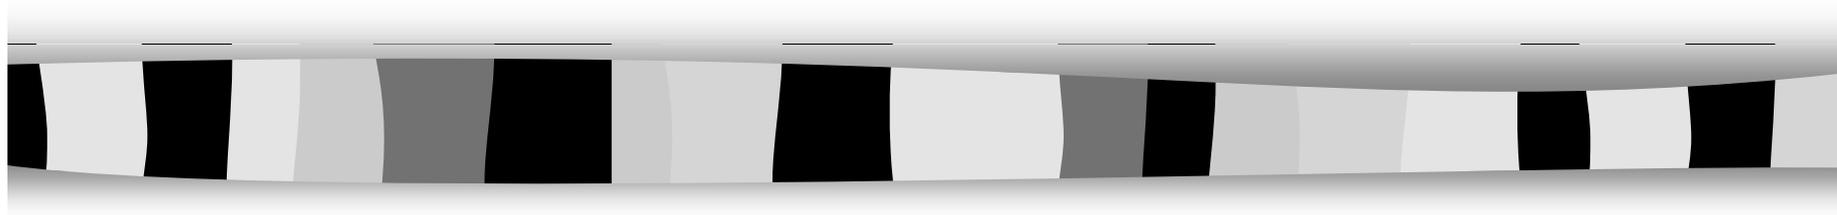
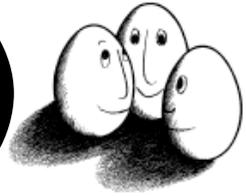


# Information



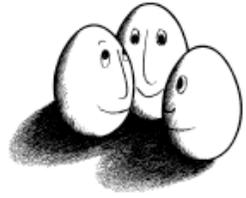
# Extraction

# Information Extraction (IE)



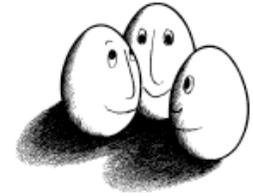
- Extraktion von strukturierten Informationen aus textuellen Dokumenten
- Textart:
  - beliebig, unbekannt
  - natürlichsprachlich
- Suche nach zuvor festgelegten Informationen
- Weiterverarbeitung: direkte Darstellung, Datenbank, Tabellenkalkulation
- **Ziel:** Entwicklung von Systemen, die spezielle Informationen aus freien Texten aufspüren und strukturieren können

# Information Retrieval (IR)



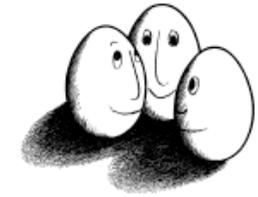
- Dokumente aus Dokumentensammlung auswählen
- Benutzeranfrage durch Stichwörter
- Ergebnis: geordnete Menge relevanter Dokumente

# Szenario



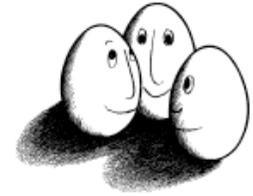
- Benutzer sucht Informationen über Aktienkurse von Firmen mit Besitz in Bolivien
- Daten sollen in einer Tabellenkalkulation weiterverarbeitet werden

# IR vs. IE



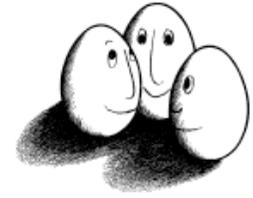
- IR-Systeme finden Texte und präsentieren sie dem Benutzer.
- Vorgehen:
  - Eingabe einer Liste von relevanten Suchbegriffen ins System.
  - Rückgabe: Menge von Dokumenten, die ähnliche Begriffe enthalten.
  - Benutzer entscheidet selbst, welche Texte relevant sind, und übernimmt die Weiterverarbeitung.

