsmittel an	SH
22.4.	14 <sup>00</sup>	Pat. lt. Pflegeplan versorgt	SH
	21 <sup>00</sup>	Pat. lt. Plan versorgt; ist nach Betastung schmerzlos	SH
23.4.	8 <sup>00</sup>	Pat. saß fast die ganze Nacht im Bett und konnte nicht im Liegen schlafen	SH
	12 <sup>00</sup>	Pat. hatte 3x Breiig bis dünnflüssigen Stuhlgang (braun)	SH
	14 <sup>00</sup>	Versorgg. lt. Plan	SH
	21 <sup>00</sup>	Pat. lt. Plan versorgt, hält sich nicht an ihre Bettruhe	SH
24.4.	2 <sup>30</sup>	Pat. beim Toilettengang erwacht, hält sich nicht an Bettruhe (sieht herein zum Mann)	SH
25	3 <sup>30</sup>	Pat. wachte aus dem Lärmemittelschlaf	SH

### **Familienanamnese:**

Vater verstorben an Bronchial-Karzinom, Mutter verstorben an den Folgen einer Pneumonie. Mutter Diabetes mellitus. 5 gesunde Kinder.

### **Systemanamnese:**

Derzeit Appetitlosigkeit, Trockengewicht um 75 Kg, derzeit 80 Kg. Miktio: gelegentlich Harn-verhalt, gehäuft Harnwegsinfekte, derzeit keine Algurie. Vor Dialyse keine Rest-Diurese. Stuhlgang obstipiert, benutzt regelmäßig Abführmittel. Vor NTX starker Juckreiz, Seit NTX deutlich rückläufig. Kein Husten/Auswurf. Noxen: Nichtraucherin, kein Alkohol.

### **Soziale Anamnese:**

Früher Arbeiterin in der Elektronikbranche, dann Hausfrau, verheiratet, lebt mit dem Ehemann zusammen.

Allergien. Keine bekannt.

### **Medikation bei Aufnahme:**

Ulcogant 1-1-1, Pepdul mit 0-0-0-1, Cellcept 2x1 g, Bayotensin 3 x 1, Cynt 0,2 1x1, Ludiomil 50 mg 1 x 1, Sandimmun 2 x 150 mg, Clexane 0,4 ml 1 x täglich s.c.

### **Status bei Übernahme:**

58-jährige Patientin in vorgealtertem, reduziertem Allgemein- und adipösem Ernährungszu-stand (80 Kg Gewicht bei 160 cm Körpergröße). RR 170/80 mm Hg, Puls 66/Minute, regelmäßig. Punktförmige Depigmentierungen an beiden Unterarmen bei Zustand nach heftigem Kratzen wegen Juckreiz. Keine zervikalen Lymphome. Mundschleimhaut trocken, Zunge weißlich belegt. Rachenschleimhaut reizlos, Tonsillen schlecht einsehbar. Schilddrüse nicht vergrößert. Pulmo: Sonorer Klopfeschall und vesikuläres Atemgeräusch. Cor: Spitzenstoß nicht tastbar, leise, reine Herztöne. 3/6. spindelförmiges Systolikum und 1-2/6. Decrescendo-Sofort-dialstolikum über der Aorta mit Fortleitung in die Karotis. Kein abdominales und inguinales Strömungsgeräusch. Abdomen: Bei Adipositas Organgrenzen schlecht beurteilbar, Leber/Milz nicht vergrößert. Reizlose Narbe im Bereich des rechten Unterbauches bei Zustand nach NTX. Dort leichte Druckdolenz.

Wirbelsäule nicht klopfeschmerzhaft. Bds. Unterschenkelödeme. Feinschlägiger Tremor beim Arm-Vorhalte-Versuch. Pupillen isokor, Lichtreaktion prompt. Finger-Nase-Versuch bds. unsicher, ataktisch. Reflexe seitengleich.

---

# Burden of infectious diseases in South Asia

Anita K M Zaidi, Shally Awasthi, H Janaka deSilva

Infectious diseases are a major cause of death in South Asia, with children incurring a disproportionate share of the burden. This review discusses the underlying causes of some of the more common diseases and strategies to improve their detection and control

Preventable infections are a major cause of deaths and disabilities in South Asia. Over two thirds of the estimated 3.7 million deaths in children in South Asia in the year 2000 were attributable to infections such as pneumonia, diarrhoea, and measles.<sup>1-2</sup> India now has the second largest population with AIDS and HIV infection in the world, and tuberculosis and chronic hepatitis continue to threaten the lives of millions. Of the overall burden of deaths related to infectious disease in the region, around 63% are in children aged under 5 years.<sup>3</sup> Serious effort should be devoted to the control of infectious disease if South Asian countries are to meet their millennium development goal of two thirds reduction in child mortality by 2015.

Sri Lanka alone among South Asian countries has made remarkable progress in reducing the burden of infectious disease, despite civil war and meagre resources.

This review describes the burden of infectious

## Summary points

Acute respiratory infections, diarrhoea, and neonatal infections remain major child killers

India has the second highest burden of HIV and AIDS in the world, with 4.58 million people infected with HIV

Antibiotic misuse has resulted in high rates of antimicrobial resistance

Only half of all South Asian children receive routine immunisations, and many new vaccines have not been introduced in mass immunisation programmes

Lack of surveillance systems and poorly

NetDoktor.de

Startseite

Aktuell

Nachrichten

Features

Newsletter

Lexikon

Krankheiten

Symptome

Untersuchungen

Eingriffe

Laborwerte

Medikamente

Themen

Allergie

Asthma

Diabetes

Erektile  
Dysfunktion

Herz

Reizdarm

Rheuma

Transplantation

Verhütung

Alle Themen

Service

Teste Dich Selbst

## Diabetes mellitus Typ-1 (Zuckerkrankheit)

Anzeige

[Dr. med. Ingo Röhrig](#), Facharzt für Innere Medizin, Angiologie,  
Diabetologie

### Was ist Diabetes Typ-1?

[Diabetes mellitus](#) ist ein Überbegriff für verschiedene Stoffwechselkrankheiten. Die Gemeinsamkeit ist, dass sie zu erhöhten Blutzuckerwerten führen. In Deutschland leben rund sechs Millionen Diabetiker - davon sind etwa 200.000 Menschen Typ-1-Diabetiker. Schätzungsweise 15.000 Menschen erkranken jährlich in Deutschland neu.



Typ-1 Diabetes: Lebenslang Insulin spritzen

Typ-1-Diabetes wird durch den absoluten Mangel am Hormon [Insulin](#) verursacht. Dieser Diabetestyp heißt deshalb auch insulinabhängiger Diabetes mellitus. Meistens beginnt die Erkrankung schon im Kindes- und Jugendalter, aber auch im fortgeschrittenen Alter kann sich Typ-1-Diabetes entwickeln. Die Krankheit ist derzeit noch nicht heilbar, lässt sich aber gut mit Insulin behandeln. Allerdings müssen die Patienten das lebenslange Spritzen von Insulin in Kauf nehmen. Für jeden Diabetiker ist es wichtig, den Blutzucker optimal einzustellen. Nicht nur, um akute Entgleisungen des Stoffwechsels wie eine [Unterzuckerung](#) zu verhindern, sondern auch um diabetische Folgeerkrankungen zu vermeiden oder hinauszuzögern.

# Natürliche Sprache

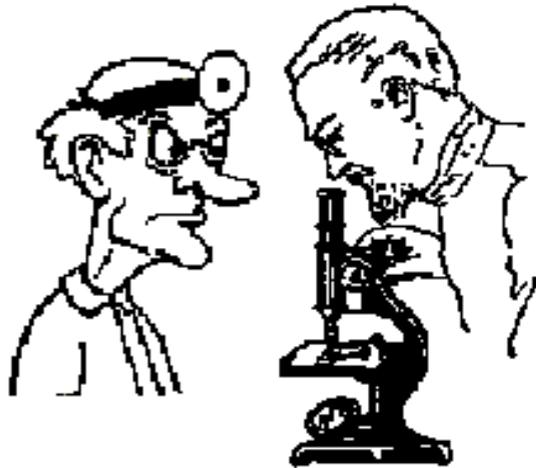


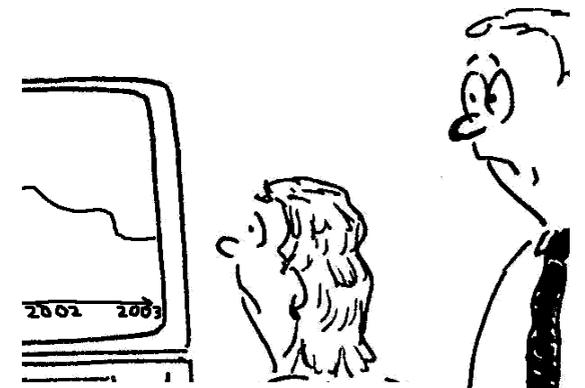
Illustration nach: www.fotografieren.de. Urheberrechte: Fotostudio.com

- ... unverzichtbar für
- Kommunikation zwischen Mitarbeitern des Gesundheitswesens
- Wissenschaftliche Kommunikation
- Klinische Dokumentation
- Wissenschaftliches Publikationswesen
- Vermittlung kanonischen Fachwissens an Fachleute, Studierende und Laien

## ...unverzichtbar für

- Kodierung von Diagnosen und Prozeduren, DRGs
- Klinische und epidemiologische Studien
- Gesundheitsberichterstattung
- Krankheitsspezifische Register
- Qualitätssicherung, Controlling
- Dokumentenindexierung und Retrieval
- etc.

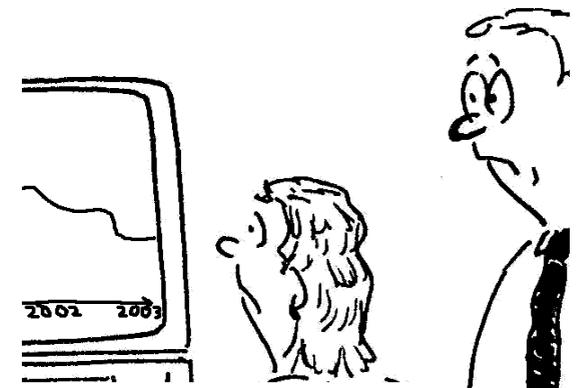
## Strukturierte Daten



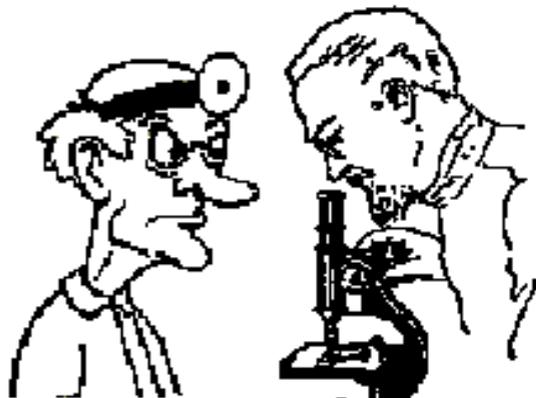
# ...erfordern medizinische Terminologiesysteme

- ICD
- OPS 301
- SNOMED
- LOINC
- MeSH
- etc., etc.

## Strukturierte Daten



# Natürliche Sprache



**Anamnese:**  
 Vater verstorben an Bronchial-Karzinom, Mütter verstorben an den Folgen einer Pneumonie, Mütter Diabetes mellitus, 5 gesunde Kinder.

**Systemanamnese:**  
 Derzeit Appetitlosigkeit, Trockengewicht um 75 Kg, derzeit 80 Kg. Miktio: gelegentlich Harn-verhalt, gehäuft Harnwegsinfekte, derzeit keine Algurie. Vor Dialyse keine Rest-Diurese. Stuhlgang obstipiert, benutzt regelmäßig Abführmittel. Vor NTX starker Juckreiz, Seit NTX deutlich rückläufig. Kein Husten/Auswurf. Noxen: Nichtraucherin, kein Alkohol.

**Soziale Anamnese:**  
 Früher Arbeiterin in der Elektronikbranche, dann Hausfrau, verheiratet, lebt mit dem Ehemann zusammen.

**Allergien:** Keine bekannt.

**Medikation bei Aufnahme:**  
 Uroogant 1-1-1, Peptid mit 0-0-0-1, Celcept 2x1 g, Bayolensin 3 x 1, Cynt 0.2 1x1, Ludomil 50 mg 1 x 1, Sandimmun 2 x 150 mg, Clexane 0.4 ml 1 x täglich s.c.

**Status bei Übernahme:**  
 58-jährige Patientin in vorgealtertem, reduziertem Allgemein- und adipösem Ernährungsstatus (80 Kg Gewicht bei 160 cm Körpergröße), RR 170/80 mm Hg, Puls 66/Minute, regelmäßig, punktförmige Depigmentierungen an beiden Unterarmen bei Zustand nach heftigem Kratzen wegen Juckreiz. Keine zervikalen Lymphome. Mundschleimhaut trocken, Zunge weißlich belegt, Rachenschleimhaut reizlos, Tonsillen schlecht einsehbar, Schilddrüse nicht vergrößert. Pulm: Sonorer Klopfeschall und vesikuläres Atemgeräusch, Cor: Spitzenstoß nicht tastbar, leise, reine Herzöne. 3/6 spindelförmiges Systolikum und 1-2/6. Decrescendo-Sofort-diastolikum über der Aorta mit Fortleitung in die Karotids. Kein abdominales und inguinales Strömungsgeräusch. Abdomen: Bei Adipositas Organgrenzen schlecht beurteilbar. Leber/Milz nicht vergrößert. Reizlose Narbe im Bereich des rechten Unterbauches bei Zustand nach NTX. Dort leichte Druckdolenz. Wirbelsäule nicht klopfmerthaft. Bds. Unterschenkelödeme. Feinschlägiger Tremor beim Arm-Vorhalte-Versuch. Pupillen isokor, Lichtreaktion prompt. Finger-Nase-Versuch bds. unsicher, ataktisch, Reflexe seitengleich.

# Strukturierte Daten



ICD 10 Codes	Cause of Death	Sex	Number of Deaths					Number of Deaths at age (In days)
			< 1 year	1-1	1-6	7-27	28-364	
	All causes	M	2495	160	703	416	1110	
		F	1005	130	440	279	1020	
		U	8	0	0	0	0	
A00-B99	Infectious and parasitic diseases	M	95	0	1	9	85	
		F	93	0	2	9	82	
A00-A09	Intestinal infectious diseases	M	65	0	0	6	59	
		F	63	0	0	6	57	
A37	Whooping cough	M	1	0	0	0	1	
		F	8	0	0	0	0	
E40-E64	Nutritional deficiencies	M	1	0	0	0	1	
		F	0	0	0	0	0	
G00-G08	Diseases of the nervous system	M	92	0	2	26	64	
		F	61	0	4	16	41	
G08_G09	Meningitis	M	37	0	2	18	17	
		F	30	0	4	12	14	
J00-J99	Diseases of the respiratory system	M	724	0	3	60	660	
		F	609	1	3	51	564	
J12-J18	Pneumonia	M	705	0	3	65	637	
		F	587	1	3	50	533	
J10-J11	Influenza	M	8	0	0	0	0	
		F	8	0	0	0	0	
Q00-Q99	Congenital anomalies	M	454	38	133	100	183	
		F	376	35	94	61	185	
Q01-Q05	Spina bifida and hydrocephalus	M	71	5	16	5	45	
		F	74	2	8	17	47	
Q20-Q28	Congenital anomalies of heart and circulatory system	M	222	8	67	67	90	
		F	149	9	42	23	75	
P00-P96	Certain conditions originating in the perinatal period	M	679	127	559	167	6	
		F	571	97	340	131	3	
P10-P15	Birth trauma	M	16	13	70	19	0	
		F	34	4	25	5	0	

