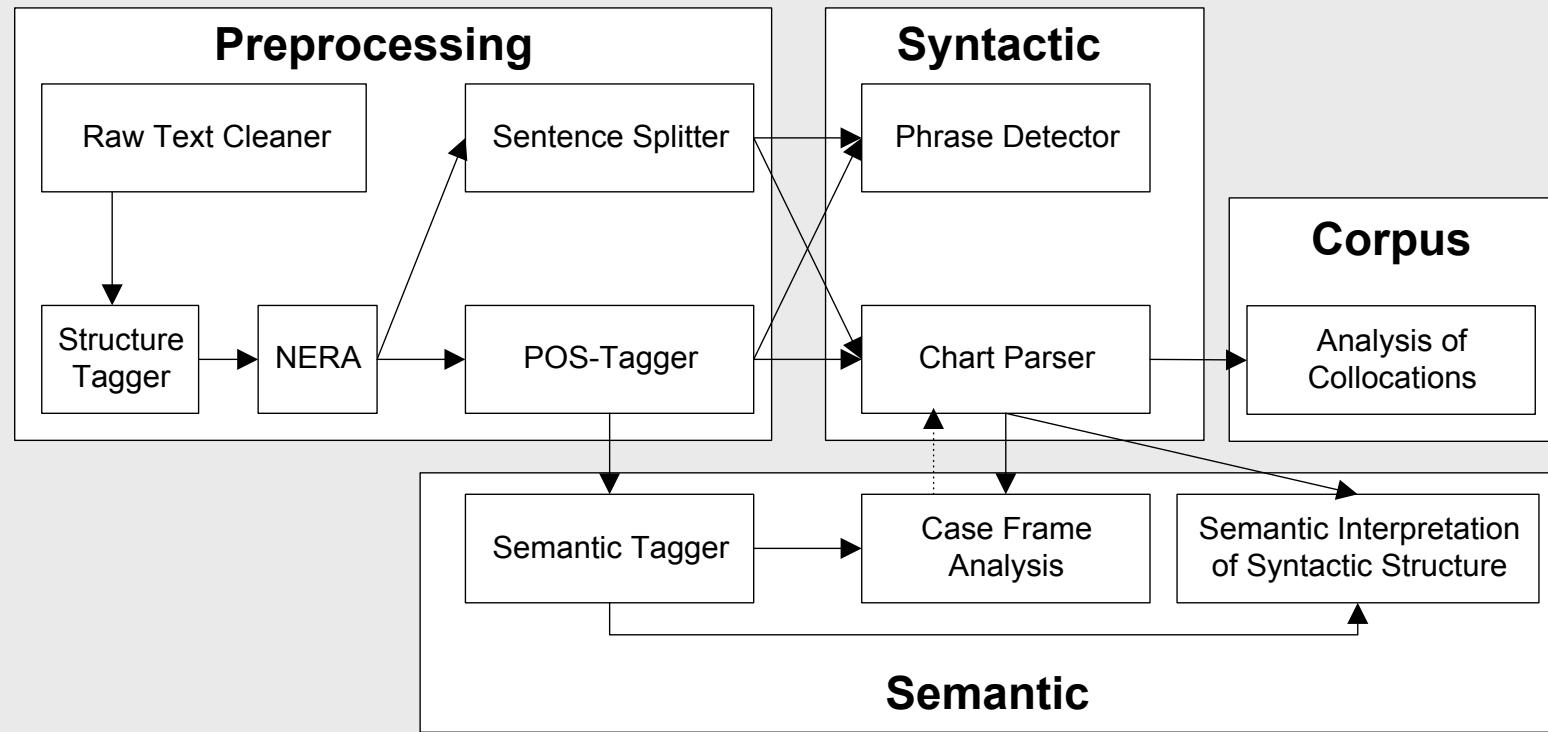


# Processing Medline Abstracts: an Experiment in Resource Integration

Manuela Kunze, Chun Xiao, Dietmar Rösner

Otto-von-Guericke Universität Magdeburg  
Fakultät für Informatik  
Institut für Wissens- und Sprachverarbeitung

# What is XDOC?

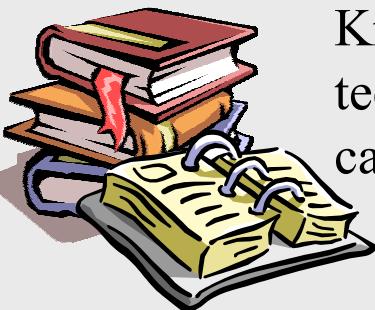


**XDOC:**

*XML* based *DOC*ument processing (for German)