# IR vs. IE



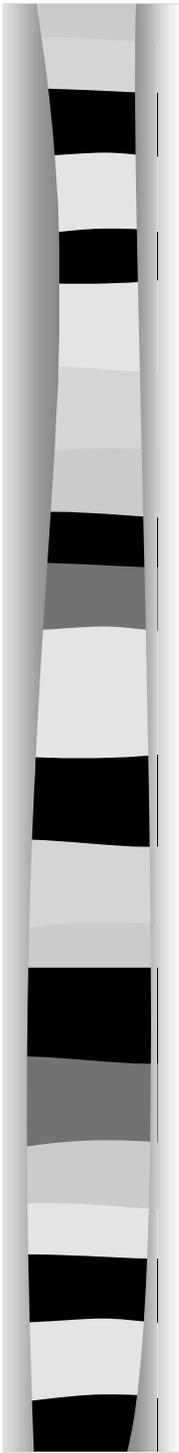
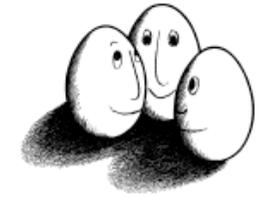
- IE-Systeme analysieren Texte und präsentieren nur die spezifischen Informationen
- Vorgehen:
  - IE-System füllt die Datenbank oder Tabellenkalkulation selbstständig mit den Namen der Firmen und deren Aktienkursen

# Vor- & Nachteile

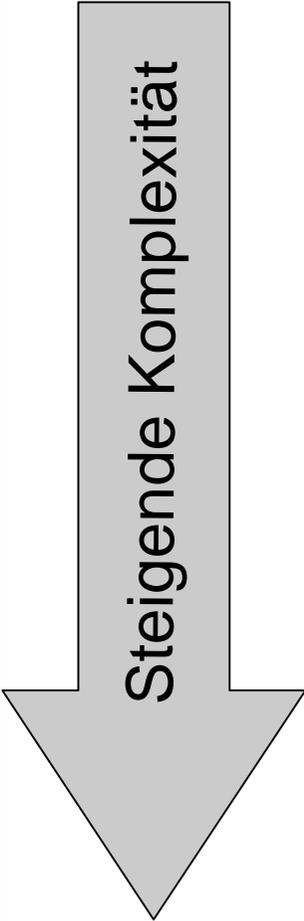


- IE Systeme sind aufwendig und wissensintensiv
- In der Regel muss das System an verschiedene Bereiche und Szenarien angepasst werden
- IE ist rechenintensiver als IR
- Zeitersparnis durch IE, lesen der Ergebnistexte entfällt

# IE Typen

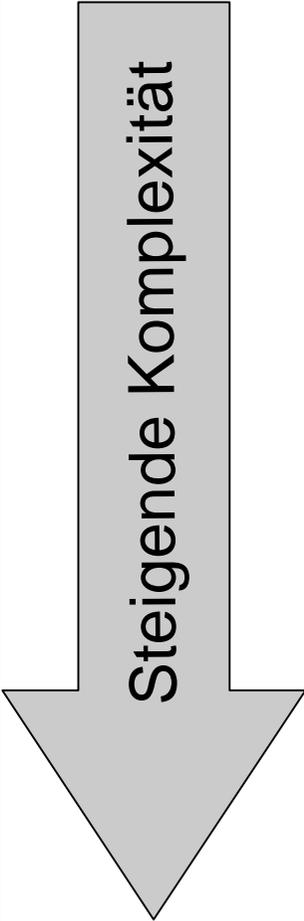
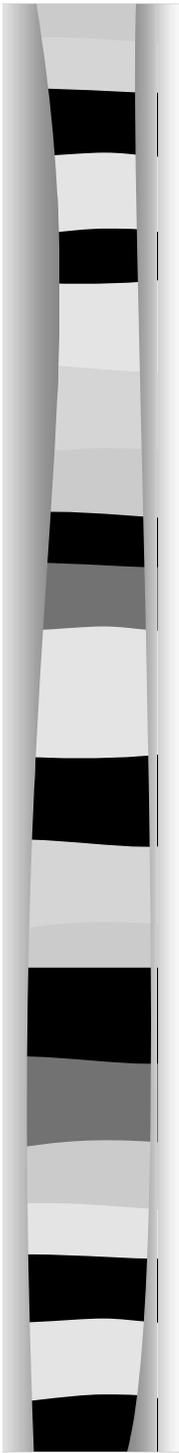
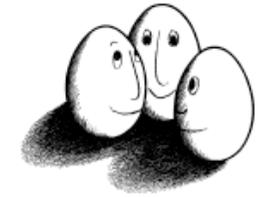


Steigende Komplexität



- Named Entity recognition (NE)  
Finden und Klassifizieren von Namen  
Heuristik: Name bezieht sich auf etwas Bestimmtes (Einzelding)
- Coreference Resolution (CO)  
Identifiziert Referenzen zwischen den NE-Objekten
- Template Element construction (TE)  
Fügt beschreibende Informationen zu NE Ergebnissen hinzu

