

Einführung in die Computerlinguistik

Statistische Modellierung und Evaluation

WS 2008/2009

Manfred Pinkal

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Mehrdeutigkeit der Wortart

- Mögliche Wortarten der Wortform *zu*?
 - Die Tür ist zu.
 - Er ist nett zu mir.
 - Er ist mir zu nett.
 - Er plant, seine Freunde zu besuchen.

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Mehrdeutigkeit der Wortart

- *Sie haben in Moskau liebe genossen*
- *Sie haben in Moskau liebe Genossen*
- *Sie haben in Moskau Liebe genossen*

liebe: V oder A?

Liebe am Satzbeginn: N oder V oder A?

- *I made her duck*

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

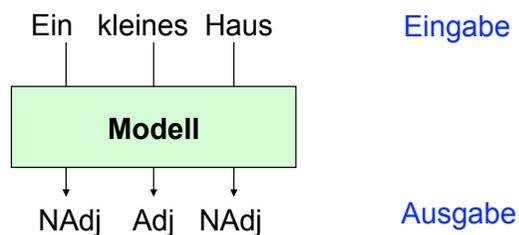
Wortart-Tagger

- Die Wortartinformation ist für viele sprachtechnologische Anwendungen wichtig: Sie ist Voraussetzung für die grammatische Analyse und hilfreich bei Lemmatisierung und morphologischer Analyse.
- Wortartinformation wird durch „Wortart-Tagger“ oder „POS-Tagger“ bereitgestellt. „POS“ wegen engl. „part of speech“ für die Wortart. „Tagger“, weil die zentrale Funktion der Systeme darin besteht, Textwörtern in Sätzen und Dokumenten eine Wortart-Markierung (engl. „tag“) zuzuordnen.
- Wortart-Tagger sind heute Standard-Werkzeuge der Sprachverarbeitung. Sie arbeiten teils mit regelbasierter, teils mit statistischer Modellierung. Die Zuverlässigkeit ist sehr hoch (>99,5%).

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Beispielaufgabe: Adjektiverkennung

- Handelt es sich bei einem Wort (in einem fortlaufenden Text) um ein Adjektiv?



Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Wortarterkennung

- **Lexikonbasiertes Modell**
 - Prüfe (mithilfe von Lemmatisierer/ Morphologie), ob die Wortform zu einem Lemma im Lexikon gehört, entnehme Wortartinformation aus dem Lexikon
 - Problem1: Wortart kann mehrdeutig sein
 - Problem2: N, V, A sind offene Wortklassen
- **Musterbasierte Modelle**, die den Kontext einbeziehen:
 - Option 1: Regelbasierte Modelle: Schreibe explizite Regeln der Form
Wenn <Muster>, dann <Wortart>
 - **Symbolisches Modell**
 - Option 2: Datenbasierte Modelle: Lerne Abhängigkeiten zwischen Mustern und Wortart aus Korpus
 - **Statistisches Modell**

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Datenanalyse: Informative Muster für die Adjektiverkennung

Intuitive Frage: **Woran erkenne ich ein Adjektiv?**

Ich moechte Ihnen fuer Ihren Bericht ueber den **siebenten** Bericht ueber **staatliche** Beihilfen in der **europäischen** Union danken.

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Datenanalyse: Informative Muster für die Adjektiverkennung

Intuitive Frage: **Woran erkenne ich ein Adjektiv?**

- Nächstes Wort ist großgeschrieben (kapitalisiert)
 - Der **siebente** Bericht
- Vorheriges Wort ist Artikel
 - Der **siebente** Bericht
- Wort selbst ist nicht kapitalisiert
 - Der **siebente** Bericht
- Wort selbst ist kein Artikel

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Symbolische Regeln

- Welche expliziten Regeln können wir aufstellen?
 - Nach Artikel, vor groß geschriebenem Wort, aktuelles Wort kein Artikel \Rightarrow Adj
 - **das** meiste **Geld** (Korrektheitsproblem)
 - Nächstes Wort nicht kapitalisiert oder kein vorangehender Artikel \Rightarrow NAdj
 - **der** fleißige, aber nicht erfolgreiche Student
 - **große** Bedenken (Vollständigkeitsproblem)