- ▶ inputs, results and resources: *XML* based

# Corpus/Application Scenarios



Knowledge acquisition from technical documentation about casting technology

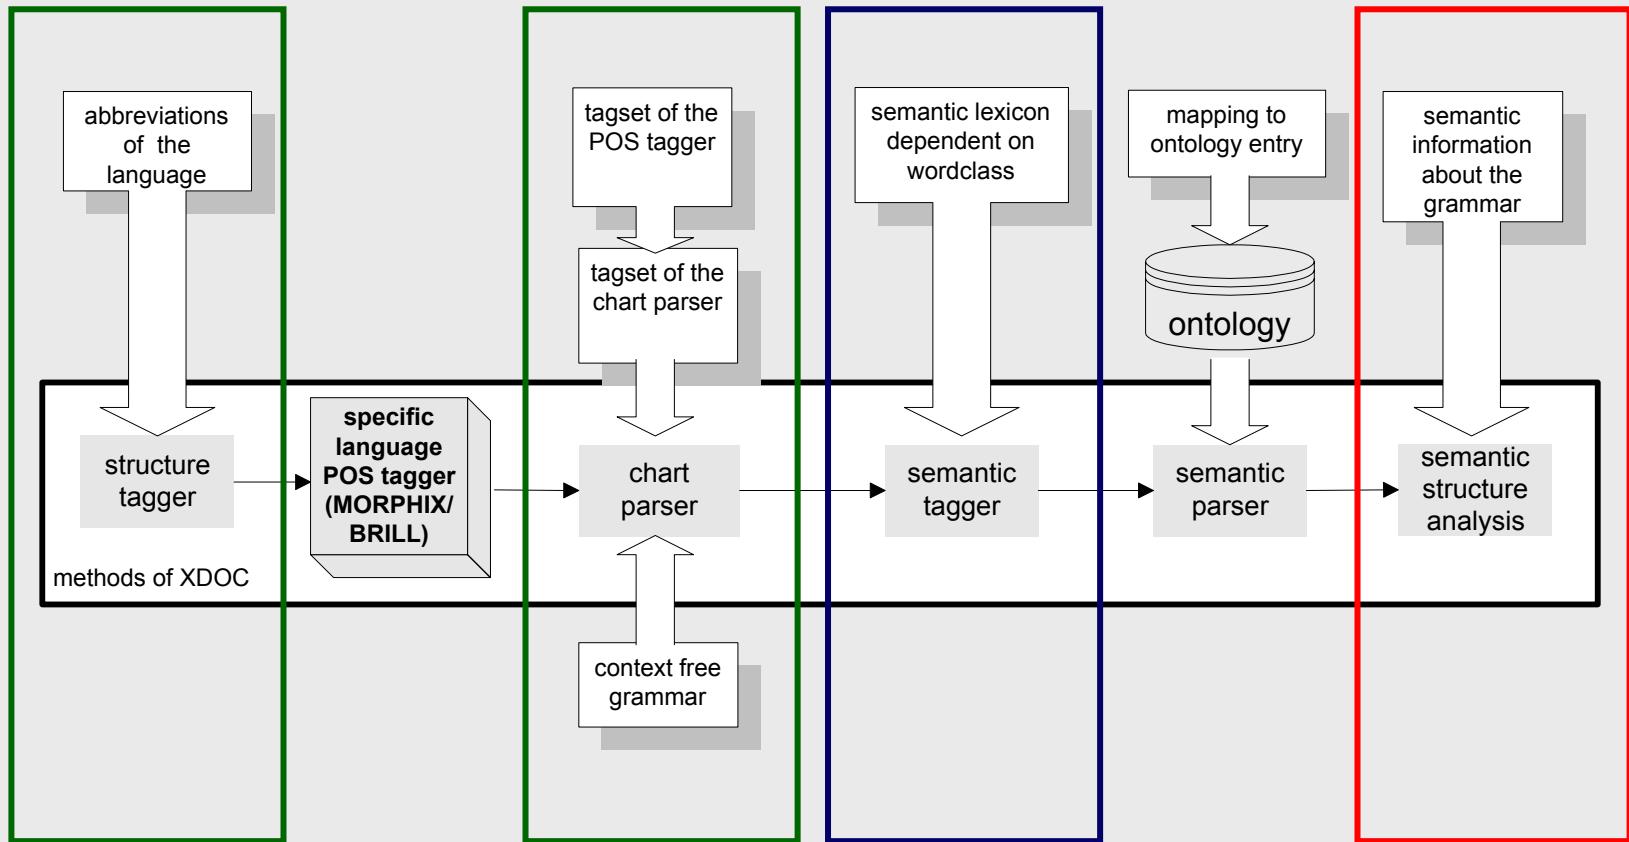
Extraction of company and product profiles from webpages

A screenshot of a web browser window displaying two separate company websites. The top site is 'DIHAG - Deutsche Industrie- und Handelskammer für Bergbau und Metallurgie' with a URL of 'http://www.dihag.de'. The bottom site is 'LÜFTERT' with a URL of 'http://www.luftert.com'. Both sites feature navigation menus, product descriptions, and contact information.

