

# Einführung in die Computerlinguistik

## Statistische Modellierung (+ Nachtrag Merkmalsstrukturen)

WS 2009/2010

Manfred Pinkal

## Grammatische Merkmale

- Wie finden Sie **die** angehängten Bilder? Das **sind** Fotos, **die** im Rahmen des TALK-Projektes entstanden **sind**, uns gehören, und von BMW schon freigegeben **waren**. Außerdem vermitteln **sie** besser den Bezug zur Forschung.

## Explizite Kodierung von Merkmalen

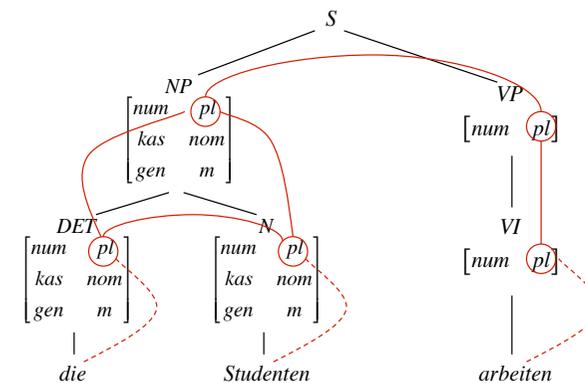
$$S \rightarrow NP \begin{bmatrix} num & sg \\ kas & nom \end{bmatrix} VP[num \ sg] \quad S \rightarrow NP \begin{bmatrix} num & pl \\ kas & nom \end{bmatrix} VP[num \ pl]$$

$$VP[num \ sg] \rightarrow VI[num \ sg] \quad VP[num \ pl] \rightarrow VI[num \ pl]$$

$$NP \begin{bmatrix} num & sg \\ kas & nom \\ gen & m \end{bmatrix} \rightarrow Det \begin{bmatrix} num & sg \\ kas & nom \\ gen & m \end{bmatrix} N \begin{bmatrix} num & sg \\ kas & nom \\ gen & m \end{bmatrix}$$

$$NP \begin{bmatrix} num & pl \\ kas & nom \\ gen & m \end{bmatrix} \rightarrow Det \begin{bmatrix} num & pl \\ kas & nom \\ gen & m \end{bmatrix} N \begin{bmatrix} num & pl \\ kas & nom \\ gen & m \end{bmatrix}$$

## Explizite Kodierung von Merkmalen



## Kontextfreie Grammatik mit Merkmalsstrukturen

- Konstituenten werden mit Paaren aus Kategoriensymbolen und Merkmalsstrukturen ausgezeichnet.
- Eine Merkmalsstruktur ist eine Menge von Merkmal-Wert-Paaren (auch „Attribut-Wert-Paaren“): Die Merkmalsstruktur des NP-Knotens im Beispiel hat drei Merkmale, das erste besteht aus dem Attribut „num“ und dem atomaren Wert „sg“.
- Die explizite Kodierung von Merkmalen erlaubt die Formulierung von Bedingungen / Constraints, z.B. „Numerus von NP und Numerus von VP sind identisch“, oder „Subjekts-NP hat Kasus Nominativ“.
- Regeln der Grammatik sind zweiteilig: Sie bestehen aus einer Ersetzungsregel (wie üblich über Kategorien und lexikalische Ausdrücke formuliert) und einer Menge von Constraints über Merkmalsstrukturen.

5

## CFG mit Merkmalsconstraints, Beispiel

$S \rightarrow NP VP$   
*Numerus der NP = Numerus der VP*  
*Kasus der NP = nom*

$VP \rightarrow VI$   
*Numerus der VP = Numerus von VI*

$VP \rightarrow VT NP$   
*Numerus der VP = Numerus von VT*  
*Kasus der NP = akk*

$NP \rightarrow DET N$   
*Numerus von DET = Numerus von N*  
*Genus von DET = Genus von N*  
*Kasus von DET = Kasus von N*  
*Numerus der NP = Numerus von N*  
*Genus der NP = Genus von N*  
*Kasus der NP = Kasus von N*

$VI \rightarrow arbeitet$   
*Numerus von VI = sg*

$VI \rightarrow arbeiten$   
*Numerus von VI = pl*

$N \rightarrow Student$   
*Numerus von N = sg*  
*Genus von N = m*  
*Kasus von N = nom*