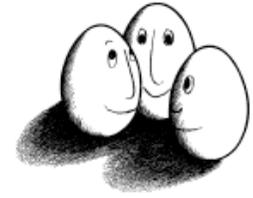
# IE Typen



Steigende Komplexität

- Template Relation construction (TR)  
Erkennt Beziehungen zu den NE Ergebnissen
- Senario Template production (ST)  
Setzt TE und TR Ergebnisse in spezielle Ereignis-Szenario

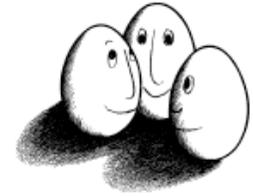
# Anwendungsbeispiel



Die glänzend rote Rakete wurde am Dienstag gestartet. Sie ist die Erfindung von Dr. Hans Müller. Dr. Müller ist ein Wissenschaftler bei Raketenerwerke Inc.

- NE: z.B.: Rakete, Dienstag, Dr. Müller (Entities)
- CO: „Sie“ bezieht sich auf Rakete

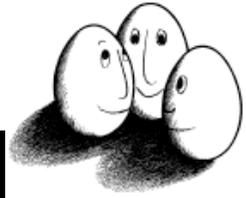
# Anwendungsbeispiel



Die glänzend rote Rakete wurde am Dienstag gestartet. Sie ist die Erfindung von Dr. Hans Müller. Dr. Müller ist ein Wissenschaftler bei Raketenerwerke Inc.

- TE: Rocket = glänzend rot Erfindung von Dr. Müller
- TR: Müller arbeitet für Raketenerwerke Inc.

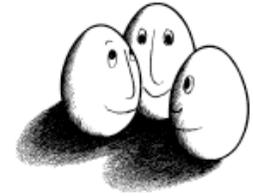
# Anwendungsbeispiel



Die glänzend rote Rakete wurde am Dienstag gestartet. Sie ist die Erfindung von Dr. Hans Müller. Dr. Müller ist ein Wissenschaftler bei Raketenerwerke Inc.

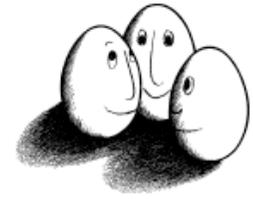
- ST: Raketenstart ist Ereignis, in welches die verschiedenen Entities verwickelt waren

# MUC



- **M**essage **U**nderstanding **C**onference (1-7)
- **M**essage **U**nderstanding **C**ompetition
- Gegründet bei DARPA Ende der 80'iger

# Evaluationskriterien für IE

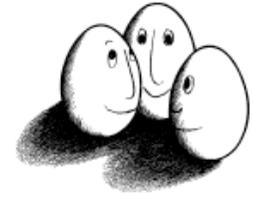


- Evaluation von IE-Systemen auf der MUC
- Präzision  $P$  = Anteil der korrekt gewonnenen Wissensseinheiten  $WE$

	relevante Texte	irrelevante Texte
ausgegebene Texte	A	B
nicht ausgegebene Texte	C	D

$$P = \frac{A}{A + B}$$

# Evaluationskriterien für IE

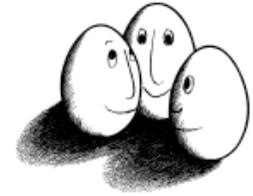


- $P_{\eta}$  = fast alle gefundenen WE sind relevant
- Vollständigkeit  $V$  = Anteil der korrekt gewonnenen WE gegenüber allen WE