A screenshot of two Microsoft Word documents. The top document is titled 'Leichenöffnungsbericht' and contains a detailed report about a deceased male of approximately 1.50-1.60 m height and 54.6 kg weight, found in a fetal position. The bottom document is titled 'Ku-04.tif [Seitenansicht] - Microsoft Word' and is a statistical summary of autopsy findings. It includes sections for 'Obduktion' (Autopsy) and 'Arzneizellen' (Medicinal substances), listing names like Univ.-Prof. Dr. med. D. Krause and Dr. med. Werner Kellner, and details about findings such as 'Leiche eines 1 Jahre alten Kindes von ca. 1,50 - 1,60 m Körpergröße und 54,6 kg Körpergewicht. Körper aufgestellt regelrecht. Vermischte schlanke/umfangreiche Körperbürtig. Es handelt sich um eine Leiche in verschiedenen Positionen in einer unbestimmten Färbung.' and 'Leiche eines 1 Jahre alten Kindes von ca. 1,50 - 1,60 m Körpergröße und 54,6 kg Körpergewicht. Körper aufgestellt regelrecht. Vermischte schlanke/umfangreiche Körperbürtig. Es handelt sich um eine Leiche in verschiedenen Positionen in einer unbestimmten Färbung.'

Analysis of autopsy protocols for statistical summary about typical injuries at traffic accidents

# XDOC for English



# Semantic Tagger

- classify content words into their semantic categories
- input data: a text tagged with POS tags
  - additional: annotated named entities
- resource: semantic lexicon
  - semantic interpretation of a token
  - information about case frame

# Semantic Tagger

C:\Daten\makunze\paper\diss\doktorandentag\trauma.html - Microsoft Internet Explorer

Datei Bearbeiten Ansicht Favoriten Extras ?  
Zurück Suchen Favoriten Medien Links

ohne Markierungen Knochen Verletzungen Faeulnis

21. Gruenliche Verfaerbung der Weichteile am Hals . Der Ansatz der Kopfwendermuskeln ist **unterblutet** . An der linken Halsseite befindet sich eine etwa waagerecht verlaufende bandfoermige **Unterblutung** der Weichteile von 6 x 1 cm Groesse . Es erfolgt eine schichtweise Praeparation der Halsweichteile . In der Tiefe sind keine **Unterblutungen** mehr erkennbar . 22.  
Schilddriesenlappen unauffaellig . 23. Probe auf Luftbrust negativ . 24. Nach Herausnahme des Brustbeines schwimmt die rechte Lunge auf 120 ml und die linke Lunge auf 70 ml Faeulnisfluessigkeit . 25. Kehlkopfeingang frei .  
Gruenfaerbung der Kehlkopfschleimhaut . Der linke Zungenbeinfortsatz des Schildknorpels ist gebrochen , **Unterblutung** abgrenzbar . 26. Gruenfaerbung der Schleimhaut der Luftroehre . Luftroehre ohne ortsfremden Inhalt . 27.  
Lungenueberzug spiegelnd . 28. Das Lungengewebe ist von gruenlicher Farbe .  
29. Brustteil der grossen Koerperschlagader mit regelrechten Abgaengen .  
Dunkelrote Verfaerbung der Gefaessinnenhaut . 30. **Bruch** des Brustbeines zwischen Ansatz der 4. und der 5. Rippe . Rippen und Wirbelsaeule intakt .

