



Hochschule **RheinMain**  
University of Applied Sciences  
Wiesbaden Rüsselsheim

# AUTOMATISCHE VERLINKUNG MIT WIKIPEDIA MITTELS C4.5- ENTSCHEIDUNGSBÄUME

Fachseminar "Machine Learning"

Letztes Update: 20. Januar 2016

Anahita Hamidi

Studienbereich Angewandte Informatik  
Hochschule **RheinMain**



# GLIEDERUNG

1. **Einleitung**
2. **C4.5 Algorithmus**
3. **Disambiguation**
4. **Detection**
5. **Quellen**

# EINLEITUNG

# WIKIPEDIA

- die größte **Enzyklopädie**
- **dicht** strukturiert
- Millionen von **Artikeln** und **Links**

Frage:

- Welche Begriffe in einem Artikel sollen verlinkt werden?
- Wie werden diese Begriffe verlinkt?

## Iranian POW negotiator holds talks with Iraqi ministers

The head of [Iran's prisoner of war](#) commission met with two [Iraqi](#) Cabinet ministers Saturday in a bid to glean information about thousands of Iranian POWs allegedly in Iraq, the official Iraqi News Agency reported.

Iraqi Foreign Minister [Mohammed Saeed al-Sahhaf](#) told Abdullah al-Najafi that the two states needed to "speed up the closure of what remains from the POW and Missing-In-Action file," INA said.

The issue of POWs and missing persons remains a stumbling block to normalizing relations between the two neighbors.

Iraq has long maintained that it has released all Iranian prisoners captured in the [1980-88 Iran-Iraq War](#). The countries accuse each other of hiding POWs and preventing visits by the [International Committee of the Red Cross](#) to prisoner camps.

The ICRC representative in [Baghdad](#), Manuel Bessler, told [The Associated Press](#) that his organization has had difficulty visiting POWs on both sides on a regular basis.

In April, Iran released 5,584 since [1990](#).

More than 1 million people w

### Baghdad

Baghdad is the capital of Iraq and of Baghdad Governorate. With a metropolitan area estimated at a population of 7,000,000, it is the largest city in Iraq. It is the second-largest city in the Arab world (after Cairo) and the second-largest city in southwest Asia (after Tehran).

[open in wikipedia](#)

filed as civil law detainees in the largest exchange

aus (Milne and Witten, 2008, "Learning to Link with Wikipedia")

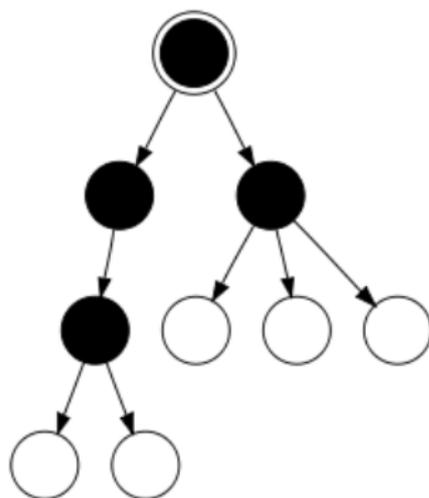
## Abbildung: Automatische Verbindung eines Begriffs

# WIKIFICATION

- dieser Prozess heißt **Wikification**
  - Disambiguation
  - Detection
- wichtiges Mittel: **Entscheidungsbäume**
- vorheriger Ansatz **Wikify!**-System von Mihalcea und Csomai (2007)

# ENTSCHEIDUNGSBAUM

- **gerichteter** Baum
- Blätter (Klasse, Wahrheitswerte)
- Knoten (Attribute)
- Kanten (Attributwert)



aus Baum (Graphentheorie)

**Abbildung:** Ein gerichteter Baum

# C4.5 ALGORITHMUS

# EINLEITUNG

- von Ross Quinlan entwickelt (1993)
- Nachfolger von ID3
- generiert Entscheidungsbaum aus den Trainingsdaten