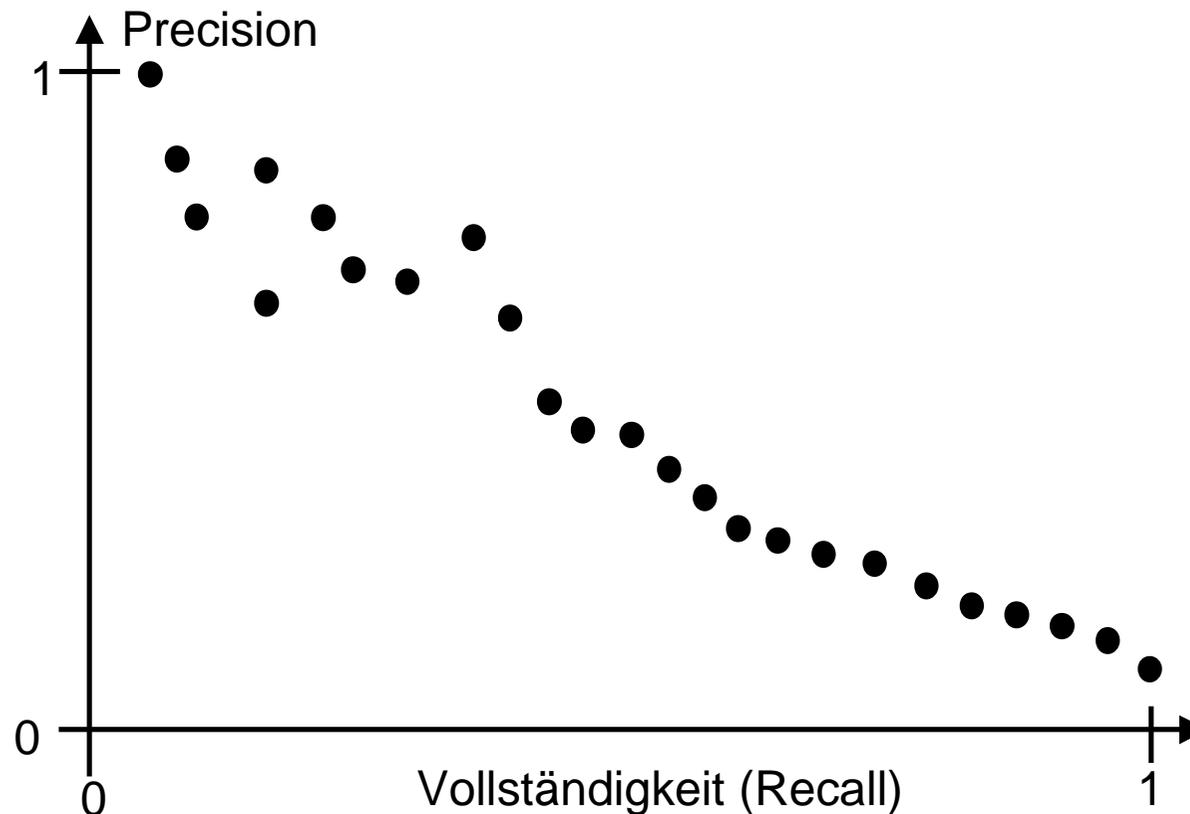
	relevante Texte	irrelevante Texte
ausgegebene Texte	A	B
nicht ausgegebene Texte	C	D

$$V = \frac{A}{A + C}$$

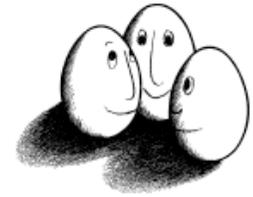
# Precision-Recall-Diagramm



- Maße sind gegenläufig  $\rightarrow$  Bei guter Vollständigkeit ergibt sich eine geringe Präzision und umgekehrt



# Evaluationskriterien für IE

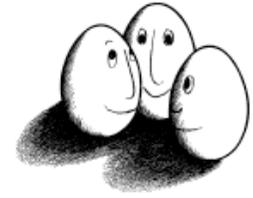


- Optimierung bezüglich hoher Präzision:  
Relevante WE werden möglicherweise nicht erkannt
- Optimierung bezüglich hoher Vollständigkeit:  
Aufnahme von irrelevanten WE
- F-Maß gibt die Güte des IE-Prozesses an

$$F = \frac{(\beta^2 + 1, 0) * P * V}{(\beta^2 * P) + V} \quad \text{In der Regel } \beta = 1$$

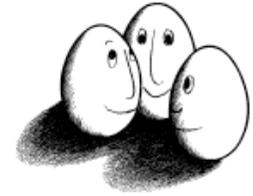
- Abweichung von 1 gibt an ob:  
P oder V stärker gewichtet werden sollte

# Dokument Views



- Terms View
- Mark-Up View
- Layout View
- Typographic View
- Linguistic View

# Seminaranmeldung Beispiel



<0.21.3.95.14.12.11.ed47+@andrew.cmu.edu.0>  
Type: cmu.andrew.official.cmu-news  
Topic: ECE Seminar  
Dates: 30-Mar-95  
Time: 4:00 - 5:00 PM  
Place: Scaife Hall Auditorium  
PostedBy: Edmund J. Delaney on 21-Mar-95 at 14:12 from andrew.cmu.edu  
Abstract:

COMPUTERIZED TESTING AND SIMULATION OF CONCRETE CONSTRUCTION

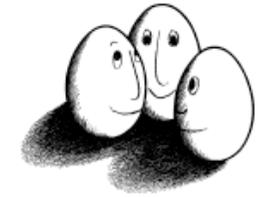
FARRO F. RADJY, PH.D.