Es ist schwer, explizite Regeln zu schreiben, die sowohl korrekt als auch vollständig sind

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

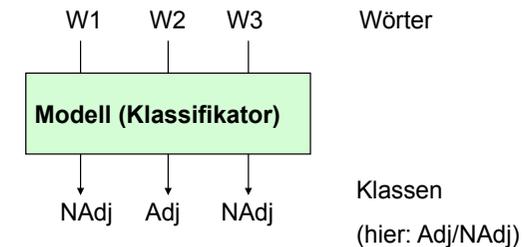
Wahrscheinlichkeiten und relative Häufigkeit

- Die Klassifikation erfolgt wahrscheinlichkeitsbasiert.
- Die **Wahrscheinlichkeit** wird auf der Grundlage **relativer Häufigkeiten** geschätzt / approximiert.

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Adjektiverkennung als statistische Klassifikationsaufgabe

- **Alternative Idee:** Zusammenhang zwischen Mustern und "Adjektivstatus" automatisch (maschinell) lernen!
- **Klassifikationsaufgabe:** jedem Eingabe-Ereignis wird eine Klasse (aus einer kleinen Menge) zugeordnet



Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Beispiel1

- Wir versuchen herauszufinden, wie hoch die **Wahrscheinlichkeit** ist, dass wir mit einem Würfel als Nächstes eine „6“ würfeln, anders ausgedrückt: Dass als Ergebnis eines Wurfes das **Ereignis** E= „6 liegt oben“ eintritt. Diese Wahrscheinlichkeit nennen wir $P(E)$ bzw. $P(„6$ liegt oben“)
- Wir schätzen $P(E)$, indem wir die relative Häufigkeit ermitteln, mit der in einer Folge von n Versuchen (einer Stichprobe aus n **Instanzen**) das Ereignis E eintritt:
$$P(E) \approx h_n(E) \text{ (für hinreichend großes } n)$$
- $h_n(E) = H(E)/n$, wobei $H(E)$ die absolute Häufigkeit ist.
- Am Beispiel: Nach 100 Würfeln wurde 19 mal die 6 geworfen:
$$P(E) \approx h_n(E) = 0,190$$

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Wahrscheinlichkeiten und relative Häufigkeit

- Beispiel2:

Die Wahrscheinlichkeit, dass es morgen in Saarbrücken regnet.

E= „es regnet“

Instanzen: Das Wetter in SB in einer Stichprobe von n Kalendertagen.

Von 365 Instanzen fallen 147 unter E:

$$P(E) \approx h_n(E) = 0,403$$

Wahrscheinlichkeiten und relative Häufigkeit

- Beispiel3:

Die Wahrscheinlichkeit, dass das nächste gelesene Textwort ein Adjektiv ist

E= „Adjektiv“

Instanzen: 1 000 000 Wörter fortlaufender Text aus einem Korpus, davon 65909 Adjektive:

$$P(E) \approx h_n(E) = 0,066$$

Bedingte Wahrscheinlichkeiten

- Beispiel:

Die bedingte Wahrscheinlichkeit, dass es morgen in Saarbrücken regnet (E=„es regnet“), gegeben dass Saarbrücken im Einfluss eines Tiefdruckgebietes ist (F=„Tiefdruck“), schreiben wir $P(E | F)$.

- Wir approximieren:
$$P(E | F) \approx \frac{h_n(E \cap F)}{h_n(F)} = \frac{H(E \cap F)}{H(F)}$$

- Am Beispiel: 215 Tage mit Tiefdruck, davon an 122 Tagen Regen:
 $P(E | F) = 0,567$

Wortart-Tagging als Klassifikation

- Wir lernen den statistischen Zusammenhang zwischen Merkmalsmustern (Ereignissen) und Wortarten (ebenfalls Ereignissen) automatisch.
- Schritt1: Datenanalyse
- Wir spezifizieren geeignete Merkmalsmuster:
 - Merkmale, die mit großer Sicherheit automatisch für die Instanzen (Textwörter) ermittelt werden können
 - Informativ in Bezug auf die Aufgabe sind: möglichst eindeutige Entscheidung bezüglich der Klassifikationsaufgabe ermöglichen.
- Vorbereitung: Wir annotieren ein „Trainingskorpus“ mit Wortart-Tags