Arbeitsplatz

# Semantic Tagger

Ort	Beteiligte	Ereignis	Verletzung	Zeit
<p>Sektionsergebnis In Schaedelhoehe links laengsverlaufende <b>Platzwunde</b> von bis auf die Schaedelschwarze . Geringgradige lackrote <b>Unterblutung</b> der Schaedelschwarze links und rechts hinten . <b>Bruch</b> des Schaedeldaches mit einer Bruchlinie , bogenfoermig nach oben verlaufend , im Bereich des Hinterhaupes mit einem Auslaeufer in Koerpermittellinie nach oben und vorn , etwa bis in Schaedelhoehe . Weiterer Verlauf der bogenfoermig verlaufenden Bruchlinie nach links und rechts seitlich zur Schaedelbasis , querverlaufend unmittelbar vor den Felsenbeinen . Scharnierartige Beweglichkeit der Bruchstuecken gegeneinander . <b>Zerreissung</b> der Hirnhaeute im Bereich der Schaedelbasis . <b>Durchtrennung</b> des Hirns im Bereich des Ueberganges vom Hirnstamm zum verlaengerten Rueckenmark . Abriss aller Brueckenvenen im Bereich der Hirnmantelkante . Ganz spaerliche <b>Blutung</b> unter die harte Hirnhaut . Zeichen des zentralen Todes und des erheblichen Blutverlustes : Blutaustritt aus beiden auusseren Gehoergaengen bei Eroeffnung der Mittelohren und der Trommelfelle . Akute Erweiterung der Herzhoehlen . In den Herzhoehlen und grossen Gefaessen relativ wenig fluessiges Blut . Spaerliche Totenfleckbildung an der Koerperueckseite . Blaesse und Hervortreten der Eigenfarbe der Organe . Blaesse und akute Ueberblaechung der Lungen . Schlaffe Erweiterung von Hamblase und Enddarm . Schraeg von links oben nach rechts unten verlaufende <b>Schuerfung</b> mit geringgradiger <b>Unterblutung</b> der Weichteile im Bereich der Stirnhaut und Schlaefenregion , links zur Jochbeinregion reichend . Ebensolche Schuerfrichtung im Bereich des Nasenueckens links und der Nasenspitze . Weiterhin ebensolche <b>Schuerfung</b> im Bereich der Unterlippe und an der Rueckseite des linken Ohres . Keine Dehnungsrisse hinter dem linken Ohr feststellbar . Im Bereich der Halswirbelsaeule <b>Unterblutung</b> des vorderen Laengsbandes und Lockerung der Zwischenwirbelscheibe zwischen dem 4. und 5. Halswirbelkoerper . Seitenkantenabriiss und <b>Unterblutung</b> des vorderen Laengsbandes im Bereich des 9. und 10. Brustwirbelkoerpers . Geringgradige <b>Blutung</b> in die Herzmuskulatur im Bereich der linken Vorderwand . Maessige <b>Zerrung</b> im Bereich der Lungenwurzel beiderseits . <b>Zerrung</b> des Lippenbaendchens der Oberlippe und <b>Absplitterung</b> an Anteilen des 1. und 2. Schneidezahnes im Unterkiefer rechts . Im Bereich des Mundbodens querlaufende oberflaechliche <b>Hautabschuerfung</b> mit roetlicher Verfaerbung und <b>Weichteilschwellung</b> mit Betonung der rechten Seite von bis . Schraeg von links oben nach rechts unten verlaufende <b>Schuerfung</b> von x im Mittelbauchbereich rechts . Geringgradige <b>Weichteilblutung</b> im Bereich des rechten Armes . Oberflaechliche <b>Hautabschuerfung</b> an der Streckseite der rechten Hand . <b>Hautabschuerfung</b> und Ablederung vom Fettgewebe ueber der rechten Gesaessbacke . <b>Bruch</b> des Beckenringes rechts des rechten Kreuzbein-Darmbein-Gelenkes . Sprengung des linken Kreuzbein-Darmbein-Gelenkes . <b>Bruch</b> des linken oberen und unteren Schambeinastes neben der Schamfuge . Abriss des Gekroeses des Duenndarmes beim Uebergang auf den Blinddarm auf - und im Bereich des sigmafoermigen Dickdarmes . Kapselzerriissung im Bereich des oberen Poles der <b>Milz</b> bis zur Wurzel . Etwas Blut im Bereich der Bauchhoehle links . Deutliche lackrote <b>Weichteilunterblutung</b> um die Nieren , rechts staerker als links , mit <b>Zerrung</b> der Nierenstiele . An der Aussen- und Rueckseite des rechten Oberschenkels , ueber der rechten Kniestie , ueber dem Innern- und Aussenknoechel des rechten oberen Sprunggelenkes sowie ueber der Streckseite des rechten Fusses oberflaechliche , zumeist rillenfoermige <b>Hautabschuerfungen</b> . An der Innenseite des linken Oberschenkels , ueber der linken Kniestie , ueber dem linken Schiebeinkante innen , an der Rueckseite des linken Unterschenkels und an der Aussenseite des linken Knoechels oberflaechliche <b>Hautabschuerfungen</b> mit teils geringgradigen <b>Unterblutungen</b> der Weichteile . Im unteren Lendenwirbelsaeulenbereich rechts <b>Weichteilunterblutung</b> . Abbruch der Spitze des Dornfortsatzes vom des 8. Brustwirbels . An der Innenseite beider Oberschenkel und unmittelbar unterhalb des Dammes mit Betonung der linken Seite sowie im Bereich des Dammes <b>Hautdefekte</b> und Weichteileimblutungen . II . Chemisch-toxikologische Untersuchungen Die Bestimmung der Ethanolkonzentration erfolgte unter Beruecksichtigung des einschlaegigen Gutachtens des BGA und des Beschlusses des BGH vom 28. Juni und verlief im Oberschenkelvenenblut , Mageninhalt und Urin negativ . Dennoch lag zum Zeitpunkt des Vorfalles keine Alkoholbeeinflussung vor . III . Todesursache Der Tod ist durch akutes zentrales Herz- und Kreislaufversagen bei offener Schaedel-Hirn-Verletzung mit Abtrennung des verlaengerten Halsmarkes vom Hirnstamm eingetreten . IV . Todesart Es handelt sich um eine nichtnatuerliche Todesart . Nach den vorliegenden Anknuepfungstatsachen wird von einem Unfallgeschehen ausgegangen . V . Vorgeschiichte Am dd.mm.jj befuhr Herr X , gegen 19.50 Uhr , mit seinem <b>PKW Opel Frontera</b> , amtliches Kennzeichen ABC-CD xxx , die <b>Bundesstrasse</b> xxx X aus Richtung XX in Richtung YY . Vor ihm befand sich G 3/99 mit seinem <b>Moped Simpson</b> S , um nach links in Richtung YZ abzubiegen . Hierbei kam es zur <b>Kollision</b> in der Form , dass der <b>Opel Frontera</b> von hinten auf das <b>Moped</b> auffuhr . Die Sitzbank verkeilte sich mit dem hinteren Anteil im Frontbereich des <b>PKW</b> . Es kam zu einer Verstaerzung der <b>PKW</b> auf dem Frontstoerleiste und im Bereich des Motorhauses unmittelbar vor dem Windabweiserblech . In</p>				