President and Founder  
Digital Site Systems, Inc.  
Pittsburgh, PA

DATE: Thursday, March 30, 1995  
TIME: 4:00 - 5:00 P.M.  
PLACE: Scaife Hall Auditorium  
REFRESHMENTS at 3:45 P.M.

-----

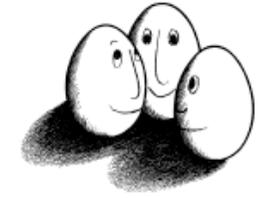
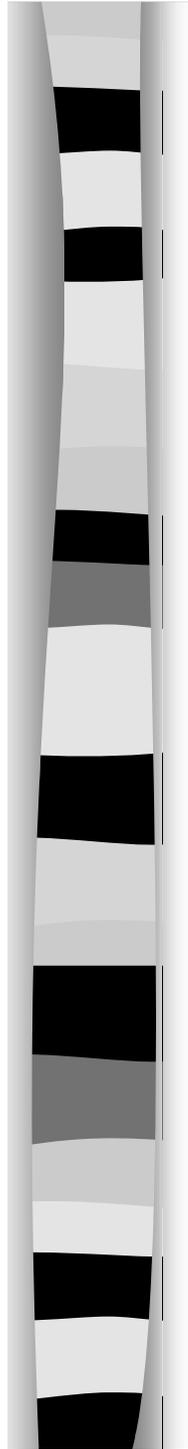
# Terms View



1	1	3	2	2	4	1	1	1	...	...	...	...	term frequency
abstract	and	andrew	at	auditorium	cmu	computerized	concrete	construction	...	...	...	...	

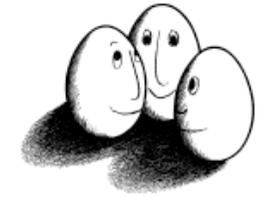
Inverse document frequency:

4	n	3	n	2	1	2	1	1	...	...	...	...	n/doc
abstract	and	andrew	at	auditorium	cmu	computerized	concrete	construction	...	...	...	...	



# Mark-Up View

- Betrachtung von Terms und Metaterms
- Metaterms geben „Rolleninformationen“ über verschiedenen Terms



# Mark-Up View Beispiel

```
<html>
<head>
<title>Dayne Freitag's Home Page</title>
</head>

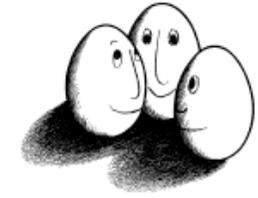
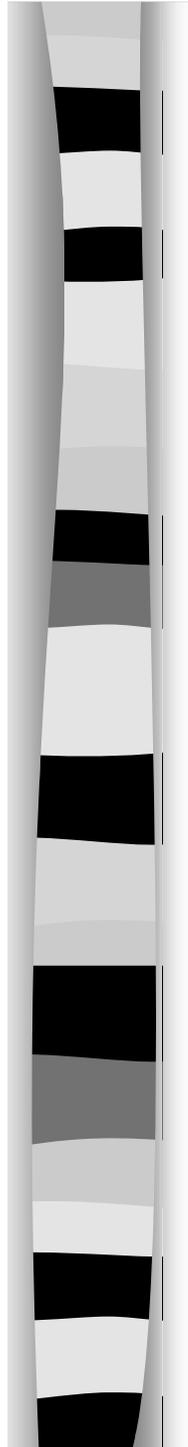
<body bgcolor="#FFFFFF">

<center><h2>Dayne Freitag</h2>
<hr>
<h3><font face="Helvetica">Contents</font></h3></center>

<center>

<table>

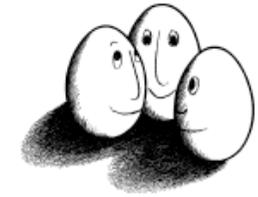
<tr><td>
<font face="Courier">
Introduction.....
<a href="intro.html"><i>intro.html</a>
</font>
```



# Layout View

- LV betrachtet die 2-dimensional Anordnung und Größe von Terms
- Vorgehen: Alle non-whitespace characters werden durch Sterne (\*) ersetzt
- Ziel: Erkennung von wichtigen Textobjekte, z. B. Paragraphen Überschriften, Mail headers, usw.