Einfachste statistische Klassifikation

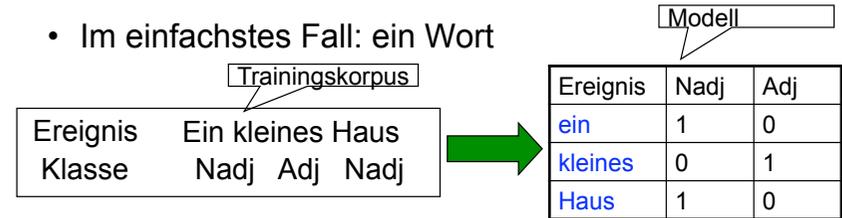
- Schritt 2: Modell lernen ("Training")
- Wir lesen den Zusammenhang zwischen Merkmalsmustern (E1, E2, ...) und Wortart-Tags (K1, K2, ...) aus dem Korpus ab.

Ereignis	K1	K2	K3
E1	10	20	0
E2	2	0	15
E3

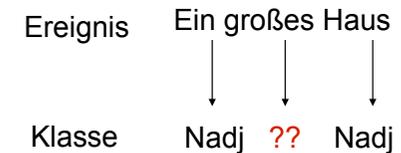
- Schritt 3: Modell anwenden (Analyse neuer Daten)
 - Jedem Ereignis in den neuen Daten wird die häufigste (≈ auf der Grundlage des bekannten Merkmalsmusters wahrscheinlichste) Klasse aus den Trainingsdaten zugewiesen.

Was ist ein Ereignis? (I)

- Im einfachsten Fall: ein Wort

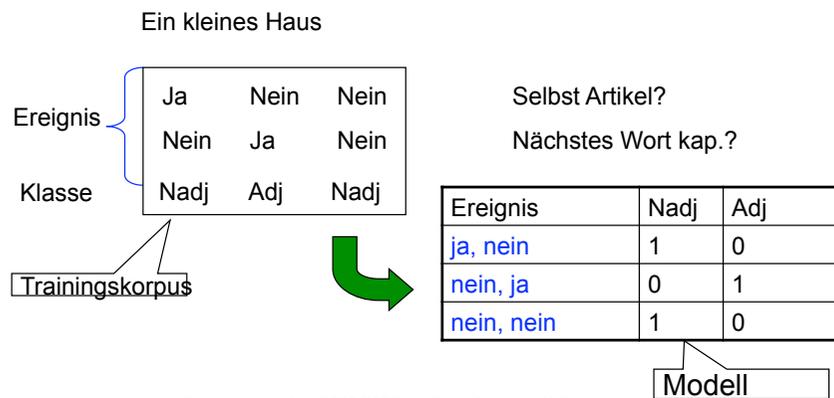


- Keine gute Idee!
 - Klassifikation eines neuen Satzes:
 - Wortliste!

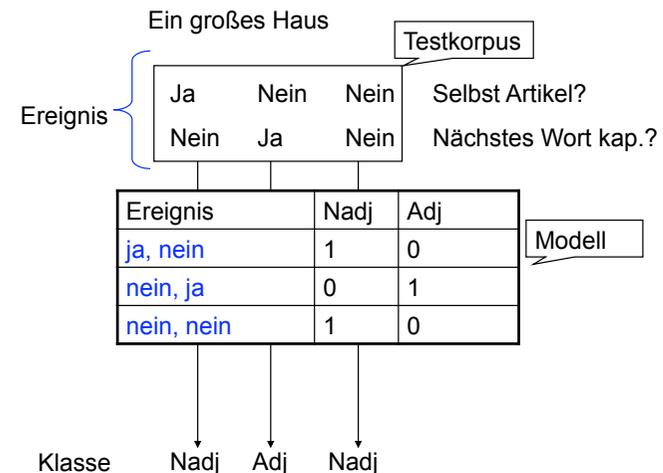


Was ist ein Ereignis? (II)

- Besser: Ereignis ist Kombination von informativen Mustern ("Features")



Klassifikation eines neuen Satzes



Was "bedeutet" das Modell?