*Schwerpunkt:  
Erfassung von Daten*

**Natürliche  
Sprache**

**Strukturierte  
Daten**



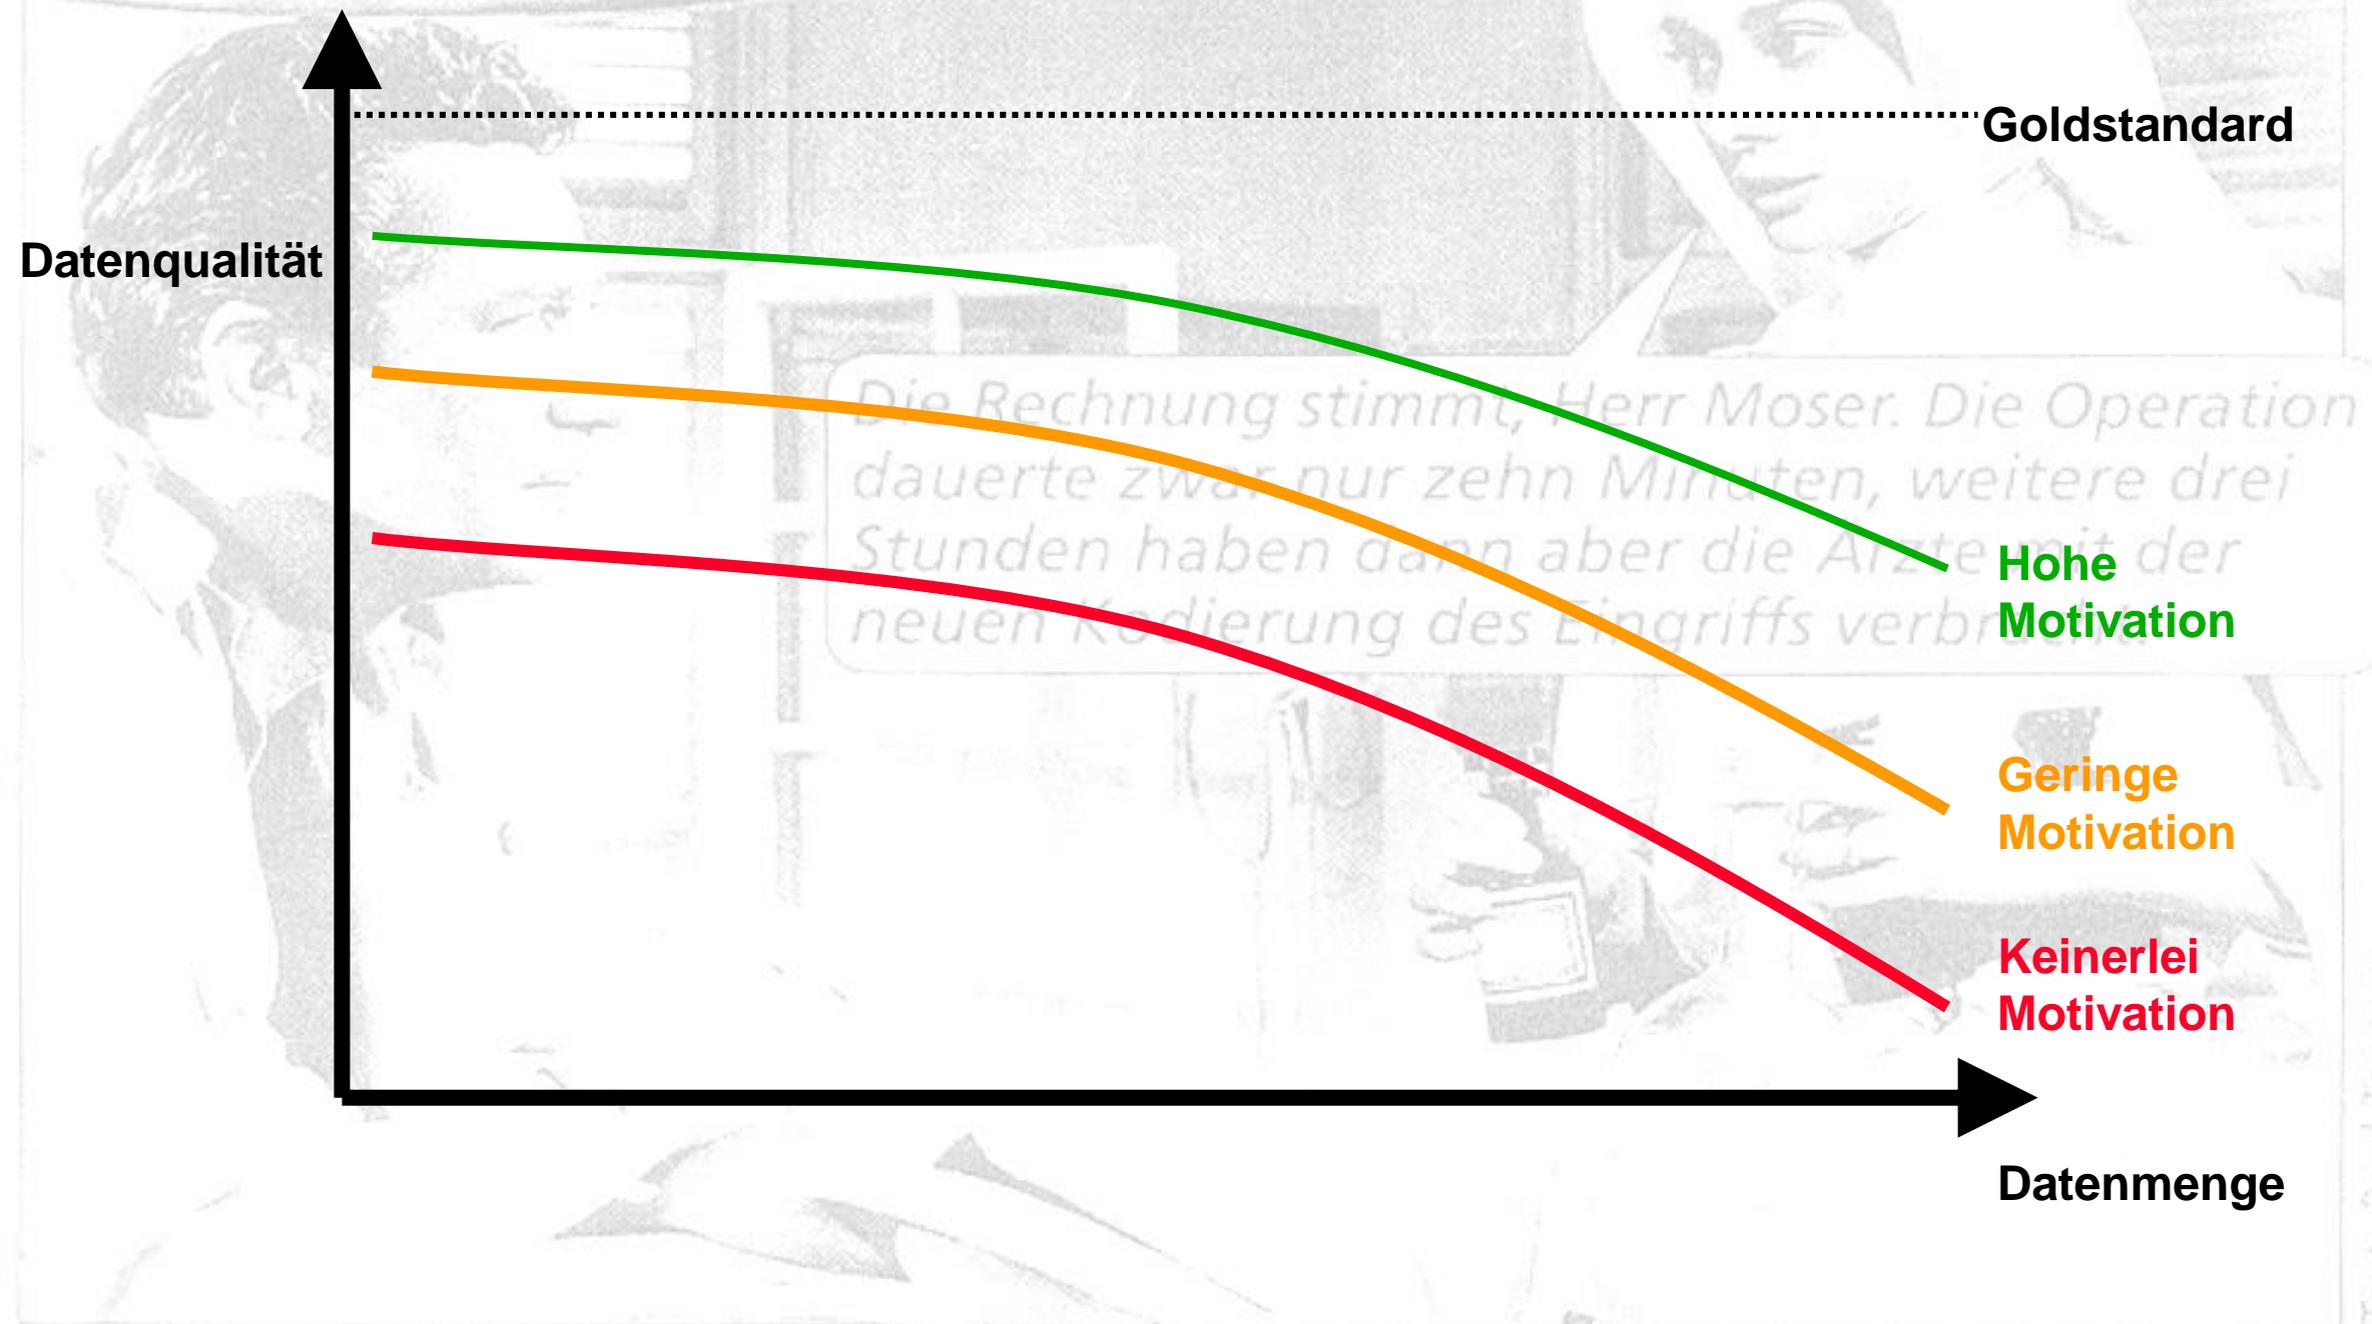
<b>+</b>	<b>Qualität</b>	<b>-</b>
<b>-</b>	<b>Kosten</b>	<b>+</b>





*Die Rechnung stimmt, Herr Moser. Die Operation dauerte zwar nur zehn Minuten, weitere drei Stunden haben dann aber die Ärzte mit der neuen Kodierung des Eingriffs verbracht.*

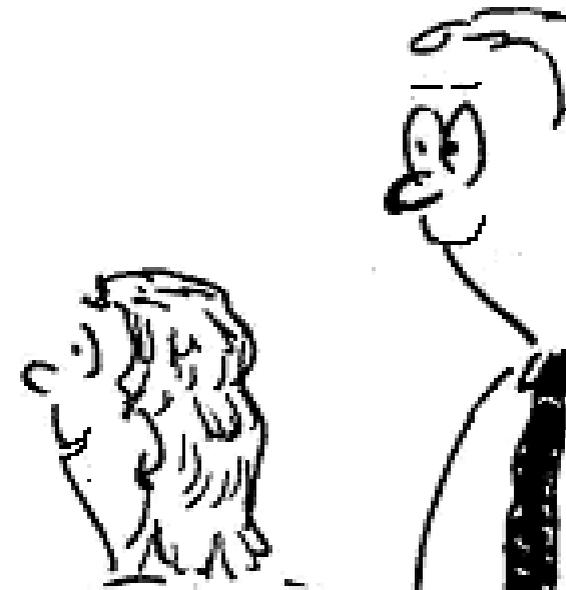
# Abhängigkeit: Datenmenge – Datenqualität - Motivation



*Schwerpunkt:  
Auswertung von Daten*

**Natürliche  
Sprache**

**Strukturierte  
Daten**

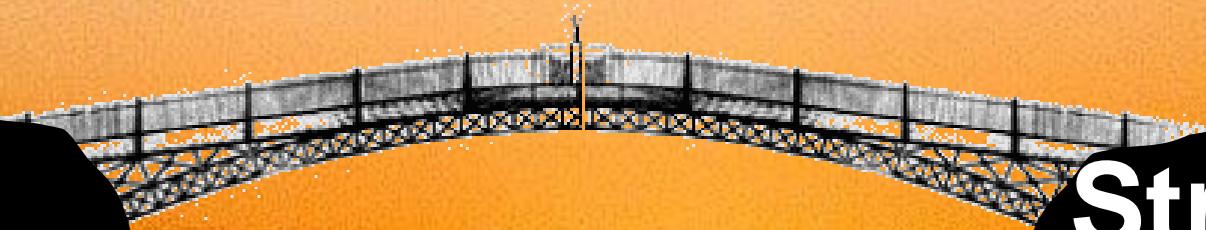




# **Automatische Verarbeitung medizinischer Sprache**

**Natürliche  
Sprache**

**Strukturierte  
Daten**





*The Tower of Babel*

Pieter Bruegel the Elder (about 1525 - 1569)

---

# Automatische Verarbeitung medizinischer Sprache

Stefan Schulz

Abteilung Medizinische Informatik

Universitätsklinikum Freiburg

---



*The Tower of Babel*  
Pieter Bruegel the Elder (about 1525 - 1569)

# Automatische Verarbeitung medizinischer Sprache

*speech*



*content*



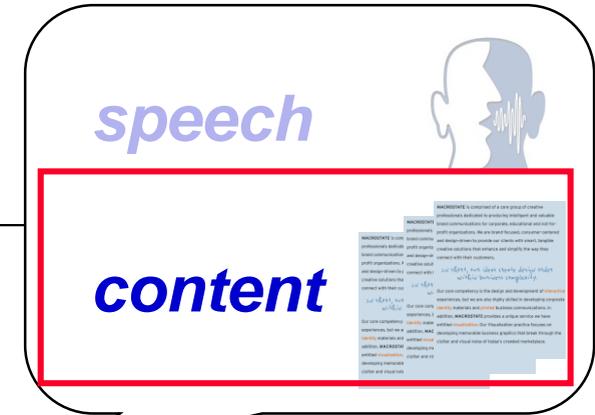
Stefan Schulz

Abteilung Medizinische Informatik  
Universitätsklinikum Freiburg



*The Tower of Babel*  
Pieter Bruegel the Elder (about 1525 - 1569)

# Automatische Verarbeitung medizinischer Sprache



Stefan Schulz

Abteilung Medizinische Informatik  
Universitätsklinikum Freiburg

# Auffälligkeiten der Medizinsprache

---

- Sprachmix: Deutsch / English / Lateinisch
- Unterschiedliche Sprachebenen: Ärzte- vs. Laiensprache
- Griechisch/Lateinische Wordstämme, Lateinische Flexionen:  
*Thyreoglobulin, Ulzera, E.coli, Kolibakterien*
- Hohe lexikalische Produktivität:
  - Komposita: *Bypassoperation, Kaliumüberdosierung*
  - Eponyme: *Parkinsonsche Erkrankung, M. Alzheimer*
  - Akronyme, Wortneubildungen: *SARS, AIDS, ARDS, 5-FU, HWI, psbAI, GGDEF, WDWN*
- Paragrammatikalität / Jargon:  
*Kein Anhalt für Malignität. (Unvollständiger Satz)*
- Agrammatikalität (Diktier-, Schreibfehler)
- Extragrammatikalität: *Gewebe wurde lymphozytär infiltriert*

# Zwei Hauptszenarien der medizinischen Textanalyse

---

- **Information Retrieval:**

gezieltes Suchen nach Informationen in einer oder mehreren großen Informationssammlungen.

- **Text Mining:**

Technologien, die es ermöglichen, relevante und „neue“ Information in unstrukturierten Texten automatisch zu erkennen und zu extrahieren



# IR vs. TM

## Information Retrieval

## Text Mining

Dr. med. Peter Groll  
Hauptstr. 1  
58275 Kalle

Patient: Herr, Adam  
Geburtsdatum: 22.06.1963, keine Angabe zum L...