# Layout View Beispiel



```
*****
*****
*****
*****
*****
*****
*****
*****
*****
*****
*****
*****
```

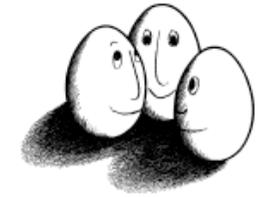
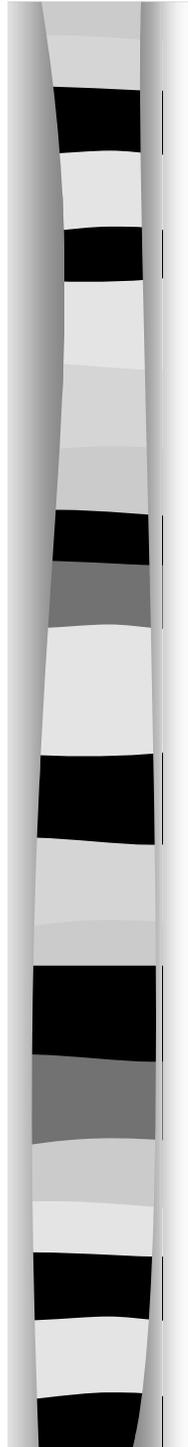
```
*****
```

```
*****
```

```
*****
*****
*****
*****
*****
```

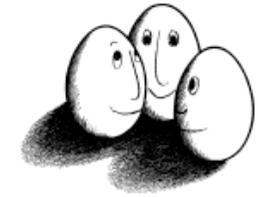
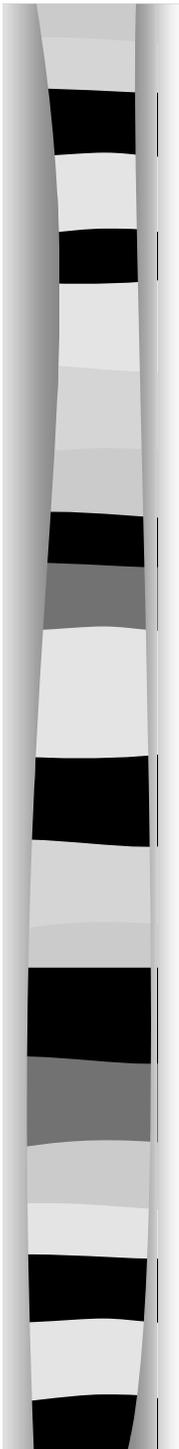
```
*****
*****
*****
*****
*****
```

```
*****
```



# Typographic View

- Zeichen werden in folgende Klassen eingeteilt:
  - Numerische
  - Zeichensetzung
  - Großbuchstaben
- Zahlen ersetzt durch „9“
- Zeichensetzung keine Änderung
- Großbuchstaben ersetzt durch „A“ sonstige Buchstaben durch „a“
- Ziel: Relevante Stellen lokalisieren



# Typographic View Beispiel

```

<9.99.9.99.99.99.99.aa99+@aaaaaa.aaa.aaa.9>
Aaaa:      aaa.aaaaaa.aaaaaaa.aaa-aaaa
Aaaaa:     AAA Aaaaaaa
Aaaaa:     99-Aaa-99
Aaaa:      9:99 - 9:99 AA
Aaaaa:     Aaaaaa Aaaa Aaaaaaaaaa
AaaaaaAa:  Aaaaaa A. Aaaaaaa aa 99-Aaa-99 aa 99:99 aaaa aaaaaa.aaa.aaa
Aaaaaaaa:

```

```

AAAAAAAAAAAA AAAAAAA AAA AAAAAAAAAA AA AAAAAAA AAAAAAAAAAAAA

```

```

AAAAA A. AAAAA, AA.A.

