



UNIVERSITÄT
LEIPZIG

NLP Lab Session 5

Hidden Markov Models

Felix Helfer

helfer@saw-leipzig.de

24.06.24 / 01.07.24

HIDDEN MARKOV MODELS

Kurzer Rückblick:

- HMMs als Verfahren für das **Sequence Labeling**
- Also: Modell, welches jeder **Einheit** in einer **Sequenz** ein **Label** zuordnet
- Anwendung z.B. bei **Part-of-Speech-Tagging**

(im Deutschen übrigens Markow)

MARKOV CHAINS

- HMM als Erweiterung einer **Markov Chain** (Markowkette).
- Markov Chains berechnen WKT für **Sequenzen beobachtbarer Zustände**.

Markov Chain

$Q = q_1 \ q_2 \ \dots \ q_N$

Menge von N Zuständen

$A = a_{11} \ a_{12} \ \dots \ a_{N1} \ \dots \ a_{NN}$

Übergangswahrscheinlichkeitsmatrix A

$\pi = \pi_1, \ \pi_2, \ \dots, \ \pi_N$

Initiale Wahrscheinlichkeitsverteilung über den Zuständen

MARKOV CHAINS

- (Für Markowketten erster Ordnung) Enthält die **Markow-Annahme**. Für eine Zustandssequenz q_1, q_2, \dots, q_i gilt:

$$P(q_i = a | q_1 \dots q_{i-1}) = P(q_i = a | q_{i-1})$$

Markov Chain

$Q = q_1 \ q_2 \ \dots \ q_N$

Menge von N Zuständen

$A = a_{11} \ a_{12} \ \dots \ a_{N1} \ \dots \ a_{NN}$


Übergangswahrscheinlichkeitsmatrix A

$\pi = \pi_1, \pi_2, \dots, \pi_N$

Initiale Wahrscheinlichkeitsverteilung über den Zuständen

MARKOV CHAINS - BEISPIEL

Bigram-Modell




Übergangswahrscheinlichkeiten A

	kleine	Katzen	kratzen	kaum
π	0.6	0.2	0.1	0.1
kleine	0.0	0.8	0.1	0.1
Katzen	0.1	0.1	0.4	0.4
kratzen	0.3	0.4	0.0	0.3
kaum	0.3	0.4	0.3	0.0

→ Wahrscheinlichkeit von „Kleine Katzen kratzen kaum“ vs. „kaum kratzen kleine Katzen“?

MARKOV CHAINS - BEISPIEL

Bigram-Modell



Übergangswahrscheinlichkeiten A

	kleine	Katzen	kratzen	kaum
\pi	0.6	0.2	0.1	0.1
kleine	0.0	0.8	0.1	0.1
Katzen	0.1	0.1	0.4	0.4
kratzen	0.3	0.4	0.0	0.3
kaum	0.3	0.4	0.3	0.0

→ Wahrscheinlichkeit von „Kleine Katzen kratzen kaum“ vs. „kaum kratzen kleine Katzen“?

$$P(\text{„kleine Katzen kratzen kaum“}) = 0.6 * 0.8 * 0.4 * 0.3 = 0.0576$$

$$P(\text{„kaum kratzen kleine Katzen“}) = 0.1 * 0.3 * 0.3 * 0.8 = 0.0072$$

VON MARKOV CHAINS ZU HIDDEN MARKOV MODELS

Wieso sind Markov Chains nur bedingt für Aufgaben wie Part-of-Speech-Tagging geeignet?

VON MARKOV CHAINS ZU HIDDEN MARKOV MODELS

Wieso sind Markov Chains nur bedingt für Aufgaben wie Part-of-Speech-Tagging geeignet?

→ Die relevanten Zustände (also: POS-Tags) sind für gewöhnlich **versteckt** (d.h. nicht beobachtet).