Dr. med. Frank H. Stein  
Abt. 101 20  
12345 Einheiten

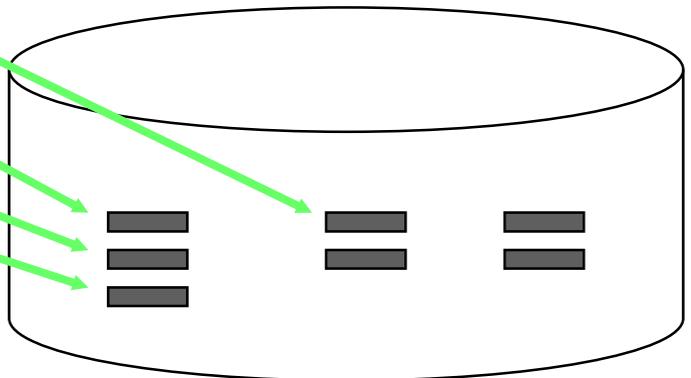
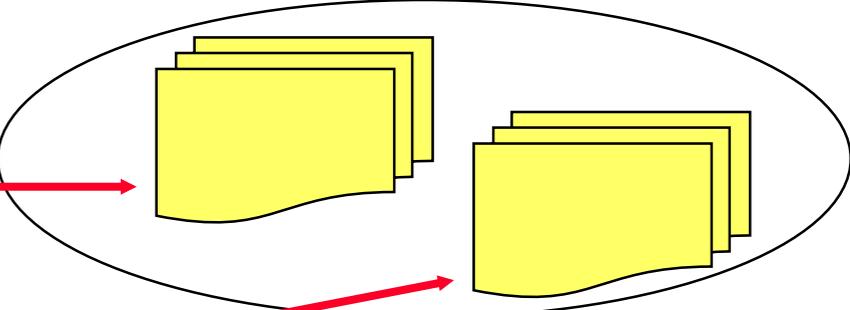
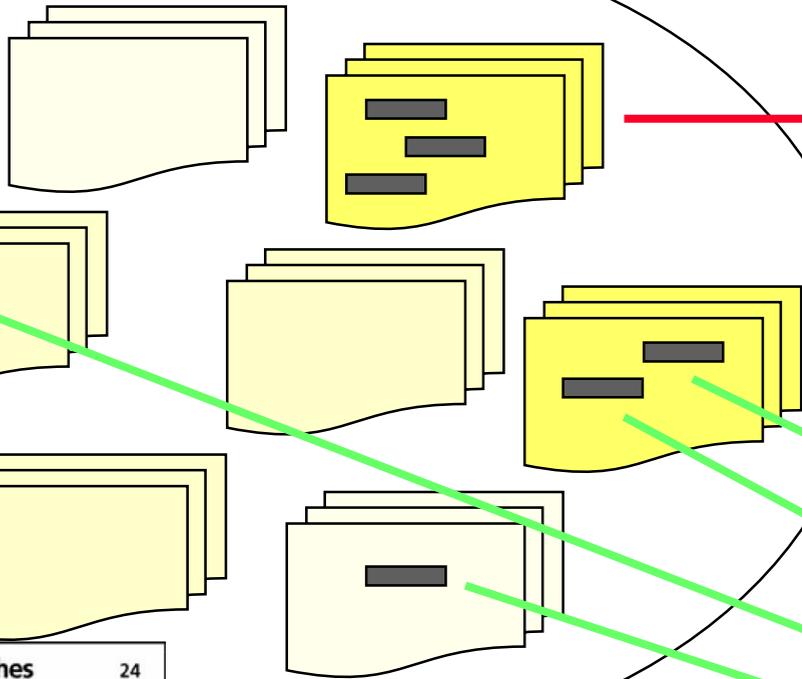
MEDEZINISCHE BELMUND POLIKLINIK  
Abteilung Innere Medizin B  
Gemeinschaftliche Hepatologie und Endokrinologie  
Ärztlicher Direktor Prof. Dr. G. v. C. H. E. Stein

Dr. med. Frank H. Stein  
Abt. 101 20  
12345 Einheiten

Dr. med. Frank H. Stein  
Abt. 101 20  
12345 Einheiten

**Operative Anamnese**  
05.05.2001

**Beobachtung:** In der Anamnese wurde berichtet, dass der Patient seit ca. 10 Jahren an einer chronischen Erkrankung leidet, die sich in den letzten Jahren verschlechtert hat. Der Patient berichtet über eine zunehmende Müdigkeit, Gewichtsverlust und eine Abnahme der Leistungsfähigkeit. In den letzten 12 Monaten wurde ein deutliches Fortschreiten der Erkrankung beobachtet. Die körperliche Untersuchung zeigt eine deutliche Abmagerung, eine erhöhte Herzfrequenz und eine leichte Schwellung der Beine. Die Röntgenuntersuchung zeigt eine deutliche Erweiterung des Herzes und eine Zunahme der Lungenschatten. Die Laboruntersuchungen zeigen eine deutliche Erhöhung der Kreatininwerte und eine Abnahme der Hämoglobinwerte.



**ZFA** Zeitschrift für Allgemeinmedizin

**Deutsches Arzteblatt** 24

**Disease Management**

# Information Retrieval

SEARCH ICD CPT HCPCS ICD CPT HCPCS Flash Code Print ?

HCPCS CODES 14 found Export

CPT Codes Eval/Mgmt Anesthesia Surgery Radiology Path/lab Medicine Flash Entry

HCPCS Codes A B D E G H J K L M P Q R S U CCI Edit

link	A4635	Underarm Pad, Crutch, Replacement, Each	PR
copy			
link	A4636	Replacement, Handgrip, Cane, Crutch, Or Walker, Each	PR
copy			
link	A4637	Replacement, Tip, Cane, Crutch, Walker, Each	PR
copy			
link	E0110	Crutches, Forearm, Includes Crutches Of Various Materials, Adjustable Or Fixed, Pair, Complete With Tips And Handgrips	PR
copy			
link	E0111	Crutch, Forearm, Includes Crutches Of Various Materials, Adjustable Or Fixed, Each, With Tip And Handgrip	PR
copy			



Web Bilder Groups Verzeichnis News Froogle<sup>Neu!</sup>

Erweiterte Suche Einstellungen Sprachtools

Google-Suche Auf gut Glück!

Suche:  Das Web  Seiten auf Deutsch  Seiten aus Deutschland

[Werbung](#) - [Unternehmensangebote](#) - [Alles über Google](#) - [Google.com in English](#)

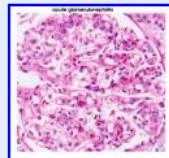
©2005 Google - Suche auf 8.058.044.651 Web-Seiten

Google Bilder glomerulonephritis Suche Erweiterte Bildsuche Einstellungen

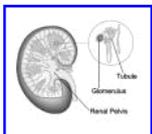
## Bilder



glomer3.jpg  
549 x 370 Pixel - 50k  
[coe.fgcu.edu/~greenep/kidney/Glomerulus.html](http://coe.fgcu.edu/~greenep/kidney/Glomerulus.html)



acute-glomerulonephritis-...  
450 x 426 Pixel - 41k  
[akimichi.homeunix.net/~emile/aki/medical/lmag...](http://akimichi.homeunix.net/~emile/aki/medical/lmag...)



kidneys\_en.gif  
300 x 269 Pixel - 17k  
[www.kidney.ca/~glomerulonephritis.htm](http://www.kidney.ca/~glomerulonephritis.htm)



4237Diffuse\_Proliferative...  
200 x 150 Pixel - 14k  
[www.emedicine.com/med/topic882.htm](http://www.emedicine.com/med/topic882.htm)



All Databases PubMed Nucleotide Protein Genome

Search PubMed for diabetes nephritis Go Clear Save Search

Limits Preview/Index History Clipboard Details

Display Summary Show 20 Sort by Send to

All: 1850 Review: 308

Items 1 - 20 of 1850

- 1: [Roussos L, Ekstrom U, Ehle PN, Oqvist B, Floren CH.](#)  
Apolipoprotein E polymorphism in 385 patients on renal replacement therapy in Sweden.  
Scand J Urol Nephrol. 2004;38(6):504-10.  
PMID: 15841787 [PubMed - indexed for MEDLINE]
- 2: [Lin SL, Chiang WC, Chen YM, Lai CF, Tsai TJ, Hsieh BS.](#)  
The renoprotective potential of pentoxifylline in chronic kidney disease.  
J Chin Med Assoc. 2005 Mar;68(3):99-105. Review.  
PMID: 15813241 [PubMed - indexed for MEDLINE]

About Entrez

Text Version

Entrez PubMed

Overview

Help | FAQ

Tutorial

New/Noteworthy

E-Utilities

PubMed Services

Journals Database

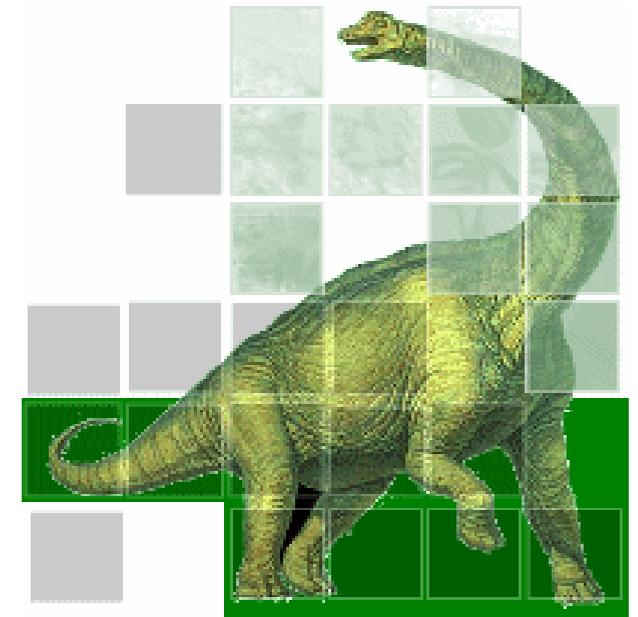
MeSH Database

Single Citation

# Beispiel: Sprachübergreifendes Dokumentenretrieval: MorphoSaurus

---

- Subwort-Lexikon:
  - Organisiert bedeutungstragende Wortstämme und Affixe in mehreren Sprachen
- Subwort-Thesaurus:
  - Gruppiert synonyme Lexikoneinträge (auch sprachübergreifend)
- Zerlegungsalgorithmus:
  - Extraktion von Subwörtern und Zuweisung von *Bedeutungsklassen*



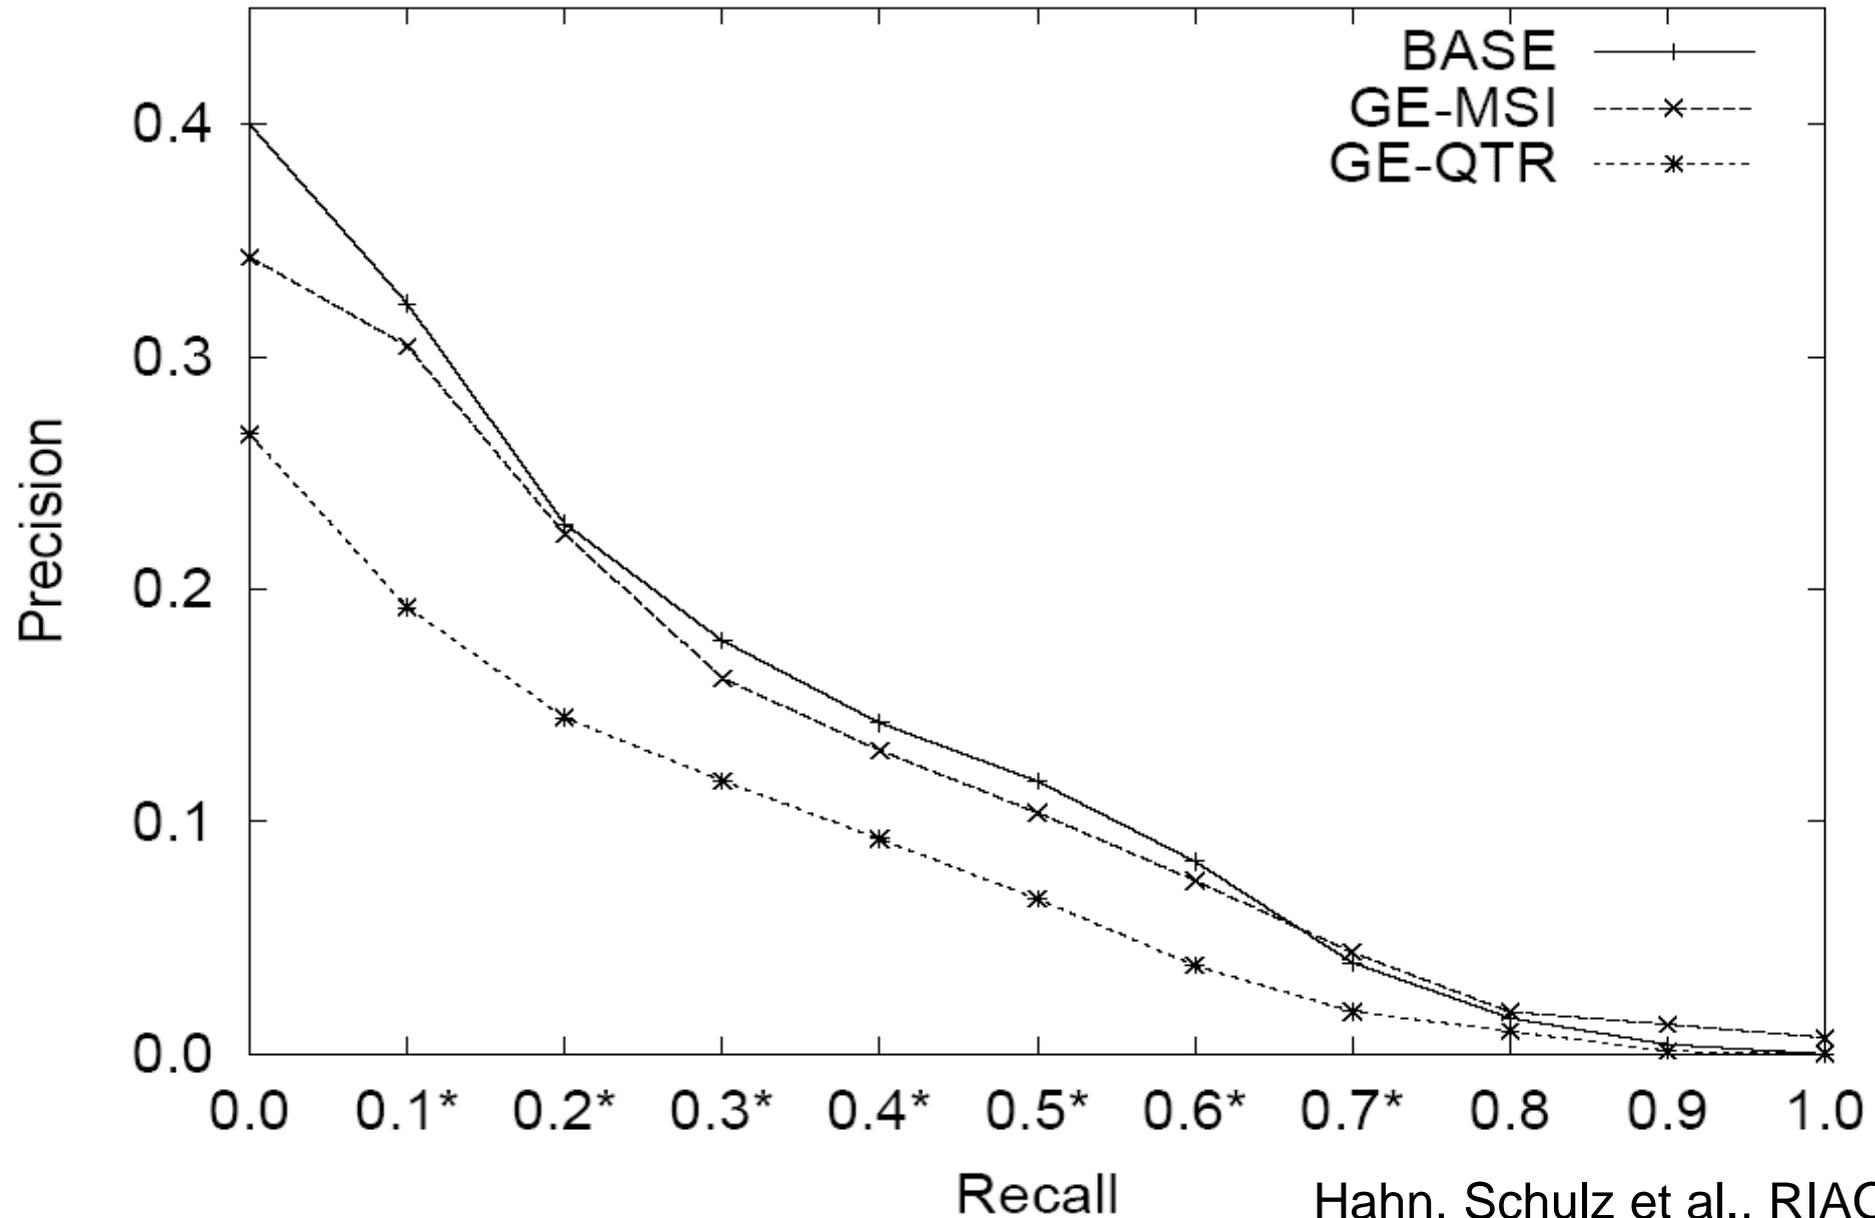
**Morphosaurus**

**Morphosaurus-  
Identifizier (MID)**

Original Document	Orthographic Normalization	Morphological Segmentation	Semantic Normalization
<p>High TSH values suggest the diagnosis of primary hypothyroidism while a suppressed TSH level suggests hyperthyroidism.</p>	<p>high tsh values suggest the diagnosis of primary hypothyroidism while a suppressed tsh level suggests hyperthyroidism.</p>	<p>high tsh value s suggest the diagnosis of primary hypothyroidism while a suppressed tsh level suggests hyperthyroidism.</p>	<p>#up# tsh #value# #suggest# #diagnost# #primar# #small# #thyre# #suppress# tsh #nivell# #suggest# #up# #thyre# .</p>
<p>Erhöhte TSH-Werte erlauben die Diagnose einer primären Hypothyreose, ein supprimierter TSH-Spiegel spricht dagegen für eine Schilddrüsenüberfunktion.</p>	<p>erhoehte tsh-werte erlauben die diagnose einer primaeren hypothyreose, ein supprimierter tsh-spiegel spricht dagegen fuer eine schilddruesenueberfunktion.</p>	<p>er hoeh te tsh - wert e erlaub en die diagnose einer primaeren hypothyreose, ein supprim iert er tsh - spiegel spricht dagegen fuer eine schilddruesen ueber funktion.</p>	<p>#up# tsh - #value# #permit# #diagnost# #primar# #small# #thyre# , #suppress# tsh - {#mirror# #nivell#} #speak# #thyre# #up# #function# .</p>
<p>A presença de valores elevados de TSH sugere o diagnóstico de hipotireoidismo primário, enquanto níveis suprimidos de TSH sugerem hipertireoidismo.</p>	<p>a presenca de valores elevados de tsh sugere o diagnostico de hipotireoidismo primario, enquanto niveis suprimidos de tsh sugerem hipertireoidismo.</p>	<p>a presenc a de valores elevad os de tsh sugere o diagnost ico de hipotireoid ismo primari o, enquanto niveis suprimid os de tsh suger em hiper tireoid ismo.</p>	<p>#actual# #value# #up# tsh #suggest# #diagnost# #small# #thyre# #primar# , #nivell# #suppress# tsh #suggest# #up# #thyre# .</p>