```

```

Aaaaaaaaaaaa aaa Aaaaaaa
Aaaaaaa Aaaa Aaaaaaa, Aaa.
Aaaaaaaaaaaa, AA

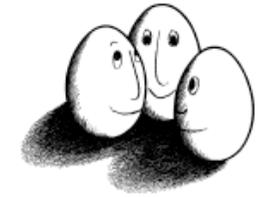
```

```

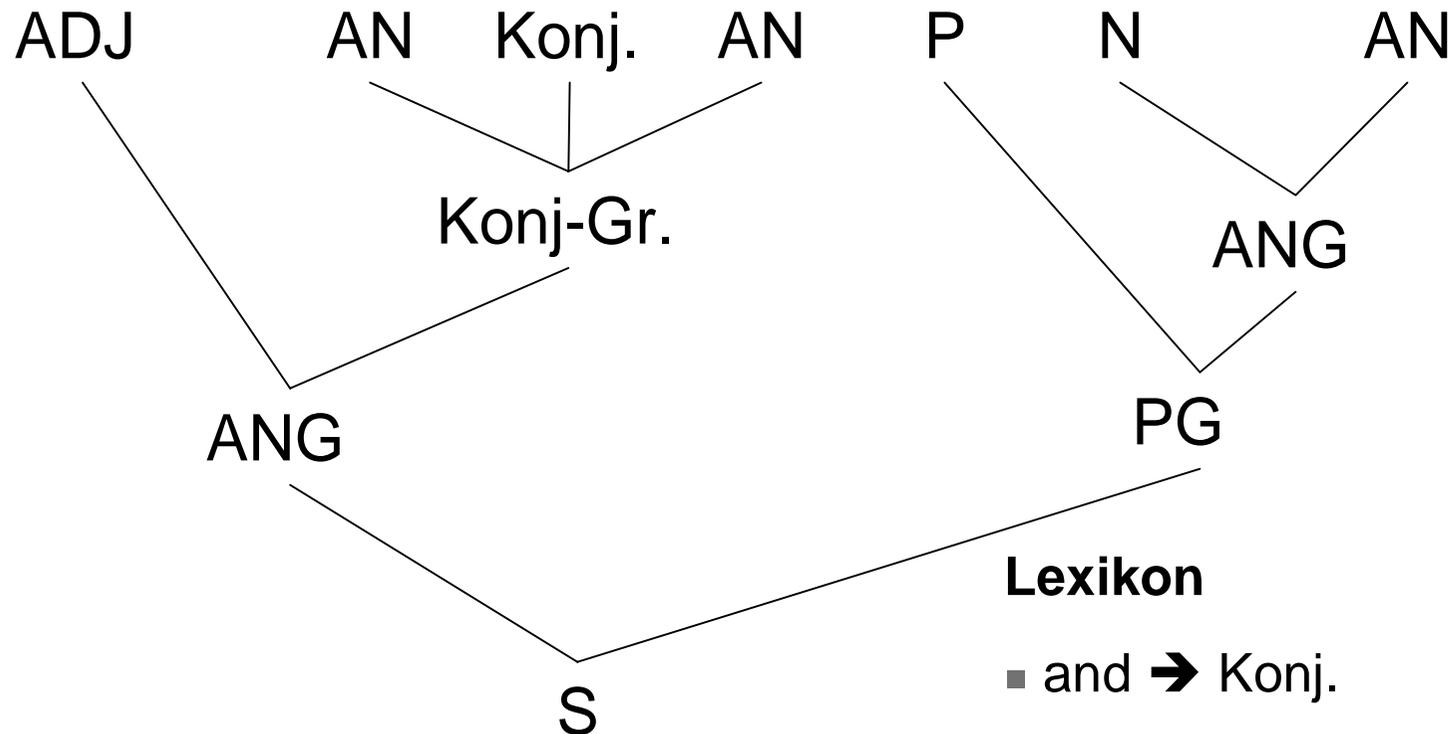
AAAA:  Aaaaaaaaa, Aaaaa 99, 9999
AAAA:  9:99 - 9:99 A.A.
AAAAA:  Aaaaaa Aaaa Aaaaaaaaaa
AAAAAAAAAAAA aa 9:99 A.A.

```

# Linguistic View Beispiel



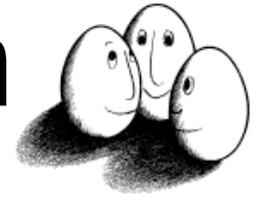
computerized testing and simulation of concrete constructic



## Lexikon

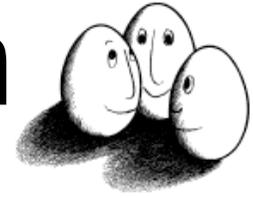
- and → Konj.
- computerized → ADJ
- of → P
- testing → AN

# Maschinelles Lernverfahren für IE



- Standard IE-Systeme sind sehr domainspezifisch:
  - Anpassung ist sehr aufwendig und muss von Experten durchgeführt werden
- **Ziel:** System, dass auf verschiedenen Domains angewendet werden kann
- **Besser:** Ausgehend von einer Trainingsmenge von bereits mit Ergebnissen versehenen Textdokumenten werden automatisch Regeln zum Füllen von Templates abgeleitet