- Features:
 - Selbst Artikel?
 - Nächstes Wort kap.?

Ereignis	Nadj	Adj
ja, nein	1	0
nein, ja	0	1
nein, nein	1	0

- Zeile 1: Artikel, nächstes Wort nicht kapitalisiert: Kein Adjektiv
- Zeile 2: Kein Artikel, nächstes Wort kapitalisiert: Adjektiv
- Zeile 3: Kein Artikel, nächstes Wort nicht kap.: Kein Adjektiv
- Also doch Regeln: nur eben automatisch gelernte...

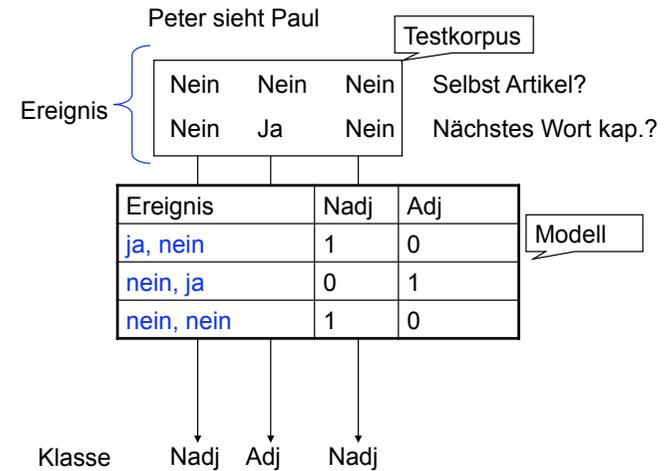
Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Intelligenter Modelle = mehr Features

- Welche weiteren Muster könnte man ausnutzen, um Adjektive zu identifizieren?
 - Wortendungen (morphologische Information)
 - Wörter /Lemmata auf -ig, -lich, -isch sind mit großer Wahrscheinlichkeit Adjektive
 - Gradpartikel stehen fast immer vor Adjektiven
 - "sehr", "besonders", ...
 - Kombination von existierenden Features
 - Voriges Wort Artikel UND selbst nicht kapitalisiert
 - ...
- Wieso verwendet man nicht einfach alle Features, die einem einfallen?

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Fehler



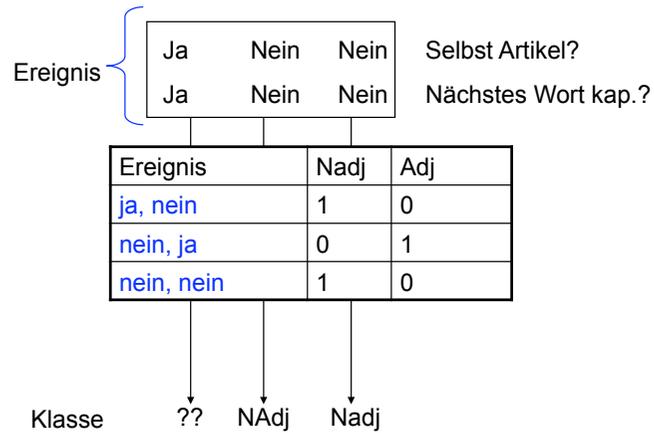
Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Größe des Ereignisraumes

- Wieviele Zeilen hat das Modell (die Tabelle)?
 - Anzahl möglicher verschiedener Ereignisse
 - Produkt der Anzahl möglicher Werte aller Features
 - Beispiel: Selbst Artikel? x Nächstes Wort kapitalisiert = $2 \times 2 = 4$
 - Lexikalische Features: Wort alleine > 10.000
- Frequenzen in Trainingskorpus werden auf Zeilen (Ereignisse) verteilt
 - Wenn Trainingskorpus nicht deutlich größer ist als die Menge möglicher Ereignisse, können in den Testdaten ungesehene Ereignisse auftreten: Modell kann keine Vorhersage machen
- Das "Sparse Data"-Problem