Dokument: Overmittelt

# Experiment Environment

- corpus: Medline abstracts
  - ca. 500 abstracts
  - ca. 90.000 tokens
- preprocessed
  - tokenizer
  - sentence splitter
  - tagger
    - maximum entropy POS tagger (PennTreebank Tagset++)
    - named entity recognition:
      - substances, enzymes, ...

# Experiment Environment

<ABSTRACT>

...

```
<SENTENCE><DT>The</DT> <JJ>nuclear</JJ>
<NOUN>enzyme~~enzyme</NOUN> <NOUN>poly(ADP-
ribose)polymerase~~enzymeB</NOUN> <LPAR>(</LPAR>
<NOUN>PARP~~enzyme</NOUN> <RPAR>)</RPAR> <VBZ STEM =
"be">is</VBZ> <RB>also</RB> <VBN STEM = "cleave">cleaved</VBN>
<IN>upon</IN> <DT>the</DT> <NOUN>activation</NOUN> <IN>of</IN>
<NOUN>caspases~~enzyme</NOUN> <CMA>, </CMA> <CC>and</CC>
<NOUN>IETD~~substance</NOUN> <RB>similarly</RB> <VBZ STEM =
"prevent">prevents</VBZ> <NOUN>PARP~~enzyme</NOUN>
<NOUN>cleavage</NOUN> <SEPR>.</SEPR></SENTENCE>
...
</ABSTRACT>
```

# Idea

- use external resources: Wordnet
  - lexical database
  - lexical relations, e.g. synonym, antonym
  - conceptual relations, e.g. hypernym, holonym, meronym

	Wordnet (1.7)
Noun	74488
Verb	12754
Adjective	18523
Adverb	3612
Total:	109377

# Import of a Tagset

```
<WORDCLASS>
  <XDOC>*noun*</XDOC>
  <GERMAN>
    <TAG casus="cas" genus="gen"
numerus="num">N</TAG>
  </GERMAN>
  <ENGLISH>
    <TAG
numerus="SINGULAR">NOUN</TAG>
    <TAG
numerus="PLURAL">NOUNS</TAG>
  </ENGLISH>
</WORDCLASS>
```

```
<WORDCLASS>
  <XDOC>*special*</XDOC>
  <GERMAN>
    <TAG>NE</TAG>
  </GERMAN>
  <ENGLISH>
    <TAG>SUBSTANCE</TAG>
    <TAG>ENZYME</TAG>
    <TAG>ENZYMEA</TAG>
    <TAG>ENZYMEB</TAG>
    ...
    </ENGLISH>
  </WORDCLASS>
  ...
```

# Import of a Tagset

Generic Tags	German	English
*noun*	N	NOUN, NOUNS
*verb*	V	VB, VBN, VBZ, VBD, VBG, VBP
*adverb*	ADV	RB, RBS, RBR
*adjective*	ADJ	JJ, JJR, JJS, JJSS
*special*	NE	SUBSTANCE, ENZYME, ENZYMEA, ENZYMEB, ...

# Results

package, package : ~~THIS MOVE~~ hypothesis, possibility, theory kind, sort, form, variety assistant, helper, help, supporter representation ideal  
eader representation, mental representation, internal representation assistant, helper, help, supporter representation is distinct chiseled,  
well-defined different (vs. same) separate (vs. joint) definite (vs. indefinite) clear (vs. unclear) from one proposed declare plan intend,  
nean, think choose, take, select, pick out request for the related accompanying, attendant, concomitant, incidental, incidental to(predicate)  
affinal similar (vs. dissimilar) relevant (vs. irrelevant) bacterium microorganism Klebsiella enteric bacteria, enterobacteria, enterics  
pneumoniae , in which unmodified unadapted GlnK SUBSTANCE relieves NifL SUBSTANCE inhibition abstinence restraint, control  
organic process, biological process action instead of stimulating arouse, elicit, enkindle, kindle, evoke, fire, raise, provoke affect effect,  
effectuate, bring about, set up sensitize, sensitise challenge it . Streptococcus eubacteria, eubacterium, true bacteria salivarius is a  
actose- and galactose-positive bacterium microorganism that is phylogenetically phylogenetic, phyletic closely close (vs. distant)  
close (vs. distant) close related think, cogitate, cerebrate tell, narrate, recount, spin, recite be interact associate, tie in, relate, link, colligate,  
link up, connect to Streptococcus eubacteria, eubacterium, true bacteria thermophilus , a bacterium microorganism that metabolizes  
actose but not galactose . In this paper material, stuff essay press, public press article medium publisher, publishing house, publishing  
we report