## Verbesserungen in C4.5:

- sowohl **diskrete**, als auch **kontinuierliche** Attribute
- **fehlende** Attributswerte

# BEISPIEL

| Day | Outlook  | Humidity | Wind   | Play |
|-----|----------|----------|--------|------|
| D1  | Sunny    | High     | Weak   | No   |
| D2  | Sunny    | High     | Strong | No   |
| D3  | Overcast | High     | Weak   | Yes  |
| D4  | Rain     | High     | Weak   | Yes  |
| D5  | Rain     | Normal   | Weak   | Yes  |
| D6  | Rain     | Normal   | Strong | No   |
| D7  | Overcast | Normal   | Strong | Yes  |
| D8  | Sunny    | High     | Weak   | No   |
| D9  | Sunny    | Normal   | Weak   | Yes  |
| D10 | Rain     | Normal   | Weak   | Yes  |
| D11 | Sunny    | Normal   | Strong | Yes  |
| D12 | Overcast | High     | Strong | Yes  |
| D13 | Overcast | Normal   | Weak   | Yes  |
| D14 | Rain     | High     | Strong | No   |

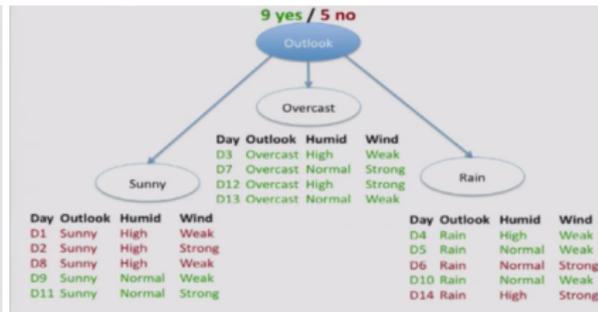


Abbildung: Trainingsdaten

## BEISPIEL

| Day | Outlook  | Humidity | Wind   | Play |
|-----|----------|----------|--------|------|
| D1  | Sunny    | High     | Weak   | No   |
| D2  | Sunny    | High     | Strong | No   |
| D3  | Overcast | High     | Weak   | Yes  |
| D4  | Rain     | High     | Weak   | Yes  |
| D5  | Rain     | Normal   | Weak   | Yes  |
| D6  | Rain     | Normal   | Strong | No   |
| D7  | Overcast | Normal   | Strong | Yes  |
| D8  | Sunny    | High     | Weak   | No   |
| D9  | Sunny    | Normal   | Weak   | Yes  |
| D10 | Rain     | Normal   | Weak   | Yes  |
| D11 | Sunny    | Normal   | Strong | Yes  |
| D12 | Overcast | High     | Strong | Yes  |
| D13 | Overcast | Normal   | Weak   | Yes  |
| D14 | Rain     | High     | Strong | No   |