$DET \rightarrow der$   
*Numerus von DET = sg*  
*Genus von DET = m*  
*Kasus von DET = nom*

6

## CFG mit Merkmalsconstraints, Beispiel

$S \rightarrow NP VP$   
 $\langle NP \text{ num} \rangle = \langle VP \text{ num} \rangle$   
 $\langle NP \text{ kas} \rangle = nom$

$VP \rightarrow VI$   
 $\langle VP \text{ num} \rangle = \langle VI \text{ num} \rangle$

$VP \rightarrow VT NP$   
 $\langle VP \text{ num} \rangle = \langle VT \text{ num} \rangle$   
 $\langle NP \text{ kas} \rangle = akk$

$NP \rightarrow DET N$   
 $\langle DET \text{ num} \rangle = \langle N \text{ num} \rangle$   
 $\langle DET \text{ gen} \rangle = \langle N \text{ gen} \rangle$   
 $\langle DET \text{ kas} \rangle = \langle N \text{ kas} \rangle$   
 $\langle NP \text{ num} \rangle = \langle N \text{ num} \rangle$   
 $\langle NP \text{ gen} \rangle = \langle N \text{ gen} \rangle$   
 $\langle NP \text{ kas} \rangle = \langle N \text{ kas} \rangle$

$VI \rightarrow arbeitet$   
 $\langle VI \text{ num} \rangle = sg$

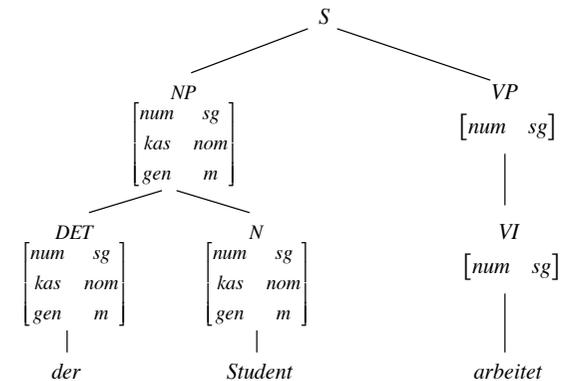
$VI \rightarrow arbeiten$   
 $\langle VI \text{ num} \rangle = pl$

$N \rightarrow Student$   
 $\langle N \text{ num} \rangle = sg$   
 $\langle N \text{ gen} \rangle = m$   
 $\langle N \text{ kas} \rangle = nom$

$DET \rightarrow der$   
 $\langle DET \text{ num} \rangle = sg$   
 $\langle DET \text{ gen} \rangle = m$   
 $\langle DET \text{ kas} \rangle = nom$