# Results

and single particle analysis indicated that complex I maintains this structure in detergent solution and does not adopt a different conformation in the active state. Thus, we provide the first experimental evidence that complex I from E. coli has an L-shape in a lipid bilayer and confirm that this is also the case for the active enzyme in solution. This suggests strongly that bacterial complex I exists in an L-shaped conformation in vivo. Our results also indicate that native lipids play an important role in the activation, stabilization and, as a consequence, crystallization of purified complex I from E. coli. The product of oxygenation of arachidonic acid by the prostaglandin H synthases (PGHS), prostaglandin (PG) H<sub>2</sub>, undergoes rearrangement to the highly reactive g-ketoaldehydes, levuglandin (LG) E<sub>2</sub> and LGD<sub>2</sub>. We previously have demonstrated that LG E<sub>2</sub> reacts with the e-amine of lysine to form both the levuglandinyl-lysine Schiff base and the pyrrole-derived levuglandinyl-lysine lactam adducts. We also have reported that these levuglandinyl-lysine adducts are formed on purified PGHSs following the oxygenation of arachidonic acid. We now present evidence that the levuglandinyl-lysine lactam adduct is formed in human platelets upon activation with exogenous arachidonic acid or thrombin. After proteolytic digestion of the platelet proteins, and isolation of the adducted amino acid residues, this adduct was identified by liquid chromatography-tandem mass spectrometry. We also demonstrate that formation of these adducts is inhibited by indomethacin, a PGHS inhibitor, and is enhanced by an inhibitor of thromboxane synthase. These data establish that levuglandinyl-lysine adducts are formed via a PGHS-dependent pathway in whole cells, even in the presence of an enzyme that metabolizes PGH<sub>2</sub>. They also demonstrate that a physiological stimulus is sufficient to lead to the lipid modification of proteins through the levuglandin pathway in human platelets. Yeast cytosine deaminase is an attractive candidate for anticancer gene therapy because of its catalysis of the deamination of the prodrug 5-fluorocytosine to form 5-fluorouracil. We cannot know the crystal structure of the enzyme in complex with the inhibitor 2-hydroxyimidazidine at 1.6

# Results: Matches in Wordnet

	total	WordNet
Nouns	32211	23955
Verb	11160	5716
Adjective	9710	6618
Adverb	2528	1581
total:	55609	37870

- not tested: 41172

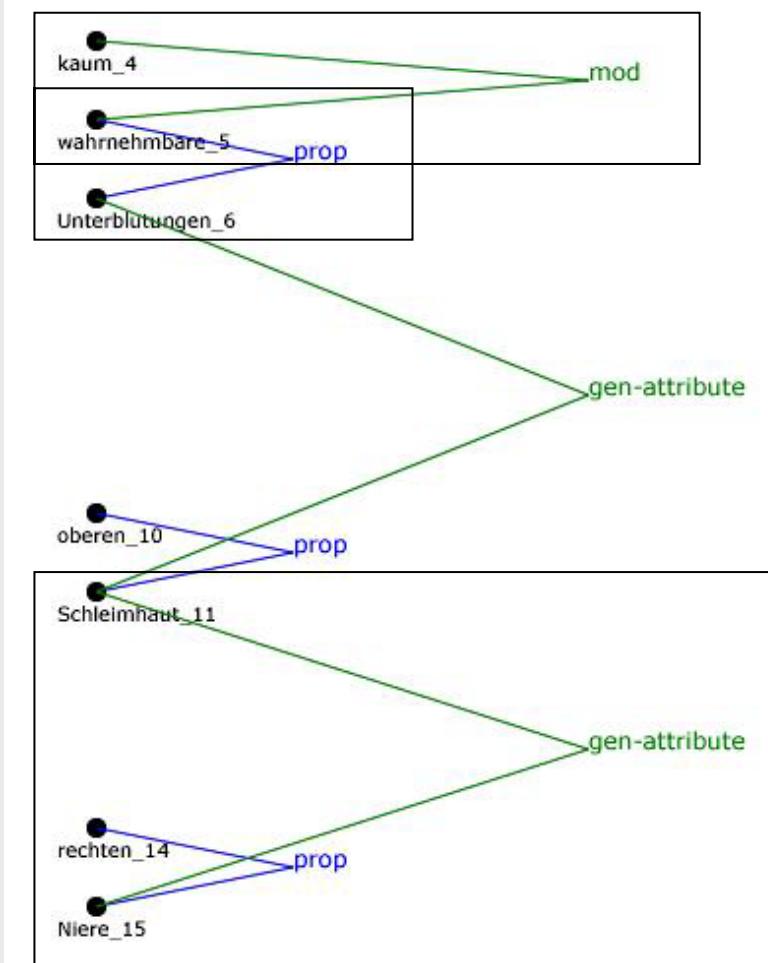
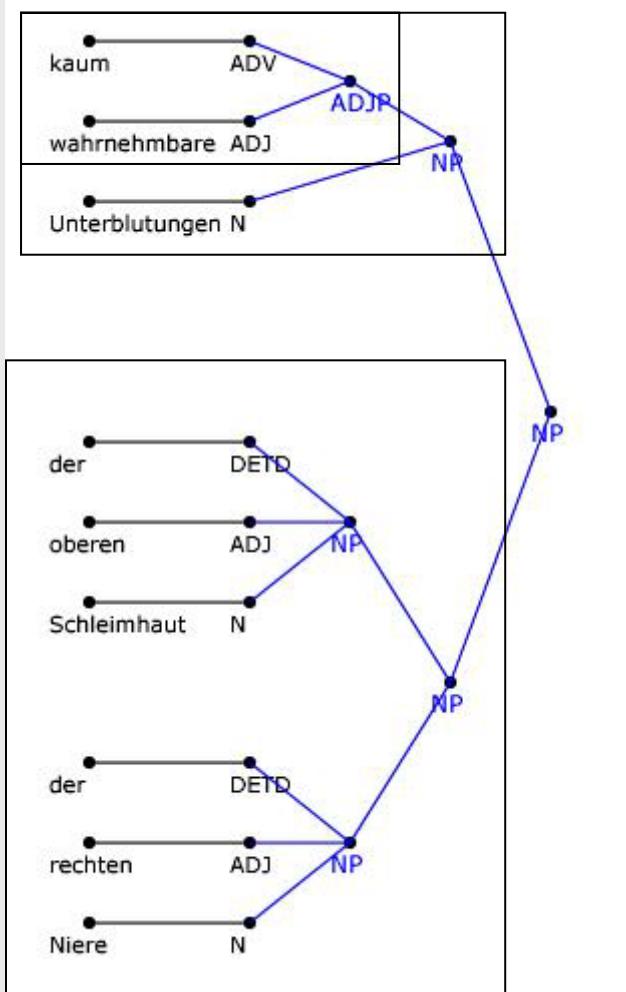
# Discussion