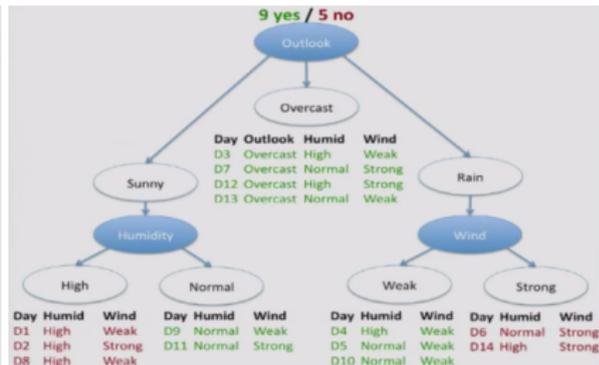


Abbildung: Trainingsdaten

# BEISPIEL

| Day | Outlook  | Humidity | Wind   | Play |
|-----|----------|----------|--------|------|
| D1  | Sunny    | High     | Weak   | No   |
| D2  | Sunny    | High     | Strong | No   |
| D3  | Overcast | High     | Weak   | Yes  |
| D4  | Rain     | High     | Weak   | Yes  |
| D5  | Rain     | Normal   | Weak   | Yes  |
| D6  | Rain     | Normal   | Strong | No   |
| D7  | Overcast | Normal   | Strong | Yes  |
| D8  | Sunny    | High     | Weak   | No   |
| D9  | Sunny    | Normal   | Weak   | Yes  |
| D10 | Rain     | Normal   | Weak   | Yes  |
| D11 | Sunny    | Normal   | Strong | Yes  |
| D12 | Overcast | High     | Strong | Yes  |
| D13 | Overcast | Normal   | Weak   | Yes  |
| D14 | Rain     | High     | Strong | No   |

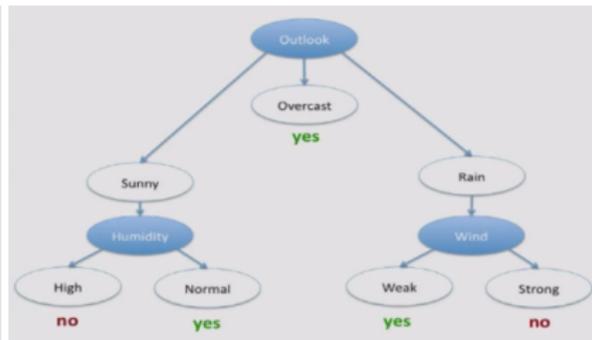


Abbildung: der erzeugte Baum

Abbildung: Trainingsdaten

# DISAMBIGUATION

# BEGRIFFSERKLÄRUNG

- wird in der Wikipedia angewendet
- Verknüpfung eines Stichworts mit dem entsprechenden Wikipedia-Artikel
- Merkmale
  - commonness
  - relatedness
  - context quality

# COMMONNESS

Definition: wie oft wurde ein Artikel als Ziel definiert?

$$commonness = \frac{c}{c_i}$$

$c$  die Anzahl der Ziel-Artikel von einem Begriff

$c_i$  die Anzahl aller Artikel mit diesem Begriff

Problem: ist aber nicht immer die beste Entscheidung.

Lösung: das Stichwort im gesamten Text betrachten.

# BEISPIEL

## Depth-first search

From Wikipedia, the free encyclopedia

**Depth-first search (DFS)** is an **algorithm** for traversing or searching a **tree** **tree structure** or **graph**. One starts at the root (selecting some node as the root in the graph case) and explores as far as possible along each branch before **backtracking**.

Formally, DFS is an **uninformed search** that progresses by expanding the first child node of the search **tree** that appears and thus going deeper and deeper until a goal node is found, or until it hits a node that has no children. Then the search **backtracks**, returning to the most recent node it hadn't finished exploring. In a non-recursive implementation, all freshly expanded nodes are added to a **LIFO stack** for exploration.

| sense                        | commonness   | relatedness   |
|------------------------------|--------------|---------------|
| Tree                         | 92.82%       | 15.97%        |
| Tree (graph theory)          | 2.94%        | 59.91%        |
| <b>Tree (data structure)</b> | <b>2.57%</b> | <b>63.26%</b> |
| Tree (set theory)            | 0.15%        | 34.04%        |
| Phylogenetic tree            | 0.07%        | 20.33%        |
| Christmas tree               | 0.07%        | 0.0%          |
| Binary tree                  | 0.04%        | 62.43%        |
| Family tree                  | 0.04%        | 16.31%        |
| ...                          |              |               |

aus (Milne and Witten, 2008, "Learning to Link with Wikipedia")

**Abbildung:** Disambiguierung des Begriffs "tree"

# RELATEDNESS

- der Bezug des Begriffs zum **Kontext**
- Kontext: die eindeutigen Begriffe
- eindeutige Begriffe: immer auf einen Artikel

$$\textit{relatedness}(a, b) = \frac{\log(\max(|A|, |B|)) - \log(|A \cap B|)}{\log(|W|) - \log(\min(|A|, |B|))}$$

$a$  und  $b$ : zwei Artikel

$A$ , bzw.  $B$ : die Menge aller mit  $a$  bzw.  $b$  verlinkten Artikel

$W$ : die Menge aller Artikel in Wikipedia

## Depth-first search

From Wikipedia, the free encyclopedia

**Depth-first search (DFS)** is an **algorithm** for traversing or searching a **tree** **tree structure** or **graph**. One starts at the root (selecting some node as the root in the graph case) and explores as far as possible along each branch before **backtracking**.