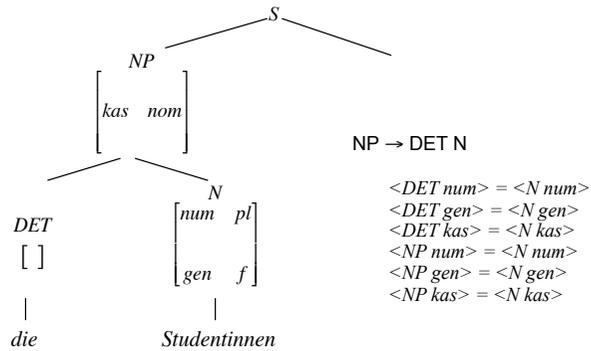
7

## Die Anwendung von Merkmals-Constraints



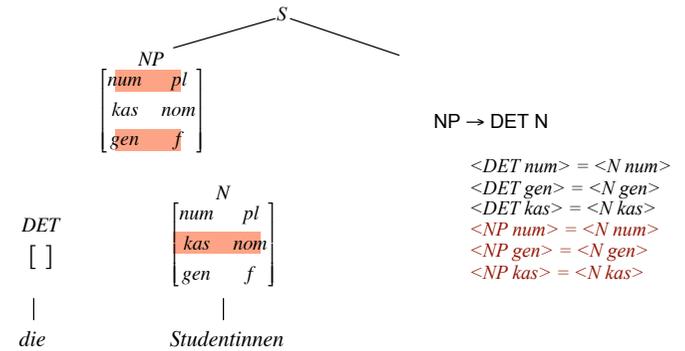
8

## Die Anwendung von Merkmals-Constraints



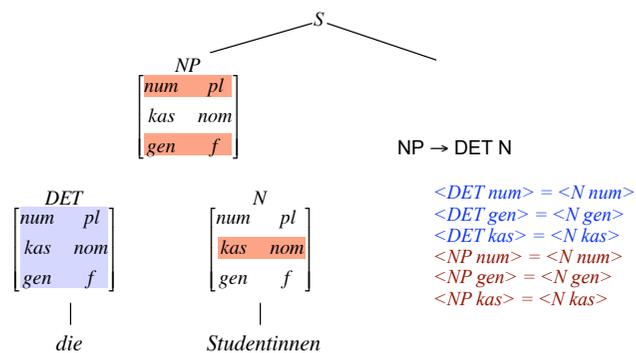
9

## Die Anwendung von Merkmals-Constraints



10

## Die Anwendung von Merkmalsconstraints



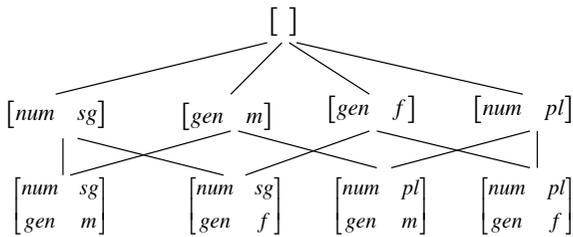
11

## Unifikation

- Bei der Anwendung von Pfadgleichungen wird nicht die Identität aktueller Werte abgeprüft, sondern
  - die Kompatibilität der vorhandenen Merkmalsinformation getestet, indem
  - die Information auf beiden Seiten der Gleichung zusammengeführt.
- Dies geschieht, indem die entsprechenden Merkmalsinformationen **unifiziert** werden. Wir schreiben  $A \sqcup B$ .
- Resultat der Unifikation ist die (allgemeinste) Merkmalsstruktur, die die Information aus beiden Merkmalsstrukturen umfasst, wenn es eine solche Struktur gibt. Ansonsten schlägt sie fehl.
- Wenn A allgemeiner ist als B ist, d.h., wenn Merkmalsstruktur B die Information aus Merkmalsstruktur A komplett enthält, sprechen wir von **Subsumption**: A subsumiert B, oder  $A \sqsubseteq B$ .
- Das Resultat der Unifikation von A und B:  $A \sqcup B$  ist die allgemeinste Struktur C, sodass  $A \sqsubseteq C$  und  $B \sqsubseteq C$ , d.h., die Struktur, die genau die gemeinsame in A und B enthaltene Information enthält.

12

## Subsumption

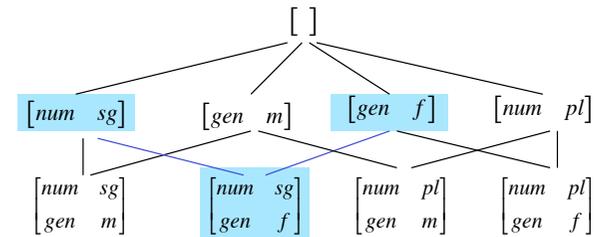


Die Graphik stellt die Halbordnung über Merkmalsstrukturen dar, die durch die Subsumptionsrelation etabliert wird: Die obere Struktur subsumiert jeweils die untere, zum Beispiel

$$[] \sqsubseteq [gen \ m] \sqsubseteq \begin{bmatrix} num & sg \\ gen & m \end{bmatrix}$$

13

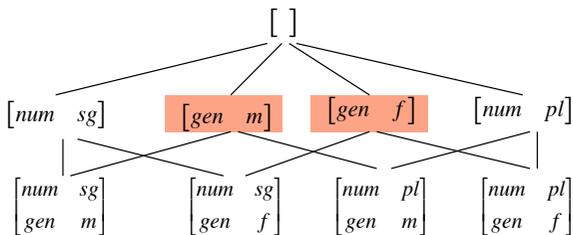
## Subsumption und Unifikation



$$\begin{bmatrix} num & sg \\ gen & m \end{bmatrix} \sqcup \begin{bmatrix} gen & f \end{bmatrix} = \begin{bmatrix} num & sg \\ gen & f \end{bmatrix}$$