- processing Medline abstracts
  - coverage > 50%
- problems
  - errors by preprocessing
    - POS tagger
    - tokenizer
  - input data: not XML conform
    - elements like ... „sandwich“... or ... >1,5 mol ...

# Next Steps: SIsS

- evaluation of SIsS
- SIsS: Semantic Interpretation of syntactic Structures
- approach:
  - input data: parsed syntactic structures
  - search for predefined structures (grammar rule)
  - semantic analysis of this structure
- resource:
  - mapping of grammar rules to an interpretation
    - core of a rule
    - attributes for the core

# SIsS: from Syntactic to Semantic



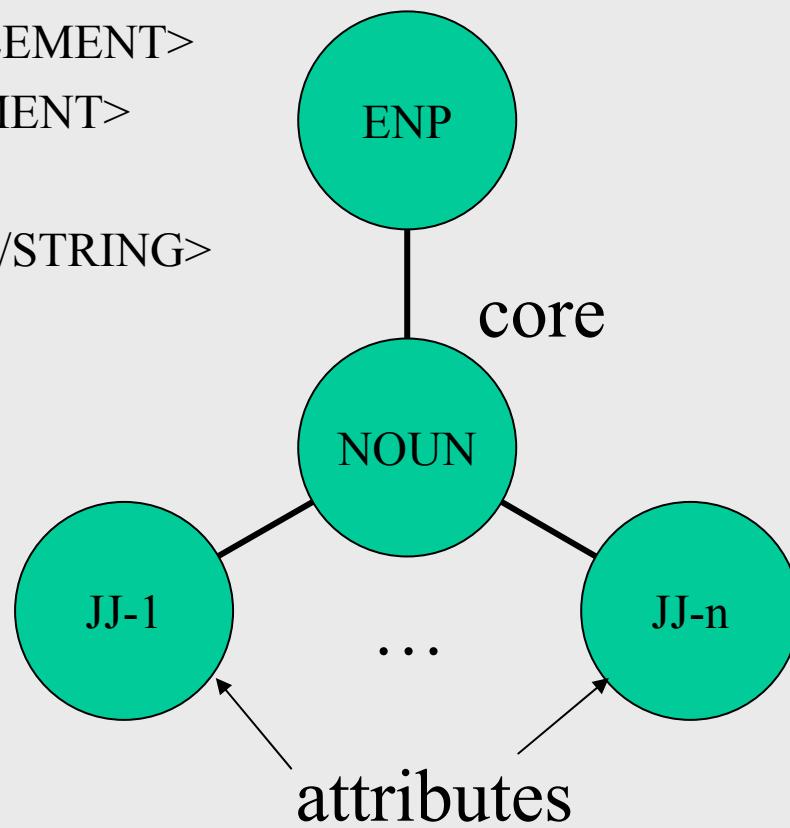
in English: hardly detected bleedings of upper mucous membrane of right kidney