Formally, DFS is an **uninformed search** that progresses by expanding the first child node of the search **tree** that appears and thus going deeper and deeper until a goal node is found, or until it hits a node that has no children. Then the search **backtracks**, returning to the most recent node it hadn't finished exploring. In a non-recursive implementation, all freshly expanded nodes are added to a **LIFO stack** for exploration.

| sense                        | commonness   | relatedness   |
|------------------------------|--------------|---------------|
| Tree                         | 92.82%       | 15.97%        |
| Tree (graph theory)          | 2.94%        | 59.91%        |
| <b>Tree (data structure)</b> | <b>2.57%</b> | <b>63.26%</b> |
| Tree (set theory)            | 0.15%        | 34.04%        |
| Phylogenetic tree            | 0.07%        | 20.33%        |
| Christmas tree               | 0.07%        | 0.0%          |
| Binary tree                  | 0.04%        | 62.43%        |
| Family tree                  | 0.04%        | 16.31%        |
| ...                          |              |               |

aus (Milne and Witten, 2008, "Learning to Link with Wikipedia")

**Abbildung:** Disambiguierung des Begriffs "tree"

# AUSWAHL EINES KONTEXTS

→ nicht jeder eindeutige Begriff ist nützlich (z.B. das Wort **the**)

die Link-Wahrscheinlichkeit =

$$\rightarrow \frac{\text{Anzahl}(A_{\text{key}})}{\text{Anzahl}(A_W)}$$

→  $A_{\text{key}}$  : die Artikel, die den Begriff als Link enthalten

→  $A_W$  : alle Artikel, die den Begriff enthalten

Gewichtung eines Begriffs:

→ **Durchschnitt** von Link-Wahrscheinlichkeit und relatedness

# CONTEXT QUALITY

context quality:

→ die Summe **der Gewichtungen** der Begriffe

*ist der Kontext homogen* → *relatedness* wird klarer

*ist der Kontext gemischt* → *commonness* wird betrachtet

Der C4.5 Klassifikator:

→ Trainingsdaten: 3 Merkmale

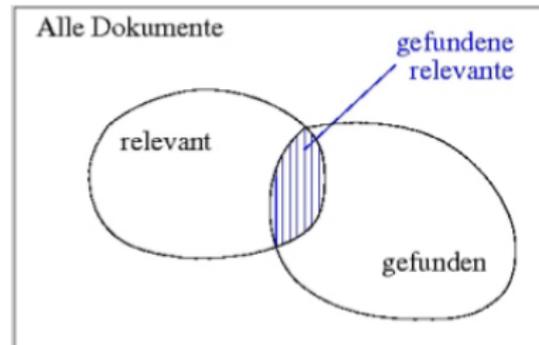
→ ergibt die Wahrscheinlichkeit für jeden Artikel

# EVALUATION

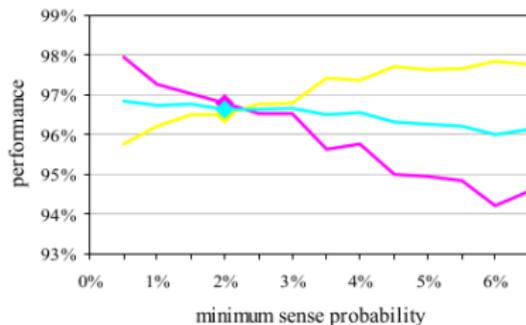
$$\rightarrow \textit{precision} = \frac{\textit{gefundene relevante}}{\textit{gefundene}}$$

$$\rightarrow \textit{recall} = \frac{\textit{gefundene relevante}}{\textit{relevante}}$$

$$\rightarrow \textit{f-measure} = 2 \cdot \frac{\textit{Precision} \cdot \textit{recall}}{\textit{precision} + \textit{recall}}$$