14

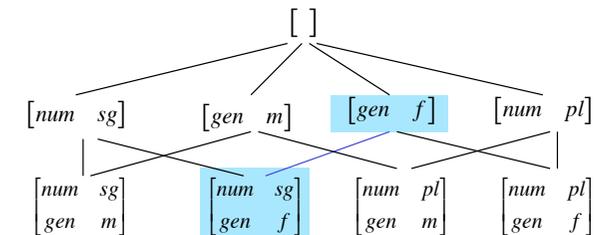
## Subsumption und Unifikation



$$\begin{bmatrix} gen & m \end{bmatrix} \sqcup \begin{bmatrix} gen & f \end{bmatrix} = fail$$

15

## Subsumption und Unifikation



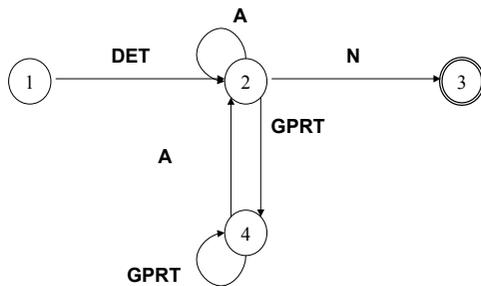
$$\begin{bmatrix} num & sg \\ gen & f \end{bmatrix} \sqcup \begin{bmatrix} gen & f \end{bmatrix} = \begin{bmatrix} num & sg \\ gen & f \end{bmatrix}$$

allgemein: wenn  $A \sqsubseteq B$ , so ist  $A \sqcup B = B$

16

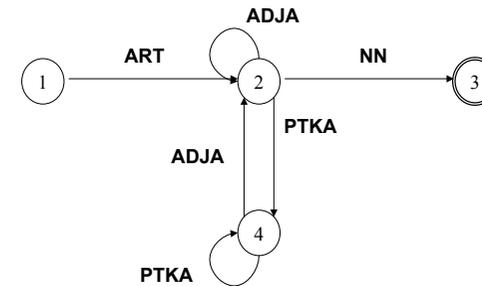
## Der alte NP-Automat

die ziemlich interessante Vorlesung  
das recht neue sehr sehr schöne rote Dach



## Ein NP-Automat

... mit Wortart-Tags (Standardbezeichnungen für Wortarten)  
aus dem Stuttgart-Tübinger Tagset (STTS)  
[www.ims.uni-stuttgart.de/projekte/corplex/TagSets/stts-table.html](http://www.ims.uni-stuttgart.de/projekte/corplex/TagSets/stts-table.html)



## Ein NP-Automat

- Erkennung von NPs mit Wortartmustern setzt als Vorverarbeitungsschritt die Annotation der Eingabe mit Wortart-Tags voraus:

die ziemlich interessante Vorlesung

↓ ↓ ↓ ↓  
ART PTKA ADJA NN

- Aber:

einige zu laute Vorlesungen

↓ ↓ ↓ ↓  
? ? ? NN

I made her duck

↓ ↓ ↓ ↓  
PPER VVFIN ? ?

## Ein NP-Automat

- Mögliche Wortarten der Wortform zu?

Die Tür ist zu.	ADV
Er ist nett zu mir.	APPR
Er ist mir zu nett.	PTKA
Er versucht zu schlafen.	PTKZU

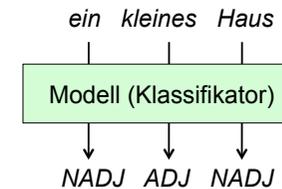
## Wortart-Tagger

- Eindeutige Wortartinformation ist für viele sprachtechnologische Anwendungen wichtig. Sie ist hilfreich bei Lemmatisierung, morphologischer und syntaktischer Analyse.
- Wortartinformation wird durch „Wortart-Tagger“ oder „POS-Tagger“ bereitgestellt (POS für „part of speech“, engl. „tag“ ist die Markierung).
- Wortart-Tagger sind heute Standardwerkzeuge der Sprachverarbeitung – wie Morphologie-Systeme. Anders als Morphologien arbeiten sie in der Regel mit **statistischer Modellierung**.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Beispielaufgabe: Adjektiverkennung

- Wortart-Tagger für das Deutsche müssen zwischen ca. 50 Kategorien wählen.
- Wir betrachten eine Teilaufgabe: Die Beantwortung der Frage, ob es sich bei einem Vorkommen eines Wortes in einem Text um ein Adjektiv handelt (also eine binäre Klassifikationsaufgabe).



Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Grundsätzliche Alternativen

- **Lexikonbasiertes Modell:**
  - Prüfe (mithilfe von Lemmatisierer/Morphologie), ob die Wortform zu einem Lemma im Lexikon gehört, entnehme die Wortartinformation dem Lexikon
  - Probleme: **Mehrdeutigkeit** und **Abdeckung**
- **Regelbasiertes/ symbolisches Modell:**
  - Formuliere ein System von wenn-dann-Regeln:  
Wenn <Merkmal1>, ..., <Merkmaln> vorliegen, dann weise <Wortart> zu.
- **Datenbasiertes/ statistisches Modell:**
  - Annotiere ein Korpus mit Wortart-Tag, lerne statistische Abhängigkeiten zwischen Merkmalen des Wortes (Merkmalsmustern) und seiner Wortart.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Datenanalyse: Informative Merkmalsmuster

- Woran erkenne ich, dass ein Wortvorkommen ein Adjektiv ist?  
*eine laute Vorlesung*  
*das siebente Übungsblatt*
- Spezifikation geeigneter Merkmale für die Modellierung:
  - Merkmale, die direkt abgelesen oder mit großer Sicherheit automatisch ermittelt werden können
  - Informativ in Bezug auf die Klassifikationsaufgabe sind
- Beispiele:
  - Groß-/Kleinschreibung
  - Groß-/Kleinschreibung des Folgewortes
  - Vorgängerwort ist Artikel/ kein Artikel

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Symbolische Regeln

Beispiele:

- Nachfolger großgeschrieben → ADJ
  - *das Haus* – **Korrektheitsproblem**
- Nachfolger großgeschrieben, selbst kein Artikel → ADJ
  - *Ich sehe Peter* – **Korrektheitsproblem**
- Nachfolger großgeschrieben, selbst kein Artikel, Vorgänger Artikel → ADJ
  - *große Bedenken* – **Vollständigkeitsproblem**

Es ist schwer, Regeln zu schreiben, die die Abhängigkeit der Wortart von Merkmalsmustern korrekt und vollständig erfassen.

Alternative: Lernen des Zusammenhangs von Merkmalsmustern und Wortarten aus Korpora!

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Statistisches Modell

- Wir spezifizieren eine Menge von geeigneten Merkmalen
  - Beispiel: selbst groß/klein, Folgewort groß/klein, Vorgänger Artikel/kein Artikel
- Wir wählen ein Textkorpus aus („Trainingsdaten“) und annotieren die Daten manuell mit Wortarttags
  - Beispiel: ADJ/ NADJ
- Wir extrahieren für jede Instanz (Textwort) das zugehörige Merkmalsmuster.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Informative Merkmalsmuster

Text:	<i>Vor</i>	<i>dem</i>	<i>kleinen</i>	<i>Haus</i>	<i>steht</i>	<i>ein</i>	<i>großer</i>	<i>Baum</i>
Annotation	NADJ	NADJ	ADJ	NADJ	NADJ	NADJ	ADJ	NADJ
Merkmale:								
n groß	+	-	-	+	-	-	-	+
n+1 groß	-	-	+	-	-	-	+	-
n-1 Art.	-	-	+	-	-	-	+	-

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Statistisches Modell

- Wir spezifizieren eine Menge von geeigneten Merkmalen
  - Beispiel: selbst groß/klein, Folgewort groß/klein, Vorgänger Artikel/kein Artikel
- Wir wählen ein Textkorpus aus („Trainingsdaten“) und annotieren die Daten manuell mit Wortarttags.
  - Beispiel: ADJ/ NADJ
- Wir extrahieren für jede Instanz (Textwort) das zugehörige Merkmalsmuster.
- Wir trainieren den Klassifikator, sodass er für jede Instanz auf der Grundlage ihres Merkmalsmusters („Ereignis“) eine Wahrscheinlichkeit für die Wortarttags (Klassen) ermittelt.
- Wir wenden den Klassifikator auf neue Daten an: Er gibt für jede Instanz die wahrscheinlichste Klasse zurück (und ggf. die zugehörige Wahrscheinlichkeit als „Konfidenzwert“)