Deshalb: Ein Modell für beobachtete *und* unbeobachtete Zustände (z.B. Token vs. POS-Tags) → **Hidden Markov Model**

HIDDEN MARKOV MODELS

Hidden Markov Model

$Q = q_1 \ q_2 \ \dots \ q_N$

Menge von N Zuständen

$A = a_{11} \ a_{12} \ \dots \ a_{N1} \ \dots \ a_{NN}$

Übergangswahrscheinlichkeitsmatrix A

$\pi = \pi_1, \pi_2, \dots, \pi_N$

Initiale Wahrscheinlichkeitsverteilung über den Zuständen

$O = o_1 \ o_2 \ \dots \ o_T$

Sequenz von T Beobachtungen, gezogen aus Vokabular V

$B = b_i(o_t)$

Sequenz von Beobachtungs-/Emissionswahrscheinlichkeiten

HIDDEN MARKOV MODELS

- Es gilt (für HMMs erster Ordnung), ebenfalls die **Markow-Annahme** (für eine *Zustandssequenz* q_1, q_2, \dots, q_i):

$$P(q_i=a|q_1 \dots q_{i-1}) = P(q_i=a|q_{i-1})$$

(WKT eines Zustands hängt nur ab vom vorigen Zustand q_{i-1})

- Des weiteren die **Ausgabeunabhängigkeit**:

$$P(o_i|q_1, \dots, q_i, \dots, q_T, o_1, \dots, o_i, \dots, o_T) = P(o_i|q_i)$$

(WKT einer Beobachtung o_i hängt nur ab vom Zustand q_i der sie hervorgebracht hat)

HIDDEN MARKOV MODELS - BEISPIEL

Zeit für ein **Beispiel** – wir erstellen unseren eigenen **Bigramm-HMM-Tagger**.

→ ***Was benötigen wir dafür?***

HIDDEN MARKOV MODELS - BEISPIEL

Training

Unsere Trainingsdaten:

the/D fake/Ad cats/N hunt/V stupid/Ad mice/N

mice/N fake/V the/D hunt/N

the/D cats/N fake/V mice/N cats/N

N: Nomen

V: Verb

D: Determinativ

Ad: Adjektiv

HIDDEN MARKOV MODELS - BEISPIEL

Übergangswahrscheinlichkeiten **A** (inklusive Start)

Bsp:
 $P(V|N)$:
3 Übergänge $N \rightarrow V$,
4 N insgesamt (mit
Übergängen)
 $\rightarrow P(V|N) = 3/4$

	N	V	D	Ad
π	0.33	0.0	0.67	0.0
N	0.25	0.75	0.0	0.0
V	0.33	0.0	0.33	0.33
D	0.67	0.0	0.0	0.33
Ad	1.0	0.0	0.0	0.0

HIDDEN MARKOV MODELS - BEISPIEL

Emissionswahrscheinlichkeiten B

Bsp:

$P(\text{cats}|N)$:

3 Vorkommen N mit „cats“,

7 Vorkommen N insgesamt

$\rightarrow P(\text{cats}|N) = 3/7$

	the	fake	cats	hunt	stupid	mice
N	0.0	0.0	0.43	0.14	0.0	0.43
V	0.0	0.67	0.0	0.33	0.0	0.0
D	1.0	0.0	0.0	0.0	0.0	0.0
Ad	0.0	0.5	0.0	0.0	0.5	0.0

HIDDEN MARKOV MODELS - BEISPIEL

Training abgeschlossen.

Jetzt: Beobachtungssequenz als Input

cats hunt stupid homework

→ **Was nun?**

HIDDEN MARKOV MODELS - BEISPIEL

Decoding

Input: Beobachtungssequenz $w_1 \dots w_n$

Ziel: wahrscheinlichste Tagsequenz $t_1 \dots t_n$

Also: $\hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(t_1 \dots t_n | w_1 \dots w_n)$

→ Wie ist das machbar mit unserem HMM-Tagger?

HIDDEN MARKOV MODELS - BEISPIEL

Decoding

$$(1) \quad \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(t_1 \dots t_n | w_1 \dots w_n)$$

HIDDEN MARKOV MODELS - BEISPIEL

Decoding

$$(1) \quad \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(t_1 \dots t_n | w_1 \dots w_n)$$

$$(2) \quad \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} \frac{P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n)}{P(w_1 \dots w_n)} \quad (\text{Bayes})$$

HIDDEN MARKOV MODELS - BEISPIEL

Decoding

$$(1) \quad \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(t_1 \dots t_n | w_1 \dots w_n)$$

$$(2) \quad \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} \frac{P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n)}{P(w_1 \dots w_n)} \quad (\text{Bayes})$$

$$(3) \quad \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n) \quad (\text{Vereinfachung})$$

HIDDEN MARKOV MODELS - BEISPIEL

$$(3) \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n)$$

HIDDEN MARKOV MODELS - BEISPIEL

$$(3) \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n)$$

$$(4) P(t_1 \dots t_n) \approx \prod_{i=1}^n P(t_i | t_{i-1}) \quad (\text{Markow-Annahme})$$