- 100 zufällige Artikel, 11000 Anchors
- Links mit **Threshold** von weniger als 2% ignorieren
- bessere Ergebnisse als vorherige Ansätze



aus (Milne and Witten, 2008, "Learning to Link with Wikipedia")

|                         | recall | precision   | f-measure |
|-------------------------|--------|-------------|-----------|
| Naïve Bayes             | 96.6   | 95.0        | 95.8      |
| C4.5                    | 96.8   | <b>96.5</b> | 96.6      |
| Support Vector Machines | 96.5   | 96.0        | 96.3      |

aus (Milne and Witten, 2008, "Learning to Link with Wikipedia")

DETECTION

# DER LINK-ERKENNUNGSPROZESS

Definition: Identifizierung der Begriffe

n-gramm: Zerlegung eines Strings in Substrings der Länge n

Beispiel: "Ich habe ein Brot gegessen." in einer 2-gramm

Zerlegung

- "Ich habe"
- "habe ein"
- "ein Brot"
- "Brot gegessen"

Detection:

- alle **n-gramms** erfassen.
- irrelevante Begriffe im Text ignorieren. (Threshold weniger als 6%)
- alle verbleibenden Begriffe mit dem Klassifikator disambiguieren.

# DER LINK-ERKENNUNGSPROZESS

Merkmale:

- Link Probability
- Relatedness
- Disambiguation Confidence
- Generality
- Location and Spread

Der Klassifikator:

- entscheidet welche Begriffe verlinkt werden sollen

# MERKMALE

Link Probability:

→ berechnet bei der Disambiguierung

Relatedness:

→ Relatedness jedes Begriffs zum Kontext. (berechnet bei der Disambiguierung)

# MERKMALE

Disambiguation Confidence:

→ wie sicher ist die Entscheidung bei der Disambiguation.

Generality:

→ unbekannte Begriffe für den Leser verlinken.

Location and Spread:

→ wie oft taucht ein Begriff in einem Dokument auf.

→ Der Begriff taucht häufig auf

→ die Link-Wahrscheinlichkeit steigt. (**frequency**)

→ an welcher Stelle taucht der Begriff auf.

→ am Anfang des Dokumentes (**first occurrence**)

→ am Ende des Dokumentes (**last occurrence**)

→ Abstand zwischen first und last occurrence (**spread**)

# EVALUATION

- 100 zufällige Artikel
- 9300 manuelle Links
- alle Markierungen weg

|                      | recall      | precision   | f-measure   |
|----------------------|-------------|-------------|-------------|
| Wikify (estimate)    | 46.5        | 49.6        | 48.0        |
| Wikify (upper bound) | 53.4        | 55.9        | 54.6        |
| New link detector    | <b>73.8</b> | <b>74.4</b> | <b>74.1</b> |

aus (Milne and Witten, 2008, "Learning to Link with Wikipedia")

**Abbildung:** das Ergebnis des Link-Erkennungsprozess

QUELLEN

# LITERATURANGABE

- Quinlan, J. R. (1993). C4.5: Programs for Machine Learning. Morgan Kaufmann Series in Machine Learning. Morgan Kaufmann, Amsterdam.
- Milne, D. and Witten, I. H. (2008b). Learning to Link with Wikipedia. In Proceedings of the ACM Conference on Information and Knowledge Management (CIKM'2008).
- William B. Cavnar and John M. Trenkle. N-gram-based text categorization. In In Proceedings of SDAIR-94, 3rd Annual Symposium on Document Analysis and Information Retrieval, pages 161–175, 1994.
- <https://en.wikipedia.org/wiki/c4.5>

Vielen Dank für  
Ihre Aufmerksamkeit!!