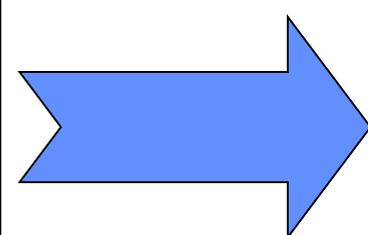
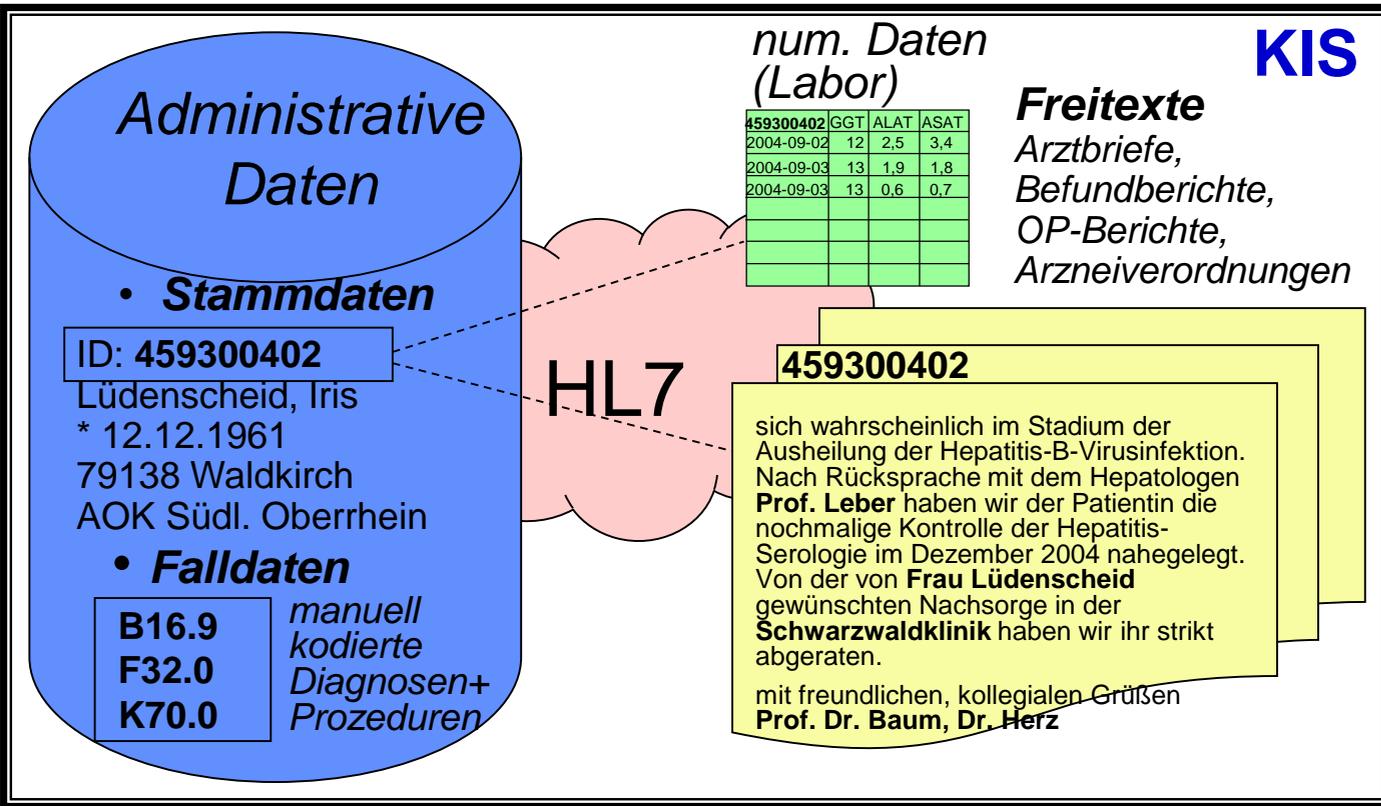
# MorphoSaurus: Sprachübergreifendes med. Dokumentenretrieval (Deutsch / Englisch)

---

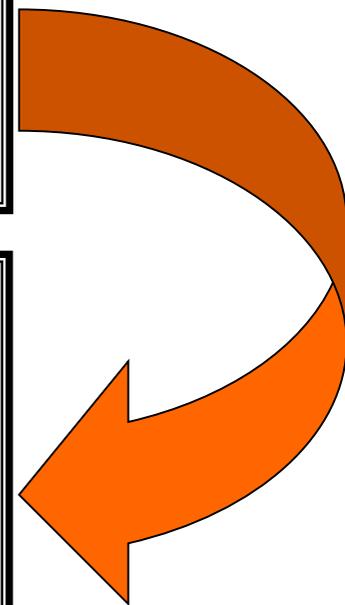


# Text Mining

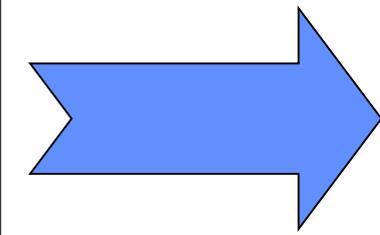
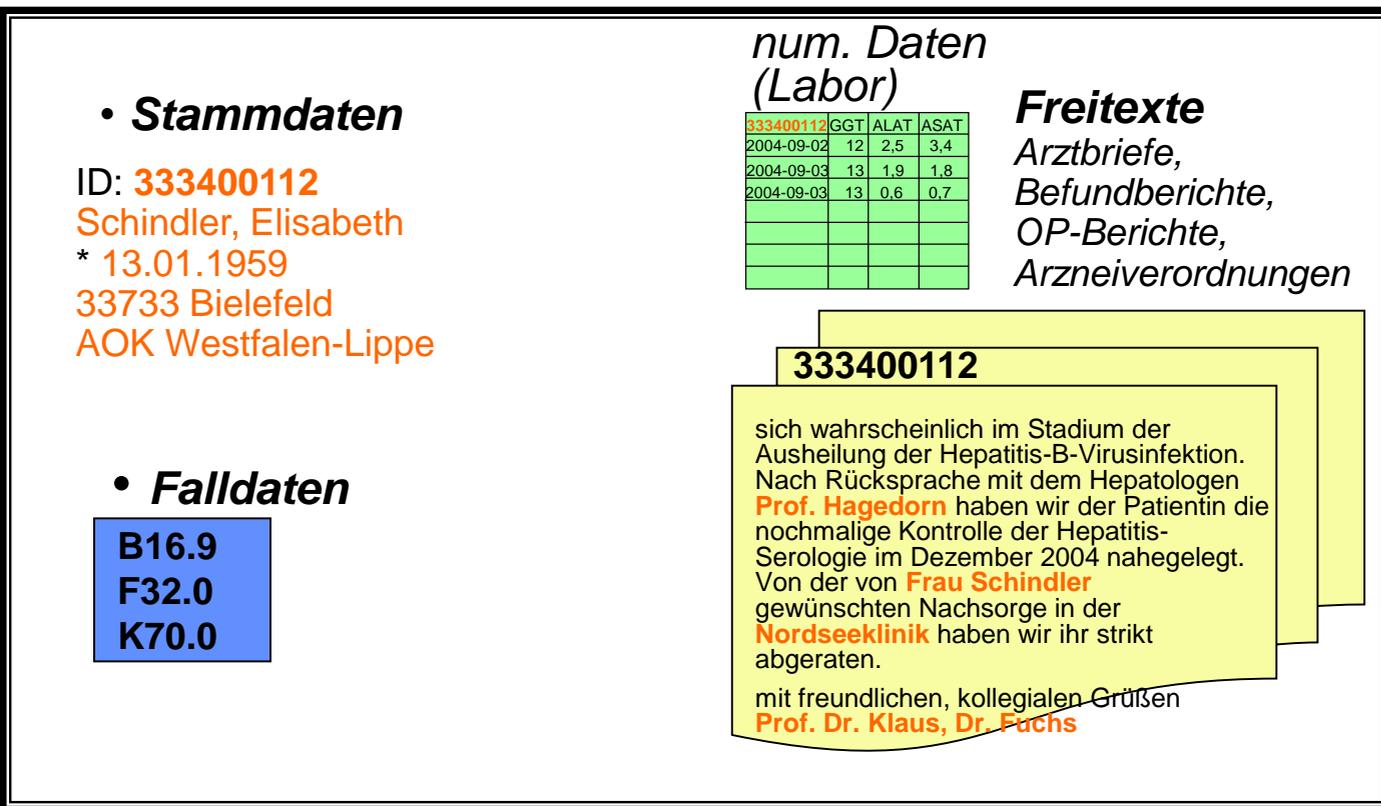
---



Text-Mining-System  
(klinikintern)



(semi)automatische Pseudonymisierung



Text-Mining-System  
(klinikextern)

# Text Mining: Anwendungsszenario I

shadow was pointed out on a routine chest X-ray film, but she had no further examination. Physical examination on admission revealed purpura of the upper and lower extremities, swelling of the gums and tonsils, but no symptoms showing the complication of myasthenia gravis. Hematological tests revealed leucocytosis: WBC count 68 700/ $\mu$ l (blasts 11.5%, myelocytes 0.5%, bands 2.0%, segments 16.0%, monocytes 65.5%, lymphocytes 4.0%, atypical lymphocytes 0.5%), Hb 7.1 g/dl (reticulocytes 12%) and a platelet count of  $9.1 \times 10^4$ / $\mu$ l. Further laboratory examination revealed elevated serum lactic dehydrogenase (589 U/l), vitamin B<sub>12</sub> (2010 pg/ml) and ferritin (650.0 ng/ml). Human chorionic gonadotropin and  $\alpha$ -fetoprotein levels were normal. A bone marrow aspiration revealed hypercellular bone marrow with a decreased number of erythroblasts and megakaryocytes and an increased number of monoblasts that were positive for staining by  $\alpha$ -naphthyl butyrate esterase and negative for staining by naphthol ASD chloroacetate esterase. Chest X-ray upon admission revealed a mediastinal mass and an elevated left diaphragm. Computed tomography (CT) of the chest showed a left anterior mediastinal mass. Based on these findings, the patient was diagnosed with a mediastinal tumor accompanied by AMoL. First, in June 1991, the patient was treated with DCMP therapy: daunorubicin (DNR) (25 mg/m<sup>2</sup>, days 1, 2, 3, 4, 6 and 8), cytosine arabinoside (Ara-C) (100 mg/m<sup>2</sup>, days 1-9), 6MP-riboside (6-MP) (70 mg/m<sup>2</sup>, days 1-9) and prednisolone (PSL) (20 mg/m<sup>2</sup>, days 1-9), followed by five courses of consolidation chemotherapy [1, DCMP; 2, ID-Ara-C:adriacin (ADR), vincristine (VCR), Ara-C, PSL; 3, DCMP; 4, ID-Ara-C; 5, A-triple V: Ara-C, VP-16, VCR, vinblastine (VBL)]. After induction chemotherapy, a hematological examination and bone marrow findings had improved to normal, and complete remission was attained. Chest CT scan after chemotherapy in November 1991 revealed regression of the mediastinal tumor. An invasive thymic tumor was suspected and surgery was undertaken in January 1992. The tumor (50 × 45 × 45 mm), located mainly in the anterior mediastinum, was strongly adhered to the adjacent tissues. Resection of the tumor included the left upper lobe of the lung, the phrenic nerve and pericardium. The histological finding was that the tumor cells have large, vesicular nuclei and prominent nucleoli, but keratinization was unclear. The results of immunohistochemical finding of anti-TdT was negative. From these findings, we diagnosed poorly or moderately differentiated squamous cell carcinoma of the thymus. The postoperative course was uneventful. The patient underwent radiation therapy of the mediastinum and left hilum at doses of 4000 cGy delivered over 4 weeks. She was discharged in March 1992. After the first AMoL remission, the patient suffered a relapse six times and was repeatedly admitted for chemotherapy. During these periods, chest X-ray and CT revealed no recurrence of the mediastinal tumor. During her tenth admission, the patient developed pneumonia during chemotherapy and died in October 1996. No autopsy was performed.

## Tumorregister - Template

Datum	Erstdiagnose	—
Primärloka-	lisation	—————
Grading		—
Staging		—————
Morphologie		—————
Datum	Ersttherapie	—
Chemotherapie		—————
Bestrahlung		—————

# Text Mining: Anwendungsszenario II

Milde und Schwere Verlaufsformen: EB simplex (EBS), EB dystrophica (EBD)



Risikoabschätzung von Tumorentstehung durch Genotyp-Phänotyp-Korrelationen bei *Epidermolysis bullosa dystrophica*

- *Epidermolysis bullosa*: Gruppe von genetischen Hautkrankheiten mit Mutationen in Genen für Strukturproteine der dermo-epidermalen Basalmembranzzone. Inzidenz: 1 / 100.000 Geburten.
- Minimale Traumata führen zu Blasenbildung an Haut und hautnahen Schleimhäuten, Abheilung der dadurch entstandenen Wunden führt oft zur Narbenbildung und ggf. zu Verwachsungen, die auch Kontrakturen bedingen können.