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Wahrscheinlichkeit und Frequenz

- Das einfachste Verfahren für die Wahrscheinlichkeitsschätzung:
  - Auszählen der Frequenzen im Korpus
  - Relative Häufigkeit im Korpus als geschätzte Wahrscheinlichkeit
- Die unterschiedlichen Merkmalsmuster nennen wir „Ereignisse“. Die Merkmale mit ihren alternativ möglichen Werten spannen den „Ereignisraum“ auf.
- Der Klassifikator weist einer Instanz das für deren Merkmalsmuster häufigste Wortarttag zu.
- „Training“ des Klassifikators bedeutet in diesem einfachsten Fall im Grunde nur Auszählen des Korpus.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Wahrscheinlichkeit und Frequenz

Frequenz im Korpus

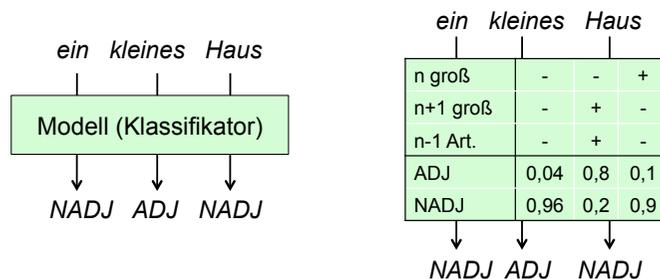
n groß	-	-	+
n+1 groß	-	+	-
n-1 Art.	-	+	-
ADJ	5	40	12
NADJ	120	10	108

Relative Frequenz/  
Geschätzte Wahrscheinlichkeit

n groß	-	-	+
n+1 groß	-	+	-
n-1 Art.	-	+	-
ADJ	0,04	0,8	0,1
NADJ	0,96	0,2	0,9

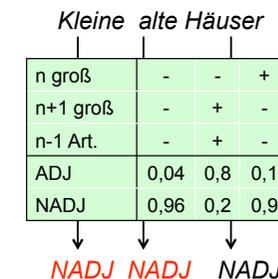
Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Einfaches statistisches Modell



Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Klassifikationsfehler



Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Bessere Resultate durch mehr Merkmale?

- Welche weiteren Merkmale könnte man ausnutzen, um Adjektive zu identifizieren?
  - Wortendungen (morphologische Information)
    - Komparativ- und Superlativendungen
    - Suffix -ig, -lich, -isch, -sam
  - Gradpartikeln
    - sehr, besonders, ziemlich
  - ...
- Wieso verwendet man nicht alle Merkmale, die irgendwie erfolgversprechend sind?

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Sparse-Data-Problem

- Je mehr Merkmale, umso besser ist grundsätzlich die Datenlage für die Entscheidung, aber:
- Je mehr Merkmale, auf desto mehr Ereignisse verteilen sich die Trainingsdaten. Die Wahrscheinlichkeitsschätzung wird ungenau oder sogar unmöglich.
- Faustregel für die Wahl einer geeigneten Merkmalsmenge:
  - Wenige gute (aussagekräftige) Merkmale sind besser als viele mittelmäßige
  - Merkmale mit weniger möglichen Werten sind grundsätzlich vorzuziehen.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Größe des Merkmalsraums

- Produkt der Anzahl möglicher Werte aller Merkmale:
  - Wir haben im Beispiel 3 binäre Merkmale verwendet, es gibt also  $2^3=8$  Muster.
  - Wenn wir 10 binäre Merkmale verwenden, haben wir über 1000 Muster.
  - Wenn wir z.B. noch als zwei Merkmale das Vorgängerwort und das Nachfolgerwort selbst hinzunehmen, kommen wir auf Milliarden von Kombinationen.
- Die Instanzen im Trainingskorpus verteilen sich auf die Merkmalsmuster.
  - Das Trainingskorpus muss deutlich größer sein als das Testkorpus. Ansonsten treten viele Merkmalsmuster gar nicht auf („ungesehene Ereignisse“): Das Modell kann dafür keine Vorhersage machen.
  - „Sparse-Data“-Problem