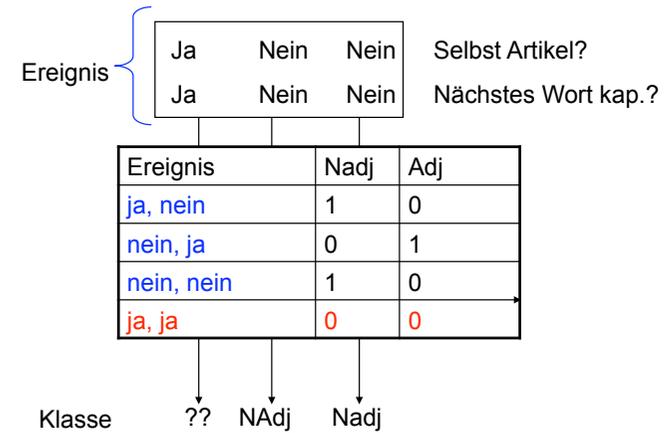
Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Sparse Data: Beispiel



Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Sparse Data: Beispiel



Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Das Sparse-Data-Dilemma

- Je mehr Features, desto besser die Datenlage für die Entscheidung
- Je mehr Features, auf desto mehr Ereignisse verteilen sich die Trainingsdaten
- Richtlinien für die Identifikation von Features:
 - Wenige gute Features sind besser als viele mittelmäßige
 - Bevorzuge Features mit wenigen Werten
- Einsatz von „Smoothing“-Techniken, z.B.
 - „Add One“
 - Kombination von Modellen unterschiedlicher Granularität

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Smoothing, Beispiel

Ereignis	K1	K2	K3
E1	10	20	0
E2	2	0	15
E3



Ereignis	K1	K2	K3
E1	11	21	1
E2	3	1	16
E3

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Evaluation: Die Rolle von Korpora

- Datenanalyse: Auswahl von informativen Merkmalen für die (Klassifikations-) Aufgabe
- Annotation: Manuelle Annotation eines hinreichend großen Korpus mit der relevanten Zielinformation (z.B. Wortart) – Annotation ist subjektiv, deshalb: Unabhängige Annotation durch mehrere Personen, Ermittlung der Übereinstimmung („Inter-Annotator-Agreement“, IAA)
- Training eines statistischen Modells
- Test / Evaluation auf einem Korpus („Gold-Standard“), das
 - Manuell annotiert
 - Und unabhängig ist, d.h., nicht für Analyse und training verwendet wurde

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Daten

Trainingsdaten (Training set)	Testdaten (Test set)
----------------------------------	-------------------------

- Meistens zwischen 70 und 90% der Daten
- Grundlage der Modellierung
- Quelle fuer Frequenzen
- Überprüfung des Modells an unabhängigen Daten

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Konfusionsmatrix

	Echtes X	Echtes nicht-X
Als X klassifiziert	✓	✗
Als nicht-X klass.	✗	✓

- Klassenspezifische Evaluation
- Setzt die „tatsächliche“ oder „echte“ Beispielklasse zu den vom Modell zugewiesenen Klassen in Beziehung.

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Konfusionsmatrix, Beispiel

	Echtes Adj	Echtes NAdj
Als Adj klassifiziert	✓	Korrektheitsfehler
Als NAdj klassifiziert	Vollständigkeitsfehler	✓

- Vier Fälle:
 - Ist Adjektiv, wird als Adj klassifiziert („true positive“)
 - Ist kein Adjektiv, wird als NAdj klassifiziert („true negative“)
 - Ist kein Adjektiv, wird als Adj klassifiziert („false positive“: Korrektheitsfehler)
 - Ist Adjektiv, wird als NAdj klassifiziert („false negative“: Vollständigkeitsfehler)

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Konfusionsmatrix, Beispiel

	Echtes Adj	Echtes NAdj
Als Adj klassifiziert	10	80
Als NAdj klassifiziert	10	900

- Gesamtfrequenzen der wirklichen und der zugewiesenen Klassen sind als Summen von Spalten bzw. Zeilen ablesbar