# Text Mining: Anwendungsszenario II

---

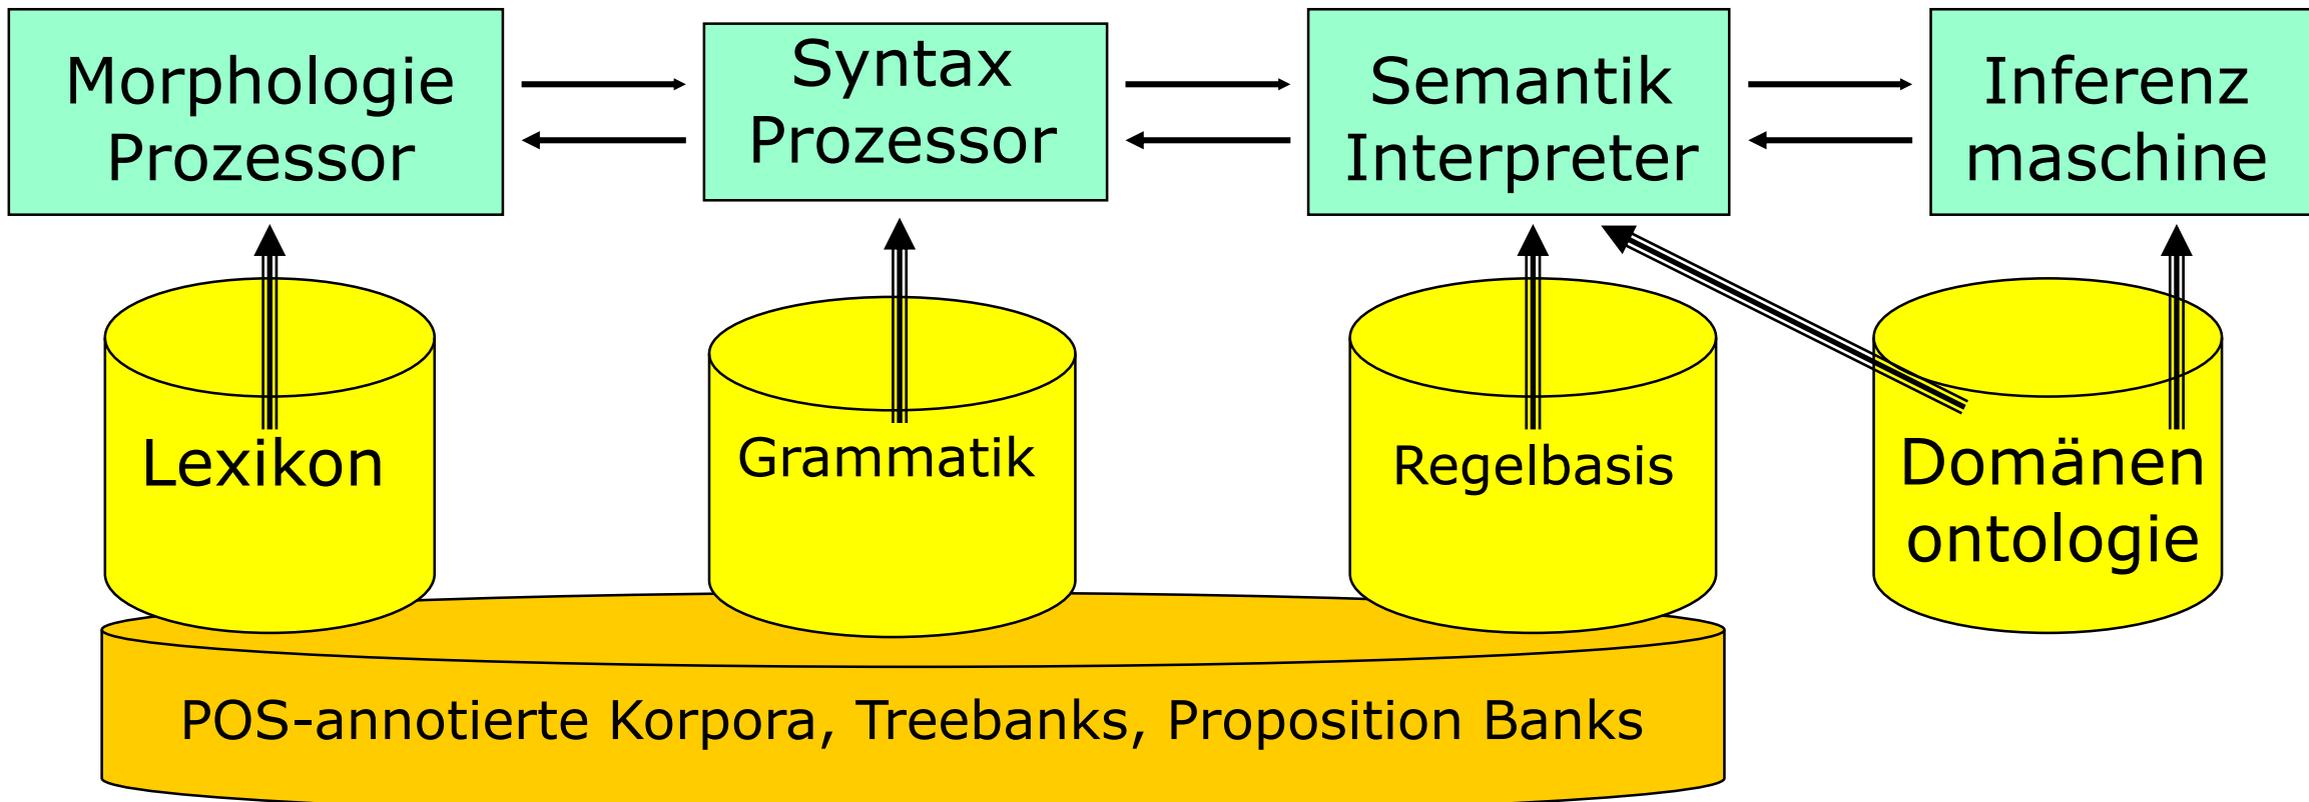
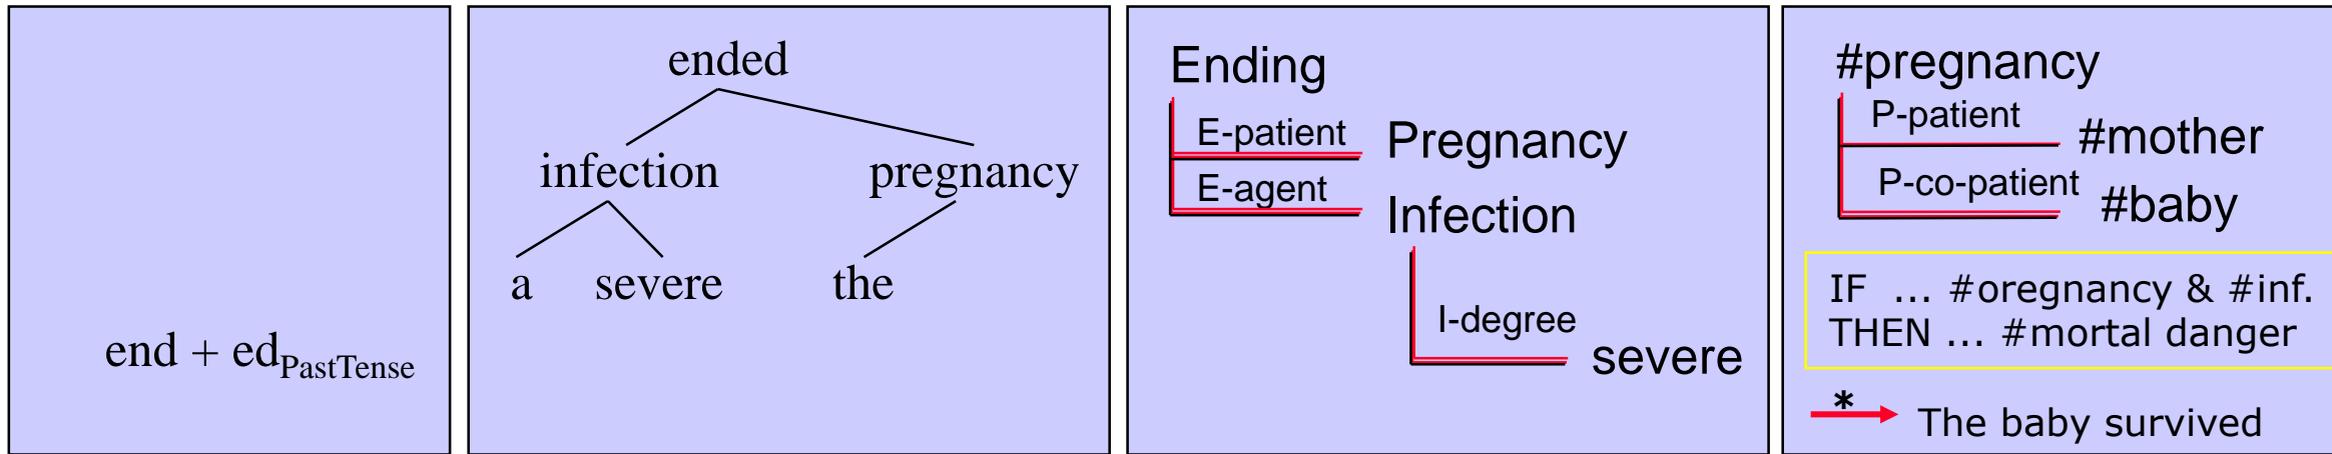
## *EB dystrophica* (EBD)

- mehr als 300 unterschiedliche Mutationen des Kollagen VII-Gens publiziert und/oder in den Mutations-Datenbanken, mehrere Hundert weitere, noch nicht bekannte Mutationen.
- Ziel des Text Minings: Verbesserung der Prognosestellung — Auffinden **bislang unentdeckter** Korrelationen zwischen Art und Lokalisation der Genmutation und des klinischen Langzeitverlaufs sowie der Erkennung maligner Entartungen
- Abgleichen der Daten
  - in der Literatur,
  - in Mutations-Datenbanken,
  - in eigenen Laborbefunden etc.
  - in internen und externen klinischen Dokumenten

# Architektur eines Biomedizinischen Textanalyse-Kernsystems

# Architektur eines Biomedizinischen Textanalyse-Kernsystems

„A severe infection ended the pregnancy“



# Methoden, Werkzeuge und Ressourcen

---

- Morphologiewerkzeuge (Stemmer)
- POS (part-of-speech) Tagger
- Chunker (NP), (shallow) Parser
- Lexika, Endliche Automaten, Grammatiken, Ontologien
- Namenserkenner (NE recognition)
- Große Textkorpora (annotiert, nichtannotiert)
- Machine learning – Verfahren, e.g. SVM
- Evaluationsstandards

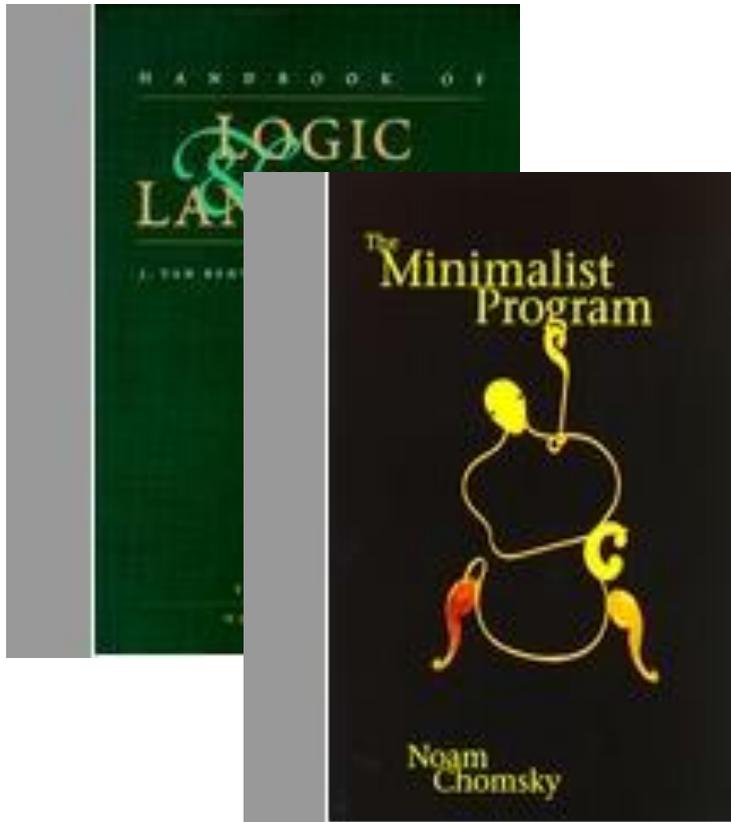
# Methoden, Werkzeuge und Ressourcen

---

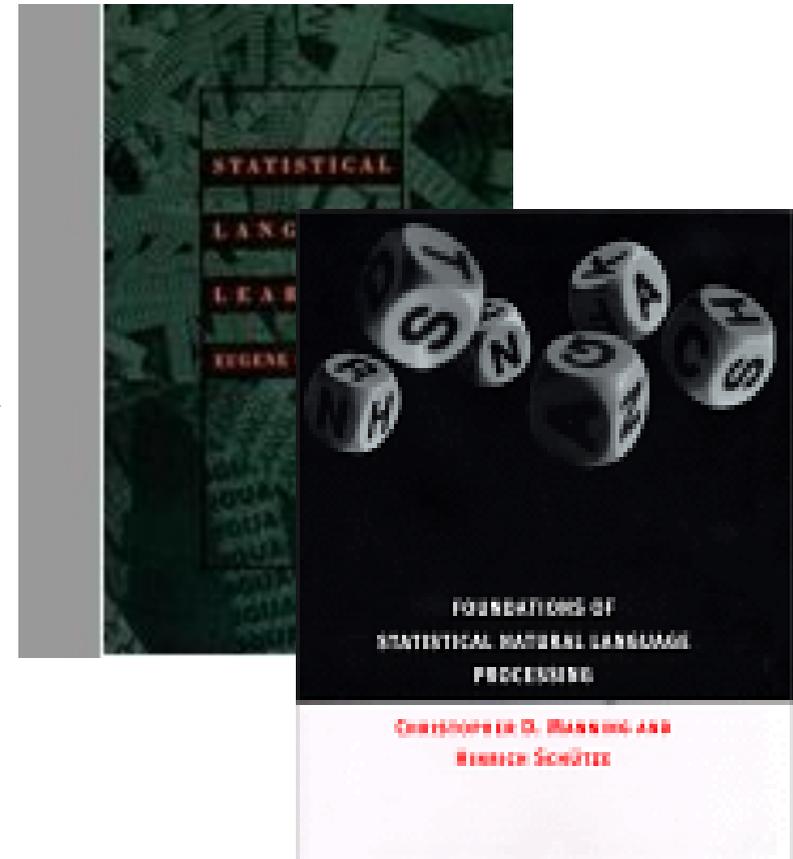
- Morphologiewerkzeuge (Stemmer)
- POS (part-of-speech) Tagger
- Chunker (NP), (shallow) Parser
- Lexika, Endliche Automaten, Grammatiken, Ontologien
- Namenserkenner (NE recognition)
- Große Textkorpora (annotiert, nichtannotiert)
- Machine learning – Verfahren, e.g. SVM
- Evaluationsstandards