# SIsS for English

- example:

```
<RULE RULE-CAT="ENP" RULE="NP2">  
    <ELEMENT>DT</ELEMENT>  
    <ELEMENT OP="*">JJ</ELEMENT>  
    <ELEMENT>NOUN</ELEMENT>  
    <EXAMPLE>  
        <STRING>the pretty girl</STRING>  
    </EXAMPLE>  
</RULE>
```

NP2 → DT JJ\* NOUN

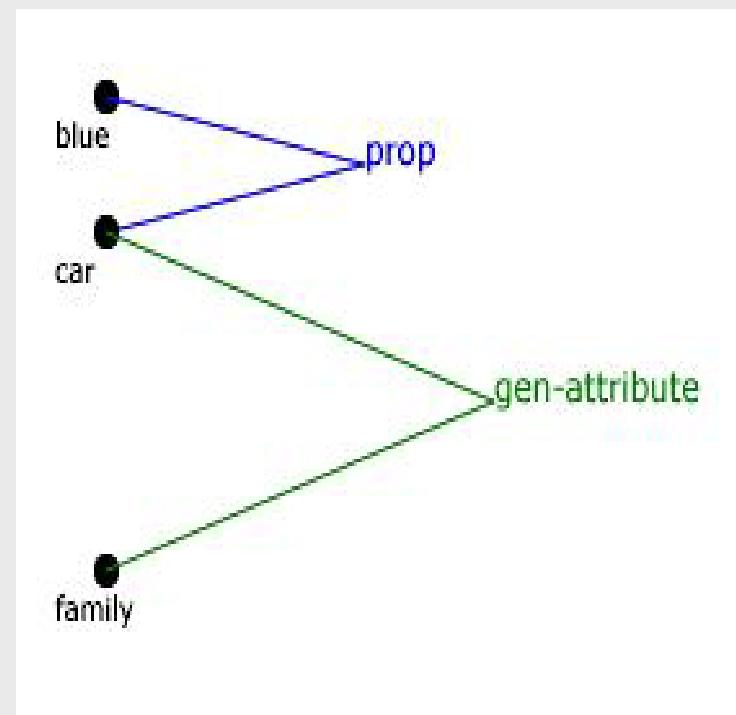
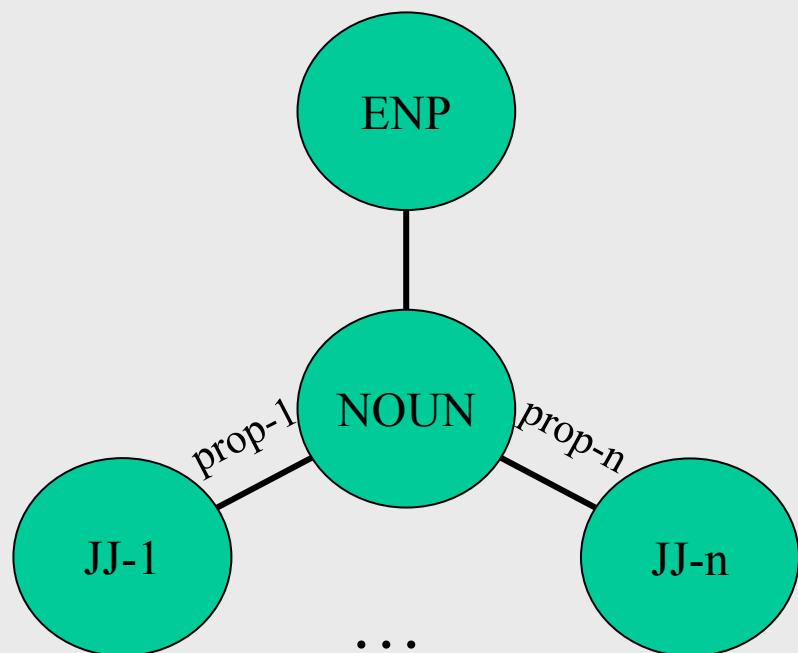


# SIsS: Resources

- wordclasses:
  - concepts: NOUN, NOUNS, JJ, JJS
  - relations:
    - JJ, JJS: property
    - RB, ...: modicator
- grammar rules:
  - NP2: NOUN (core)  
or
  - NP34: NP (core), relation: ,genitive-attribute‘  
 $\text{NP34} \rightarrow \text{NP PP (of)}$

# SIsS: Results

results:  $\text{prop-1}(\text{JJ-1}, \text{NOUN})$ , ...,  $\text{prop-n}(\text{JJ-n}, \text{NOUN})$



example: the blue car of the family ...

# Future Work

- SIsS:
  - use of WordNet's holonym and meronym relation for resolving of ‚genitive-attribute‘ relation
- Semantic Parser:
  - use of WordNet's verb frames for ‚shallow‘ case frame analysis
  - on the base of semantic fields

# Questions ?