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Evaluation

- Annotation eines „Goldstandard“: Testkorpus mit der relevanten Zielinformation (z.B. Wortart)
  - Um subjektive Varianz auszuschließen, wird durch mehrere Personen unabhängig annotiert und die Übereinstimmung („Inter-Annotator Agreement“) gemessen.
  - Testkorpus und Trainingskorpus müssen disjunkt sein, um Effekte aus den Besonderheiten der Korpus-texte auszuschließen („overfitting“)
- Automatische Annotation des Testkorpus mit statischem Modell/ Klassifikator
- Messung der Performanz durch Vergleich von automatischer Annotation mit Goldstandard

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Akkuratheit

- Akkuratheit (accuracy) ist das einfachste Maß:

Akkuratheit = korrekt klassifizierte Instanzen/alle Instanzen

- Fehlerrate (error rate) ist der Komplementärbegriff zu Akkuratheit:

Fehlerrate = 1 – Akkuratheit

- Das Akkuratheitsmaß verdeckt oft die tatsächliche Performanz eines Verfahrens.
- Grundlage für eine feinere Evaluation des Klassifikators ist die Konfusionsmatrix.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Konfusionsmatrix

- Konfusionsmatrix (Verwechslungstabelle) für binäre Klassifikation:

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	ok	falsch
Klassifiziert als NADJ	falsch	ok

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Konfusionsmatrix

- Konfusionsmatrix (Verwechslungstabelle) für binäre Klassifikation:

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	ok	Korrektheitsfehler
Klassifiziert als NADJ	Vollständigkeitsfehler	ok

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Konfusionsmatrix

- Konfusionsmatrix (Verwechslungstabelle) für binäre Klassifikation:

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	true positive	false positive
Klassifiziert als NADJ	false negative	true negative

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UoS Computerlinguistik

## Konfusionsmatrix

- (Fiktives) Beispiel:

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	20	80
Klassifiziert als NADJ	20	880

- Von insgesamt 1000 Fällen sind 900 korrekt (Wahre Positive und wahre Negative): Akkuratheit ist also 90%, Fehlerrate 10%.
- Tatsächlich ist die Adjektiverkennung miserabel: von fünf als ADJ klassifizierten Instanzen ist nur eine korrekt.
- Recall und Precision als klassenspezifische Maße, die Vollständigkeits- und Korrektheitsfehler separat messen.

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Precision

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	True positive	False positive
Klassifiziert als NADJ	False negative	True negative

- Welcher Anteil der als X klassifizierten Instanzen ist tatsächlich ein X?

$$\text{Precision} = \text{True positives} / (\text{True positives} + \text{False positives})$$

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	20	80
Klassifiziert als NADJ	20	880

$$\text{Precision für ADJ} = 20 / (20 + 80) = 0,2$$

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Recall

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	True positive	False positive
Klassifiziert als NADJ	False negative	True negative

- Welcher Anteil der echten X wurde tatsächlich gefunden (als X klassifiziert)?

$$\text{Recall} = \text{True positives} / (\text{True positives} + \text{False negatives})$$

	Echtes ADJ	Echtes NADJ
Klassifiziert als ADJ	20	80
Klassifiziert als NADJ	20	880

$$\text{Recall für ADJ} = 20 / (20 + 20) = 0,5$$

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## Precision und Recall

- Precision und Recall sind im allgemeinen nur zusammen aussagekräftig
  - Hohe Präzision, hoher Recall: gutes Modell
  - Niedrige Präzision, niedriger Recall: schlechtes Modell
  - Hohe Präzision, niedriger Recall: „Vorsichtiges“ Modell
    - Findet nicht alle Instanzen von X
    - Klassifiziert kaum keine Nicht-Xe als X
  - Niedrige Präzision, hoher Recall: „Mutiges“ Modell
    - Findet fast alle Instanzen von X
    - Klassifiziert viele nicht-Xe fehlerhaft als X
  - Extremfälle
    - Modell klassifiziert alles als X: Recall 100%, Precision niedrig
    - Modell klassifiziert nichts als X: Recall 0%, Precision nicht definiert

Vorlesung "Einführung in die CL" 2009/2010 © M. Pinkal UdS Computerlinguistik

## F-Score

- Der „F-Score“ ist ein Maß für die „Gesamtgüte“ der Klassifikation, in das Precision und Recall eingehen.

$$F = \frac{2PR}{P + R}$$

- F-Score für die Klasse ADJ im Beispiel:

$$F = \frac{2 * 0,2 * 0,5}{0,2 + 0,5} = 0,29$$