# Paradigmenwechsel in der Computerlinguistik

---



Regelbasiert, KI



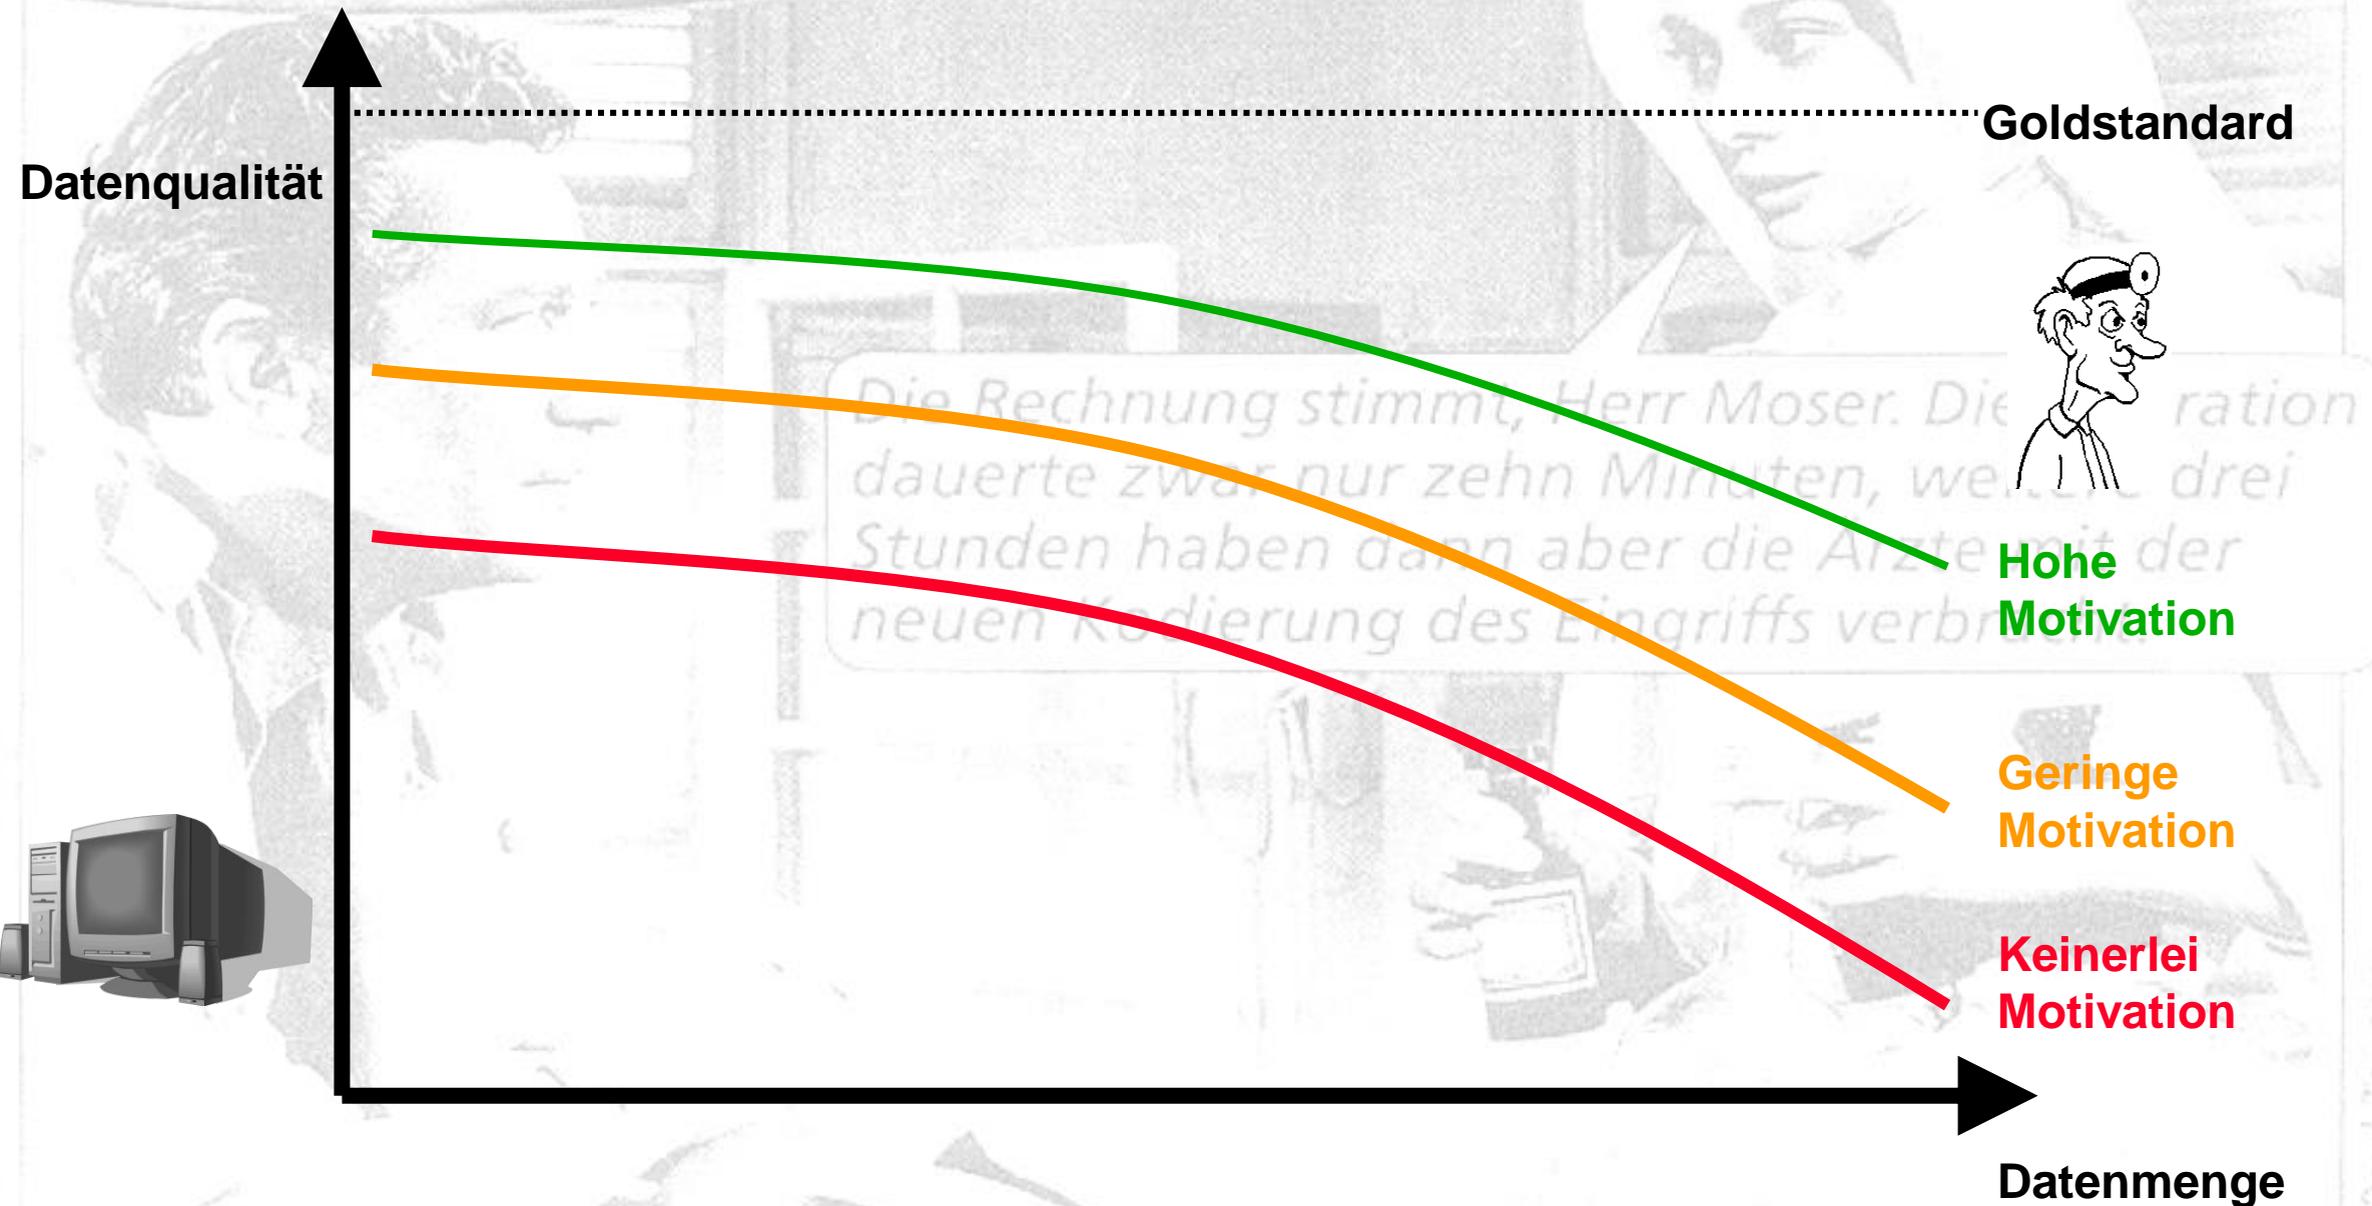
Stochastisch, ML

# Herausforderung für medizinische Sprachverarbeitung

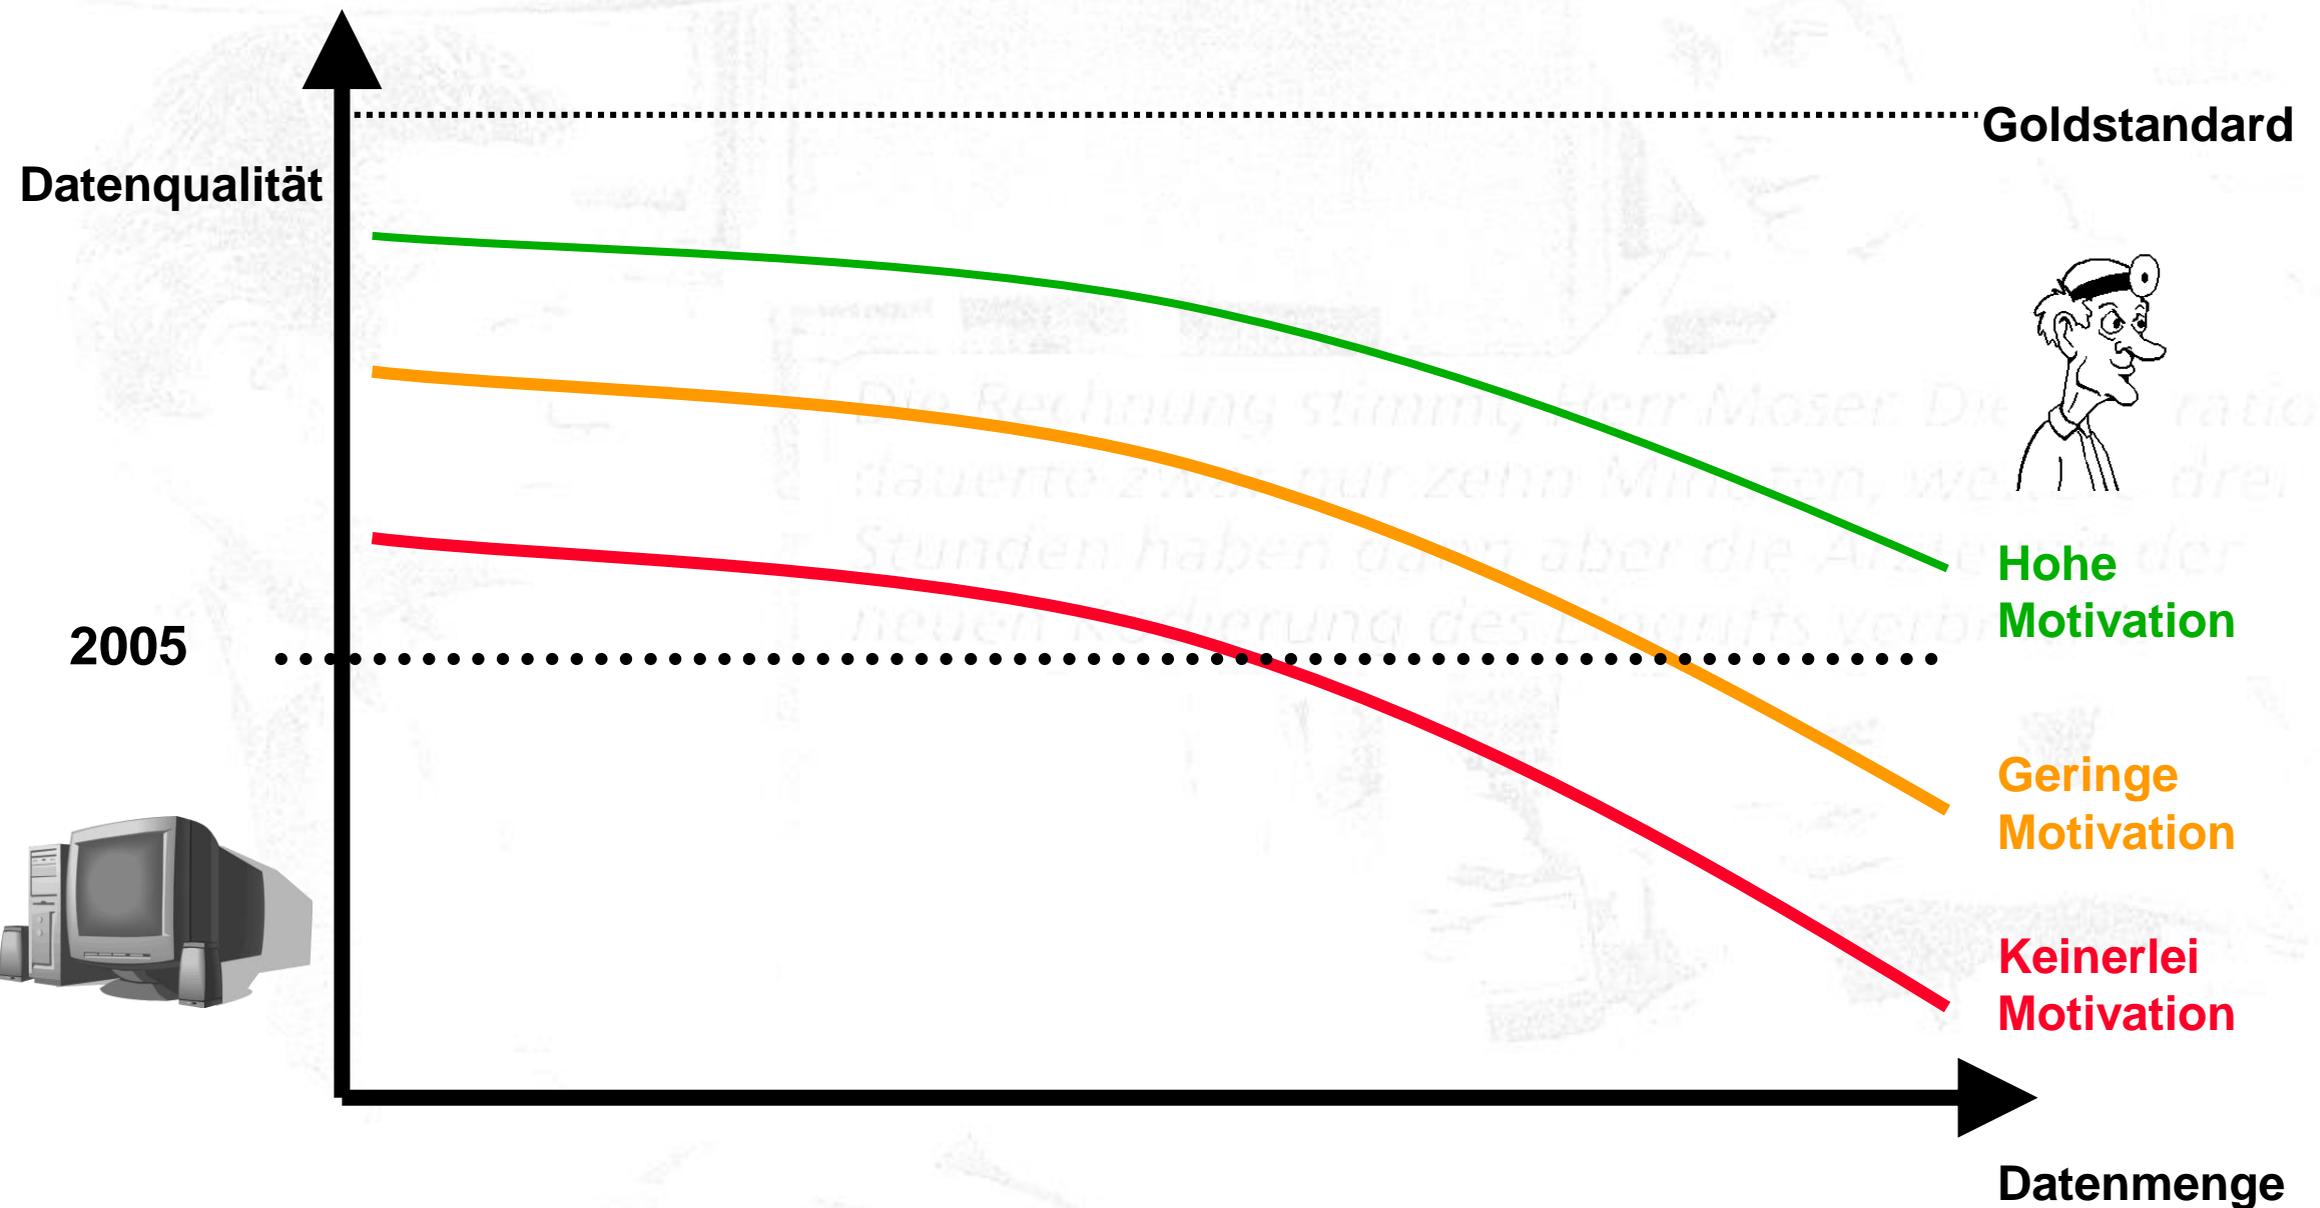
---

- Ambiguität
  - Lexikalisch: Bruch (Hernie) vs. Bruch (Fraktur)
  - Syntaktisch: z.B. Anbindung von PPs
    - *extraction [of the transplant [with a scalpel] ]*
    - *[extraction] {of the transplant} [with a scalpel]*
  - Semantisch, z.B. Skopus von Quantoren, Negationen, Koordinationen, Gradaussagen
    - *each* sample showed an increased Ph value
- Komplexität, Berechenbarkeit, z.B.
  - Abhängenzgrammatiken: **NP-complete**
  - Prädikatenlogik höherer Ordnung, Modallogik: **unentscheidbar**
- Kombination mit Ontologien und medizinischen Terminologiesystem
- Kombination von symbolischen und stochastischen Ansätzen