# Maschinelles Lernverfahren für IE Beispiel



- Annotiertes Trainingsbeispiel:

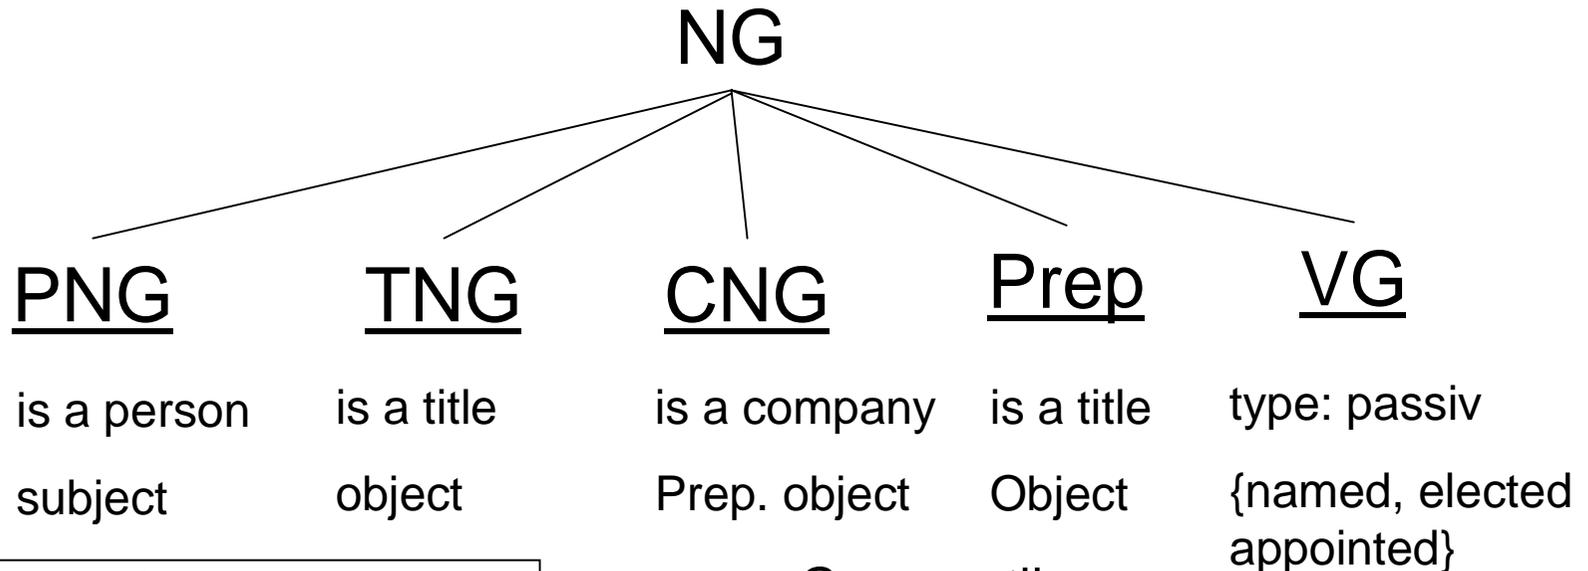
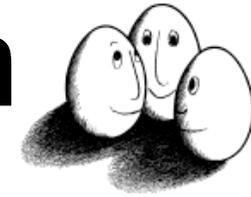
<PNG>Sue Smith</PNG>, 39, of Menlo Park, was appointed  
<TNG> president </TNG> of <CNG> Foo Inc. </CNG>

- Abgeleitete Template-Regel:

Noun-group(PNG, head(isa(person))), noun-group(TNG,  
head(isa(title))), noun-group(CNG, head(isa(company))), prep,  
head(of OR at OR by)), verb-group(VG, type(passiv),  
head(named OR elected OR appointed)), subject(PNG, VG),  
object(VG, TNG), post-nominal-prep(TNG, PREP), prep-  
obj(PREP, CNG)

→ management-appointment(person(PNG), title(TNG),  
company(CNG))

# Maschinelles Lernverfahren für IE Beispiel



appointment  
 Person: PNG  
 Title: TNG  
 Company: CNG

Grammatik  
 S → NG, VG  
 VG → V, TNG  
 TNG → T, Prep  
 Prep → Prep,  
 CNG

Object  
Lexikon  
 ... Is a person