Probleme

- Problem 1: Macht keinen Unterschied zwischen (Gold-)Klassen (Adj vs. Nadj)
 - Wieso unterscheiden?
 - In der Computerlinguistik sind die interessanten Klassen oft klein
 - In Gesamtevaluation geht Qualität der kleinen Klasse unter
 - Klassenspezifische Akkuratheit / Fehlerrate
 - 10 / 20 korrekt für Adj: 50%
 - 900 / 980 korrekt für Nadj: 91.8%
- Problem 2: keine Unterscheidung zwischen Korrektheits- und Vollständigkeitsfehlern (falschen Positiven und falschen Negativen)

Akkuratheit und Fehlerrate

- Einfachstmögliche Evaluation ist die Berechnung der **Akkuratheit**: Die relative Häufigkeit der korrekten Klassifikationen (wahre Positive und wahre Negative) in der Gesamtmenge.

	Echtes Adj	Echtes NAdj
Als Adj klassifiziert	10	80
Als NAdj klassifiziert	10	900

$$\frac{10 + 900}{1000} = \frac{910}{1000} = 0,91$$

- **Fehlerrate** ist definiert als 1-Akkuratheit (im Beispiel: 0,09)

Recall

	Echtes X	Echtes Nicht X
Als X klassifiziert	True positives	False positives
Als Nicht-X klass.	False negatives	True negatives

$$\text{Recall} = \frac{\text{True positives}}{\text{True positives} + \text{False negatives}}$$

- Welcher Anteil der echten X wurde als X klassifiziert? (Vollständigkeit)
- Werte zwischen 0 und 1 (höher = besser)

Recall für Klasse Adj

	Echtes Adj	Echtes Nadj
Als Adj klassifiziert	10	80
Als Nadj klass.	10	900

$$\text{Recall} = \frac{\text{True positives}}{\text{True positives} + \text{False negatives}}$$

- Hier: $10/(10+10) = 0.5$
- Interpretation: Die Hälfte aller echten Adjektive wurde durch das Modell richtig erkannt

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Präzision

	Echtes X	Echtes Nicht X
Als X klassifiziert	True positives	False positives
Als Nicht-X klass.	False negatives	True negatives

$$\text{Precision} = \frac{\text{True positives}}{\text{True positives} + \text{False positives}}$$

- Welcher Anteil der als X klassifizierten Instanzen ist wirklich ein X? (Korrektheit)
- Werte zwischen 0 und 1 (höher = besser)

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Präzision für Klasse Adj

	Echtes Adj	Echtes Nadj
Als Adj klassifiziert	10	80
Als Nadj klass.	10	900

$$\text{Precision} = \frac{\text{True positives}}{\text{True positives} + \text{False positives}}$$

- Hier: $10 / (10+80) = 11\%$
- Interpretation: Wenn das Modell behauptet, eine Instanz sei ein Adj, ist das nur 11% der Fälle wahr

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Präzision und Recall

- Präzision und Recall können i.A. nur zusammen betrachtet werden
 - 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 fast keine Nicht-Xe als X
 - Niedrige Präzision, hoher Recall: "mutiges" Modell
 - Findet fast alle Instanzen von X
 - Klassifiziert auch Nicht-Xe als X

Vorlesung "Einführung in die CL" 2008/2009 © M. Pinkal UdS Computerlinguistik

Extremfälle..und die Kombination

- Extremfälle
 - Modell klassifiziert (fast) alles als X
 - Recall gegen 100%, Präzision beliebig niedrig
 - Modell klassifiziert (fast) nichts als X
 - Recall beliebig niedrig, Präzision geht gegen 100% (bei Recall 0% ist Präzision nicht definiert)
- **F-Score**: Kombination aus P und R: $F = \frac{2PR}{P+R}$
 - Ein Maß für „Gesamtgüte“ der Klassifikation
 - Werte zw. 0 und 1 (höher = besser)

F-Score für Klasse Adj

	Echtes Adj	Echtes Nadj
Als Adj klassifiziert	10	80
Als Nadj klass.	10	900

- Precision: $10 / (10+80) = 0.11$
- Recall: $10 / (10+10) = 0.5$
- F-Score: $(2 * 0.5 * 0.11) / (0.5 + 0.11) = 0.18$