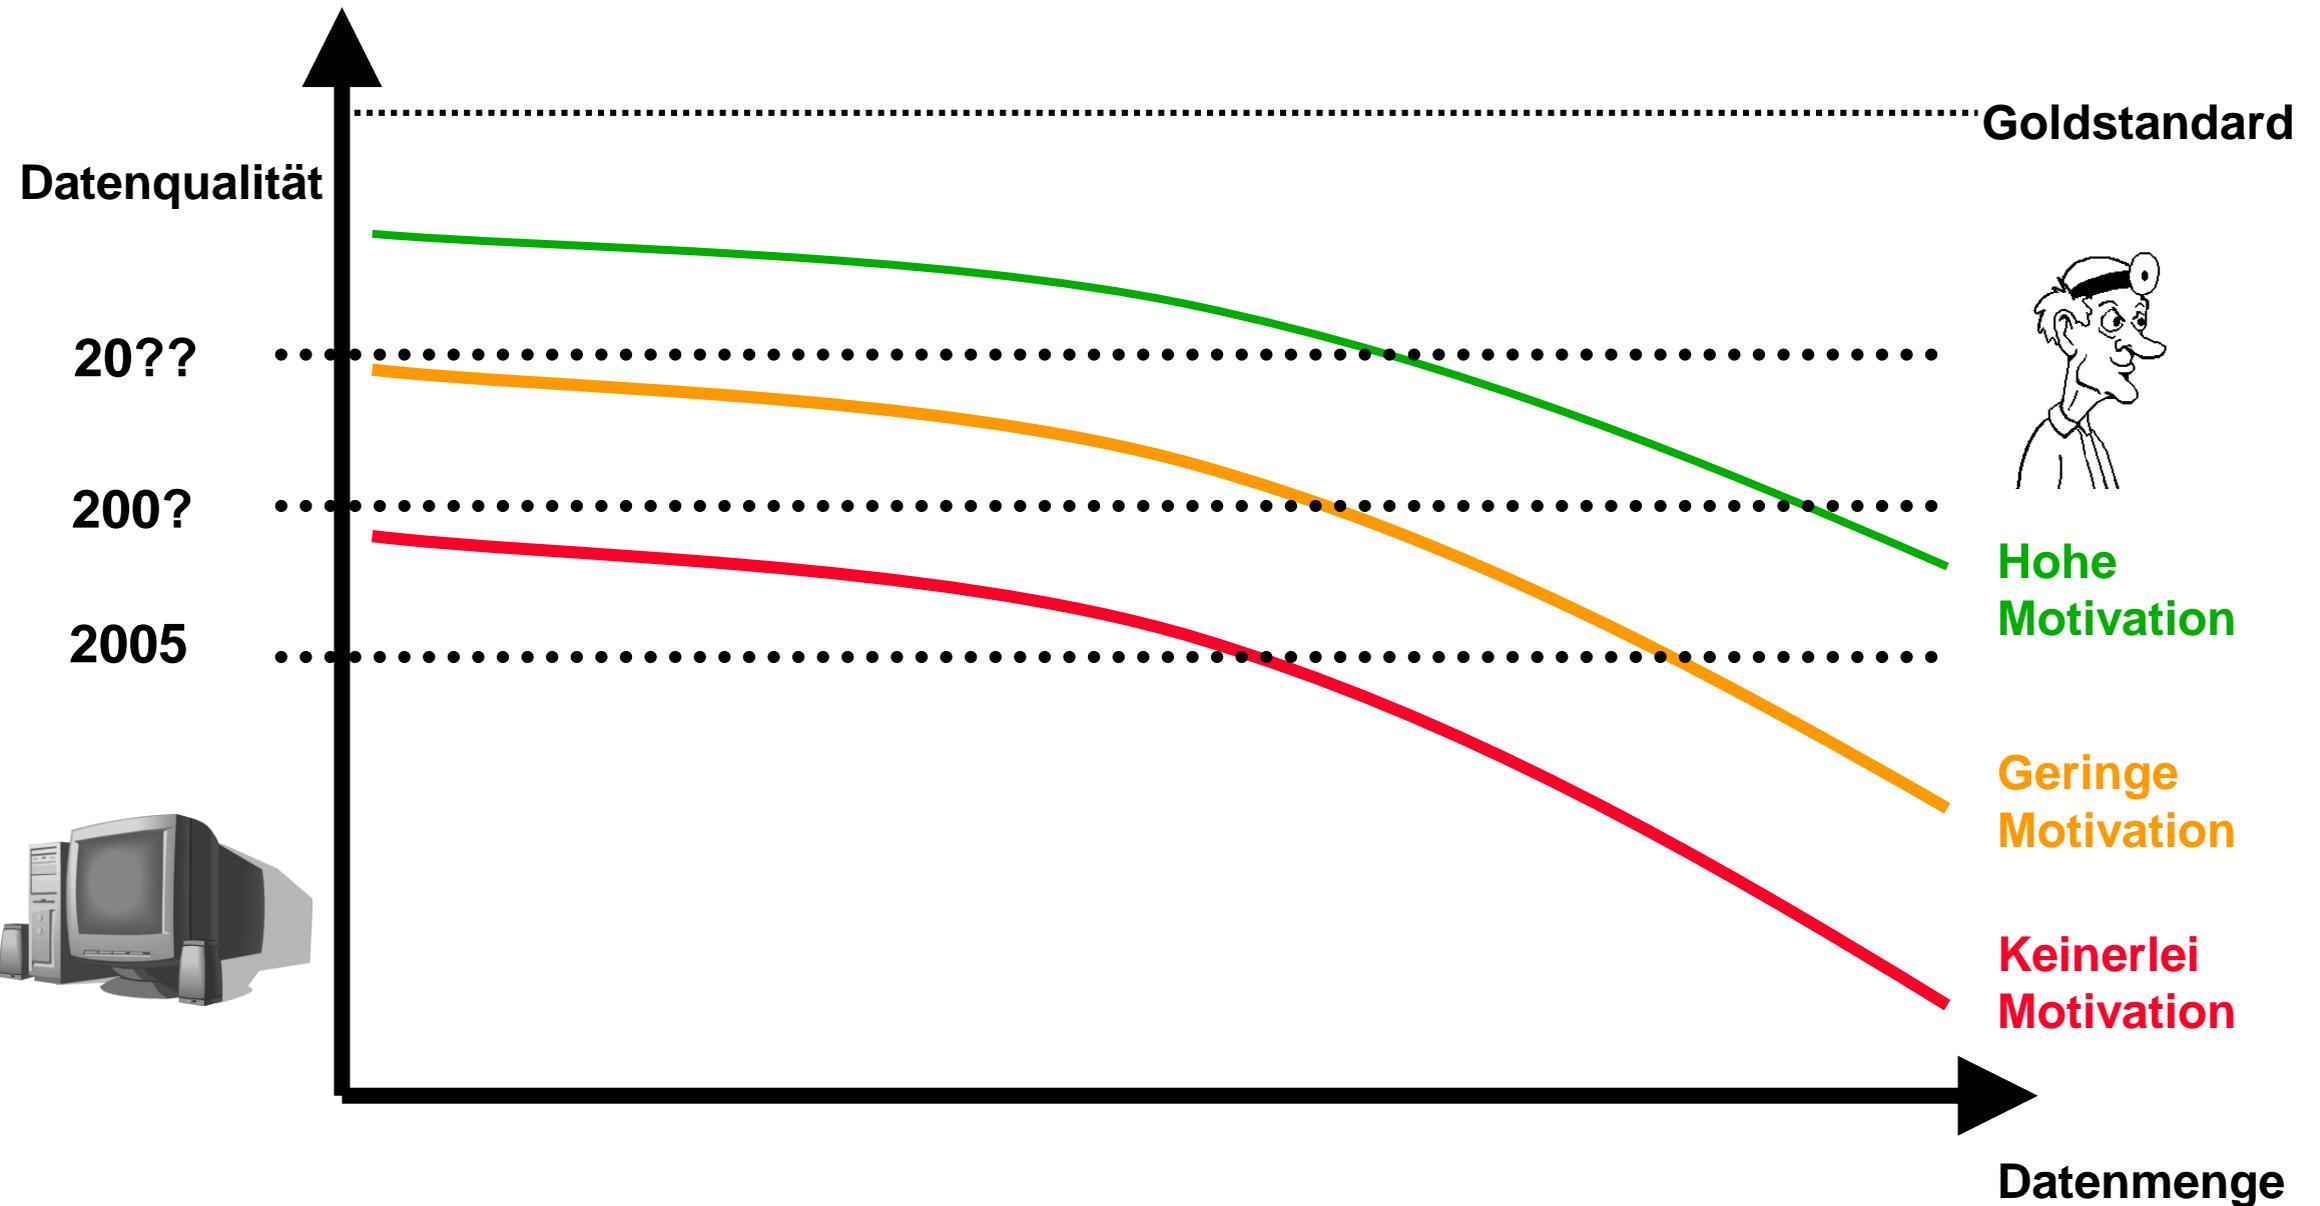
# Ausblick: Menschliche vs. Maschinelle Sprachverarbeitung



# Ausblick: Menschliche vs. Maschinelle Sprachverarbeitung



# Ausblick: Menschliche vs. Maschinelle Sprachverarbeitung



# Aktivitäten MI Freiburg

---

- EU 6th Framework :  
Network of Excellence “SemanticMining”  
(Semantic Interoperability and Data Mining in Biomedicine):  
2004 – 2006, 25 Partner  
[www.semanticmining.org](http://www.semanticmining.org)
- Gründung: AMIA Working Group Group KR-SIG  
“Formal (Bio)medical Knowledge Representation”, 2003
- Veranstalter: Workshop KR-MED 2004 in Whistler/Canada, Juni 2004
- Initiative BioTem (Zentrum für biomedizinisches Text Mining)
- Veranstalter: Konferenz SMBM 2005 (Semantic Mining in Biomedicine), in Cambridge UK, April 2005
- Wichtiger Partner: Udo Hahn, Computerlinguistik Universität Jena (bis 2004 in Freiburg)



# Medical Terminology: Poor retrieval performance

---

Frequency of synonymous German Word forms in *Google* Searches

Spelling Variants Synonyms Inflections		
Kolonkarzinom	2070	1780
Colonkarzinom	248	135
Colonicarcinom	111	73
Colon-Ca	203	169
Kolon-Ca	66	46
Dickdarmkrebs	4000	3610
Dickdarmkarzinom	288	175
Dickdarmcarcinom	13	10
Kolonkarzinoms	471	253
Kolonkarzinome	275	139
Kolonkarzinomen	265	166

Number of Hits

Number of exclusive hits (no other form matches)



# Neue Anwendungsszenarien

---

- The Semantic Electronic Health Record
- Named entity recognition challenged by the deluge of new proper names from the bio domain
- Use huge (Terabyte !) medical corpora (from all sources including anonymized EHR data) for the discovery of domain and linguistic knowledge
- Use content technologies to match genotype information (Bio-DBs) with phenotype information (EHR).

---

(1.) In einem Partikel mit 4 mm Durchmesser wurde eine Magenschleimhaut vom Antrumtyp erfaßt.

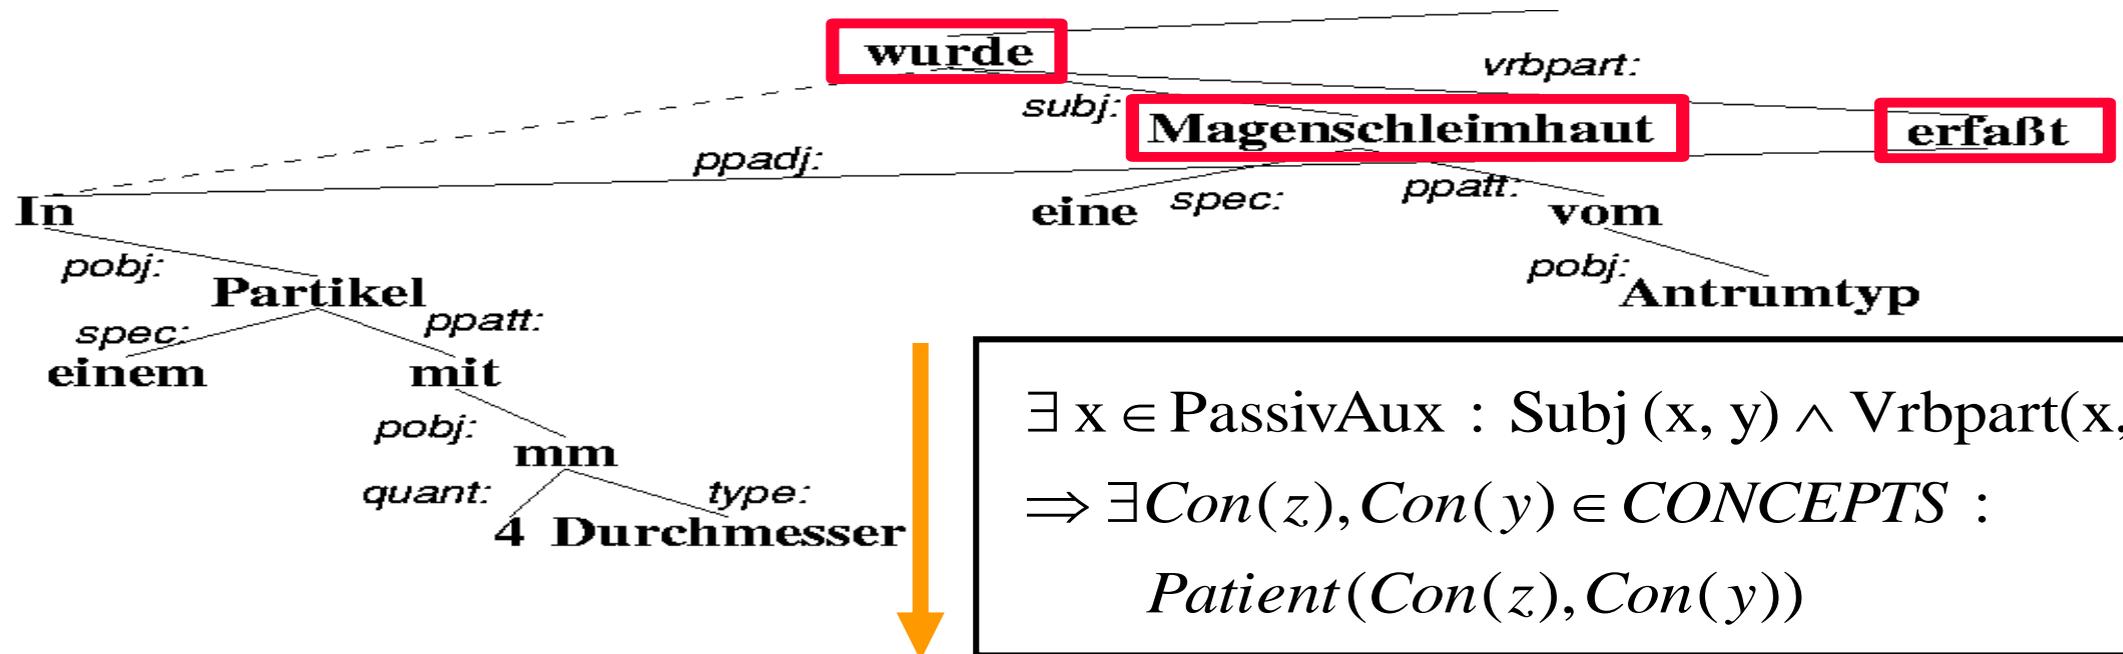


(2.) Das ödematöse Stroma wird massiv von Lymphozyten infiltriert.

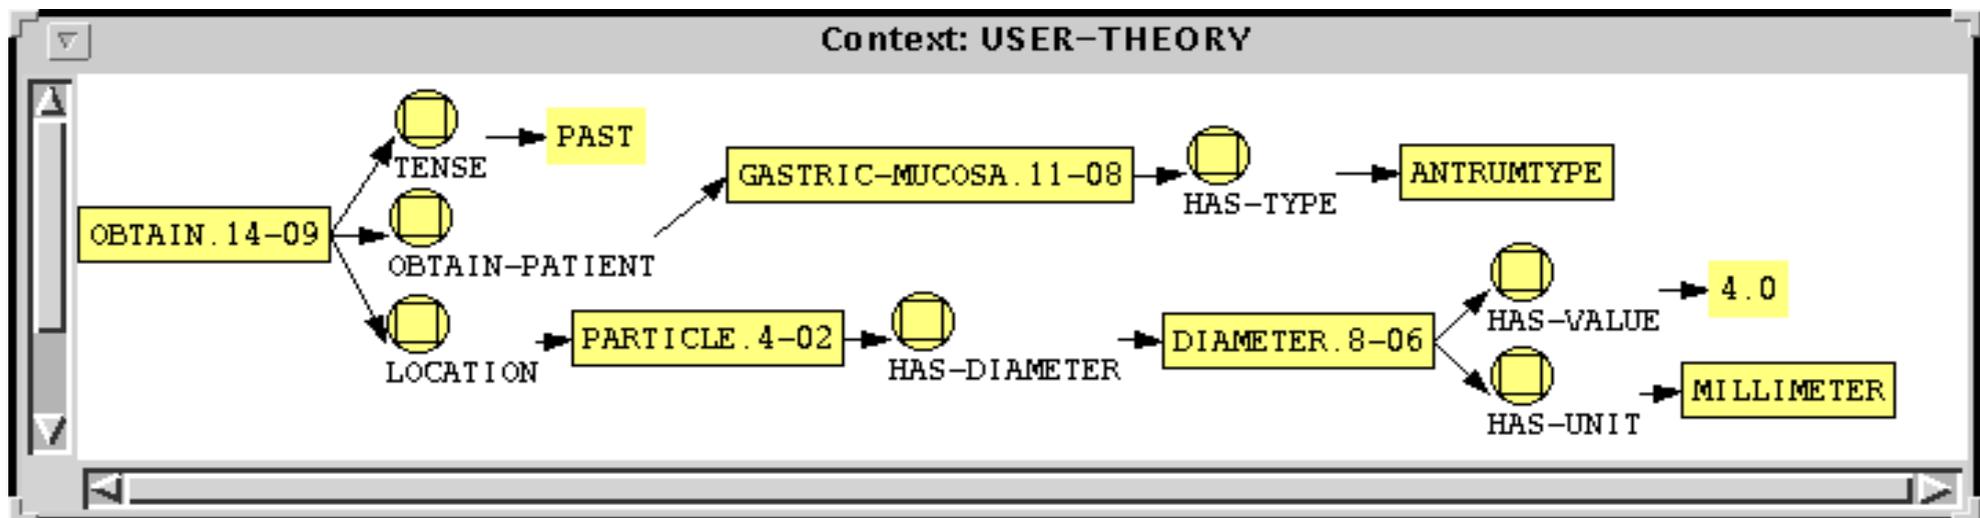


# Semantische Interpretation

In einem Partikel mit 4 mm Durchmesser wurde eine Magenschleimhaut vom Antrumtyp erfaßt.

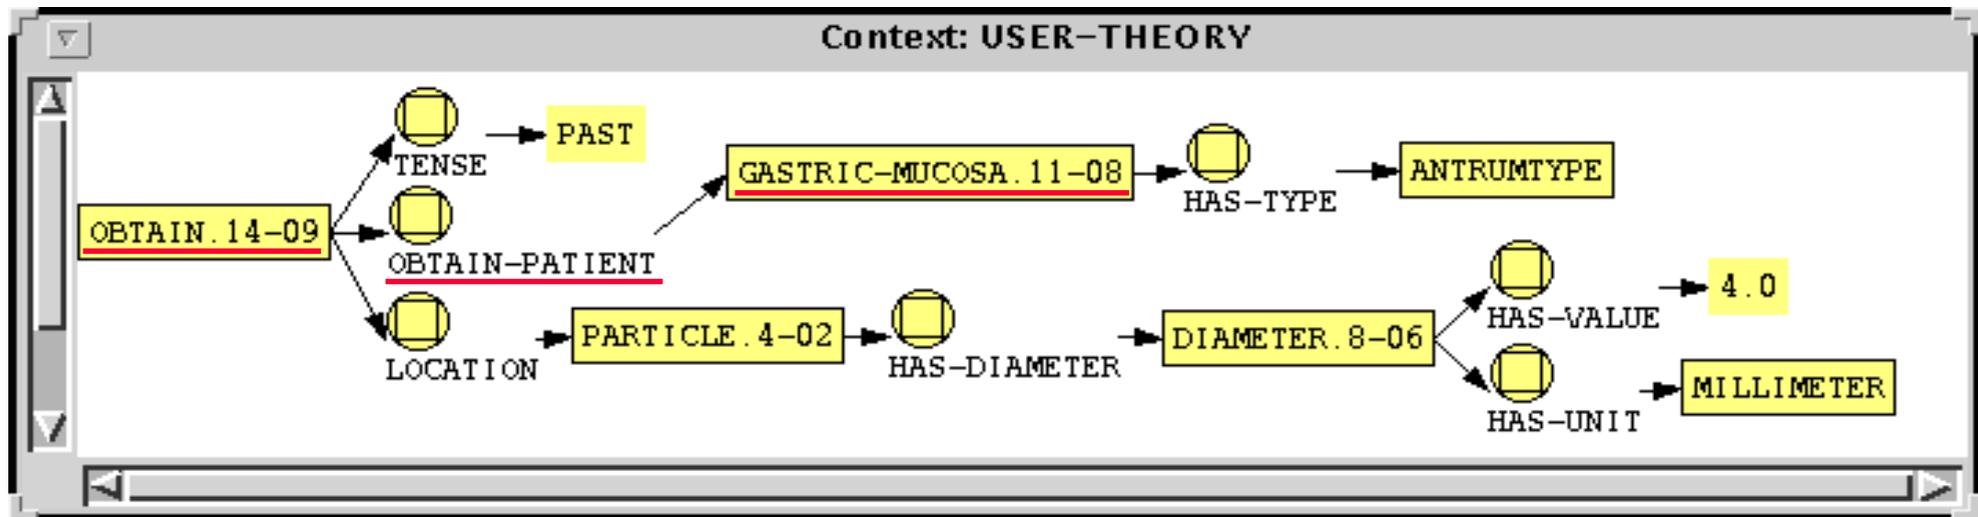


$\exists x \in \text{PassivAux} : \text{Subj}(x, y) \wedge \text{Vrbpart}(x, z)$   
 $\Rightarrow \exists \text{Con}(z), \text{Con}(y) \in \text{CONCEPTS} :$   
*Patient(Con(z), Con(y))*



# Konzept-Graph von Satz 1

In einem Partikel mit 4 mm Durchmesser wurde eine Magenschleimhaut vom Antrumtyp erfaßt.

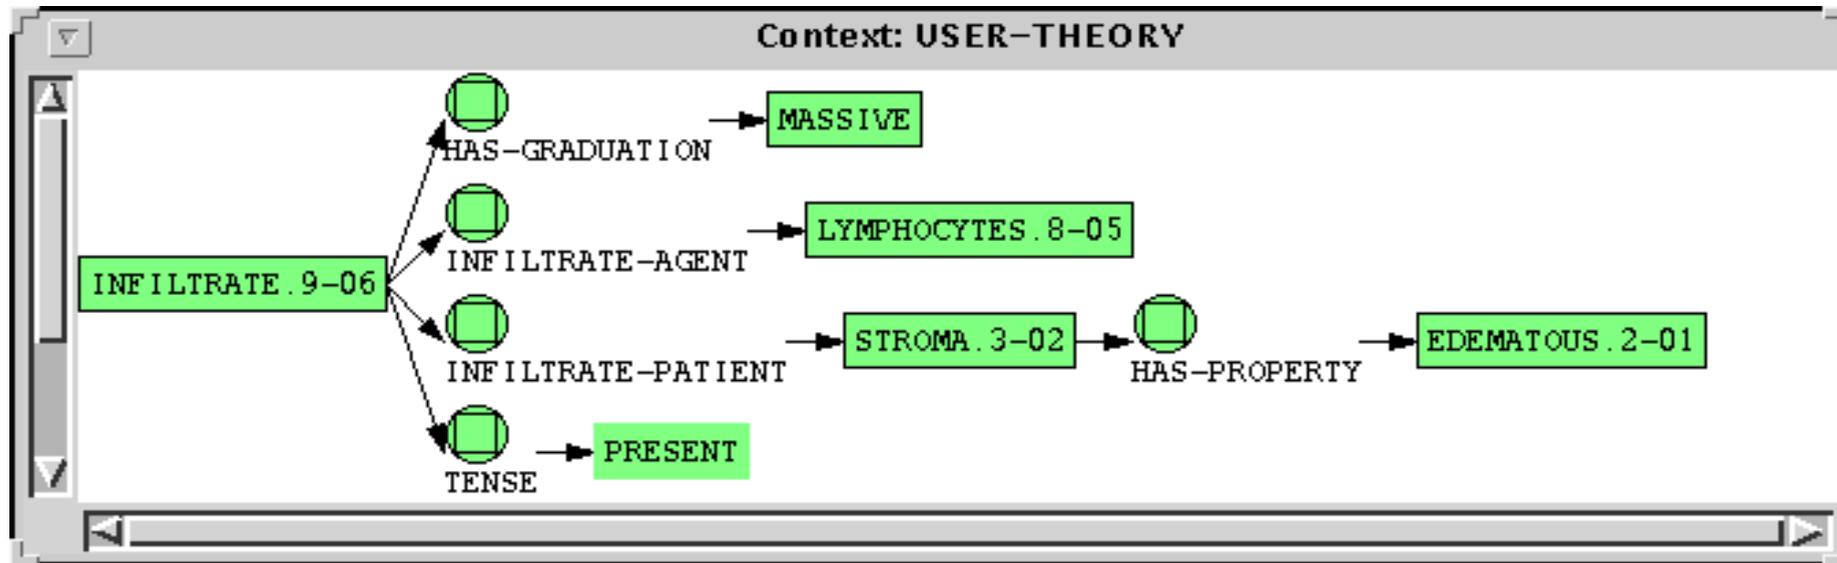


## Semantische Interpretation:

- Berechnung der konzeptuellen Relationierungen
- "Normalisierung" des Passivs
- Korrekte Anbindung der Präpositionalphrasen (in, mit, vom)

# Konzept-Graph von Satz 2

Das ödematöse Stroma wird massiv von Lymphozyten infiltriert.

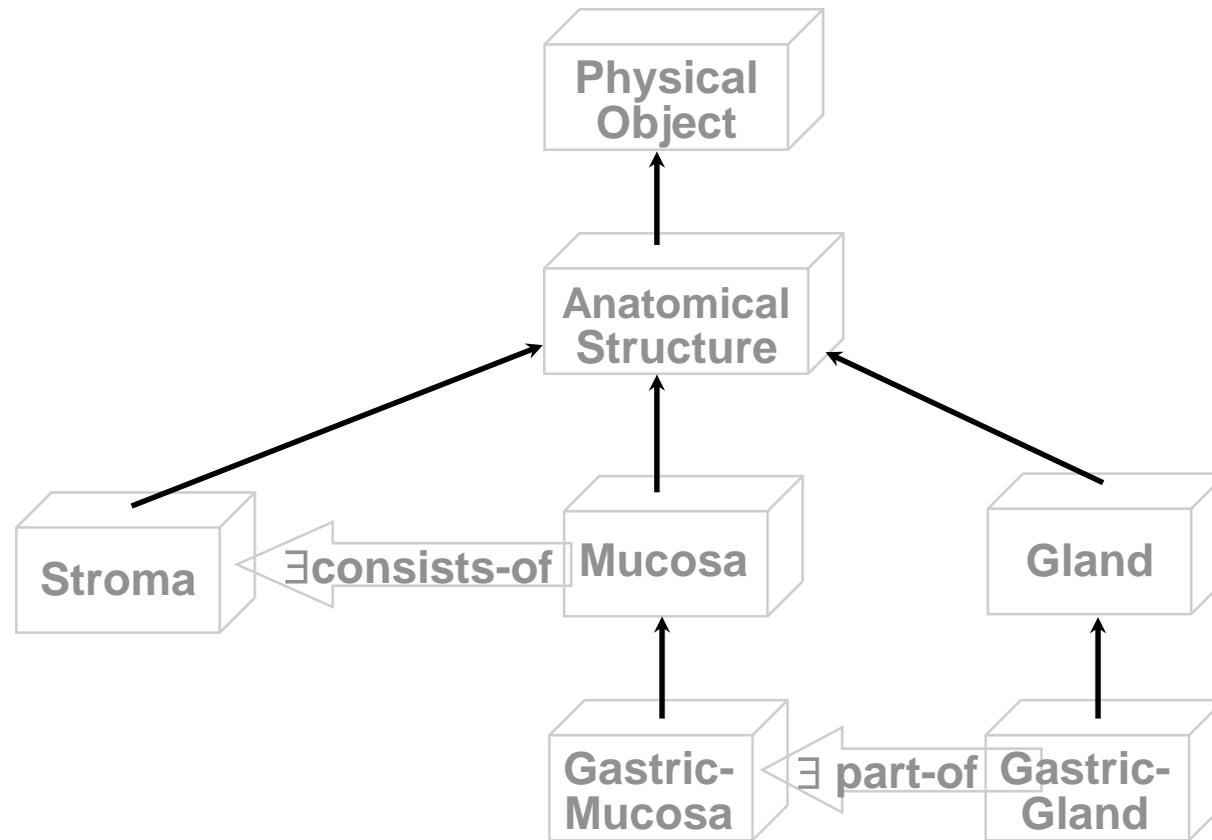


## Ergebnis der satzorientierten Analyse:

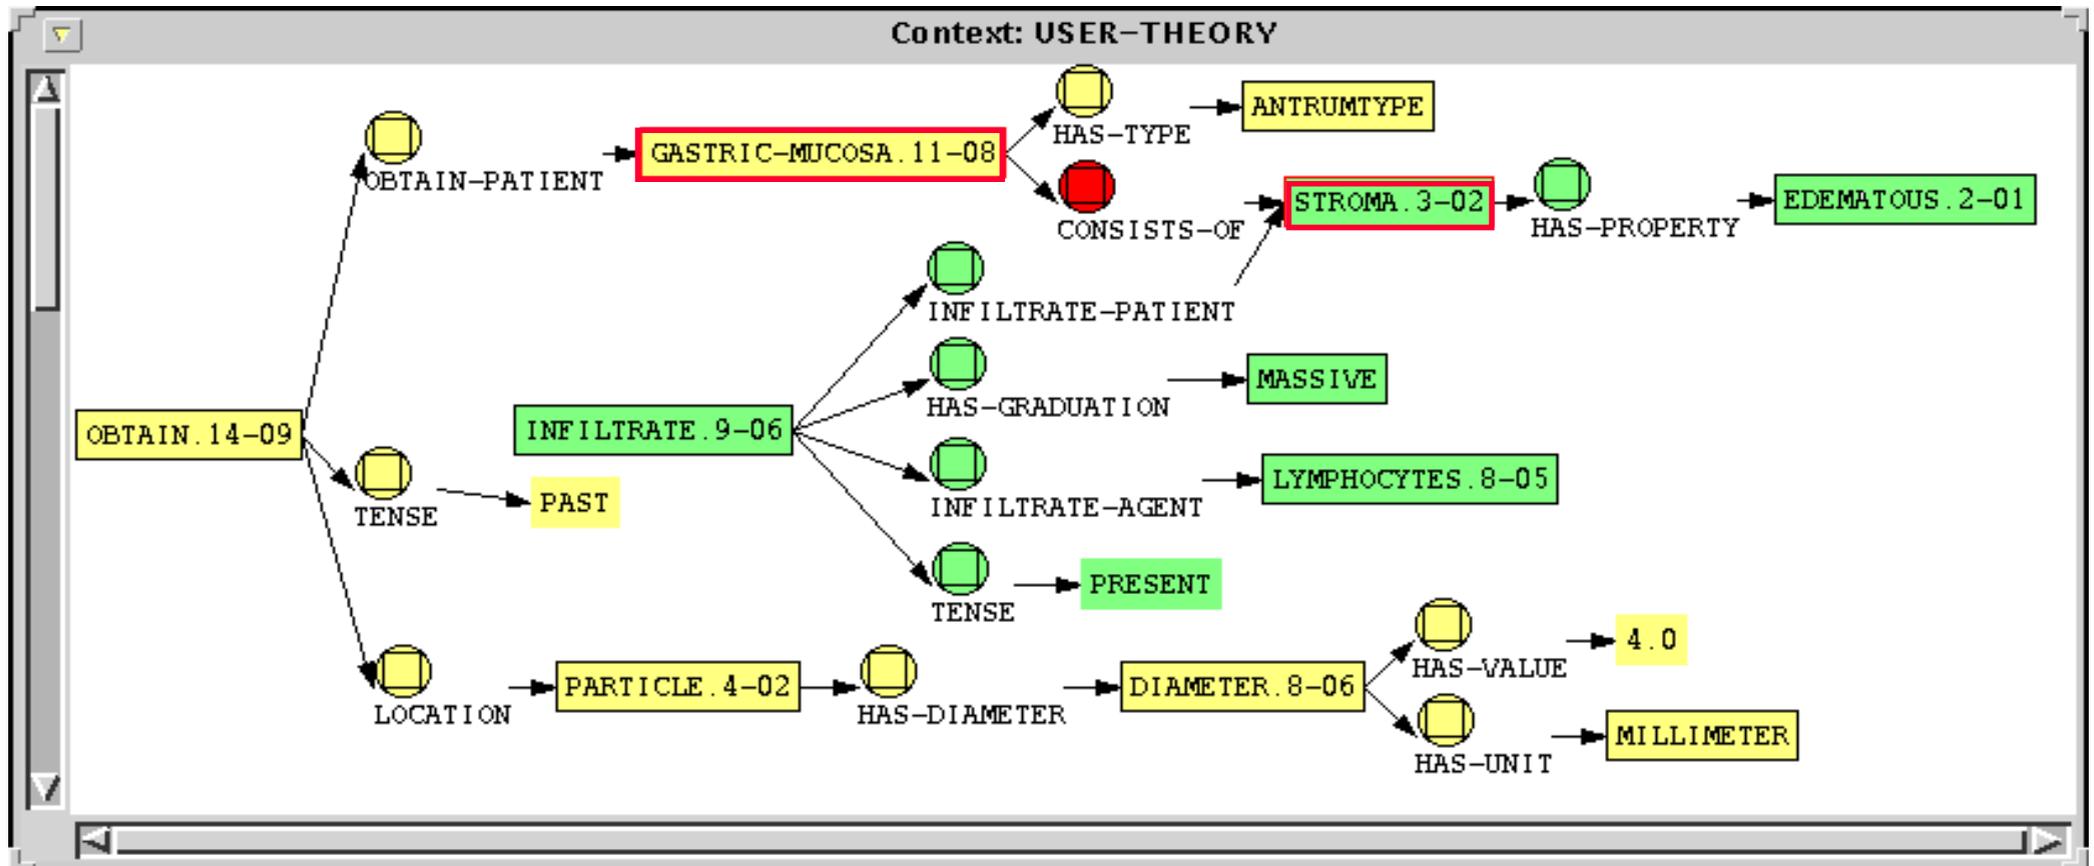
- Pro Satz ein **isolierter** Konzeptgraph
- Ist dies eine adäquate Inhaltsrepräsentation des **Texts**?

# Medizinisches Domänenwissen

---



# Kombinierter Konzept-Graph von Satz 1 und 2



Formale Rekonstruktion des impliziten textuellen Bezugs:  
Konzeptgraph von Satz 1 (gelb) und Konzeptgraph von Satz 2 (grün) werden über die inferierte Rolle (rot) relationiert.

# Stand der Kunst

---

- **Umfassende Dokumentensammlungen:**
  - KIS, EPA, WWW, ...
- **Computerlinguistische Engpässe**
  - unvollständige (manuell erstellte) Lexika, Grammatiken, Domänenmodelle
- **1. Ausweg:**
  - robuste Textanalyse mit unvollständigen Ressourcen
- **2. Ausweg:**
  - automatisches Lernen sprachlichen Wissens (Vervollständigung linguistischer Ressourcen)

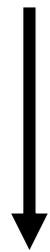
# Zentrale sprachtechnologische Methode: Part-of-Speech (POS) Tagging

---

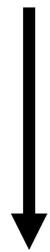
Ausgeprägt multiple Oberschenkelhämatome beidseits .



ADJD



ADJA



NN



ADV



ST

# Was aber bleibt

## (gleich) ...?

---

- Analyse geschriebener Texte
- Fachsprache (IT, Medizin/Biologie)

# Architektur eines Textanalysestests