HIDDEN MARKOV MODELS - BEISPIEL

$$(3) \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n)$$

$$(4) P(t_1 \dots t_n) \approx \prod_{i=1}^n P(t_i | t_{i-1}) \quad (\text{Markow-Annahme})$$

$$(5) P(w_1 \dots w_n | t_1 \dots t_n) \approx \prod_{i=1}^n P(w_i | t_i) \quad (\text{Ausgabeunabhängigkeit})$$

HIDDEN MARKOV MODELS - BEISPIEL

$$(3) \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(w_1 \dots w_n | t_1 \dots t_n) P(t_1 \dots t_n)$$

$$(4) P(t_1 \dots t_n) \approx \prod_{i=1}^n P(t_i | t_{i-1}) \quad (\text{Markow-Annahme})$$

$$(5) P(w_1 \dots w_n | t_1 \dots t_n) \approx \prod_{i=1}^n P(w_i | t_i) \quad (\text{Ausgabeunabhängigkeit})$$

$$(6) \hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(t_1 \dots t_n | w_1 \dots w_n) \approx \underset{t_1 \dots t_n}{\operatorname{argmax}} \prod_{i=1}^n P(w_i | t_i) P(t_i | t_{i-1})$$

emission transition

HIDDEN MARKOV MODELS - BEISPIEL

Decoding

Input: *cats hunt stupid homework*

$$\hat{t}_{1:n} = \underset{t_1 \dots t_n}{\operatorname{argmax}} P(t_1 \dots t_n | w_1 \dots w_n) \approx \underset{t_1 \dots t_n}{\operatorname{argmax}} \prod_{i=1}^n P(w_i | t_i) P(t_i | t_{i-1})$$

emission transition

→ **Wie finden wir (auch für größere Tagsets) schnell eine Lösung?**

HIDDEN MARKOV MODELS - BEISPIEL

Decoding

Viterbi-Algorithmus

A:


	N	V	D	Ad
π	0.33	0.0	0.67	0.0
N	0.25	0.65	0.0	0.1
V	0.33	0.0	0.33	0.33
D	0.67	0.0	0.0	0.33
Ad	1.0	0.0	0.0	0.0

B:

	the	fake	cats	hunt	stupid	mice
N	0.0	0.0	0.43	0.14	0.0	0.43
V	0.0	0.67	0.0	0.33	0.0	0.0
D	1.0	0.0	0.0	0.0	0.0	0.0
Ad	0.0	0.5	0.0	0.0	0.5	0.0

HIDDEN MARKOV MODELS - BEISPIEL


Decoding - Viterbi-Algorithmus



$$P(N \mid \pi) * P(\text{cats} \mid N) = 0.1419$$

HIDDEN MARKOV MODELS - BEISPIEL

Decoding - Viterbi-Algorithmus




$$0.1419 * P(N | N) * P(\text{hunt} | N) = 0.005$$

$$0.1419 * P(V | N) * P(\text{hunt} | V) = 0.03$$

HIDDEN MARKOV MODELS - BEISPIEL

Decoding - Viterbi-Algorithmus



Hier: zwei Optionen für unterste Zelle → Maximum wählen!

$$\max(0.005 * P(\text{Ad} | N) * P(\text{stupid} | \text{Ad})) = 0.00025$$

$$0.03 * P(\text{Ad} | V) * P(\text{stupid} | \text{Ad}) = 0.00495)$$

HIDDEN MARKOV MODELS - BEISPIEL

Decoding - Viterbi-Algorithmus

*cats hunt stupid **homework***

→ Was tun bei **Out-of-Vocabulary-Worten?**

HIDDEN MARKOV MODELS - BEISPIEL

Decoding - Viterbi-Algorithmus

*cats hunt stupid **homework***


→ Was tun bei **Out-of-Vocabulary-Worten?**

Zum Beispiel:

- Tag-Häufigkeiten von Wörtern mit Häufigkeit 1 heranziehen
- Morphologie o.äh. berücksichtigen
- Nur $P(t_i|t_{i-1})$ beachten (**hier verwendet**)

HIDDEN MARKOV MODELS - BEISPIEL


Decoding - Viterbi-Algorithmus



$$0.00495 * P(N \mid Ad) = 0.00495$$

HIDDEN MARKOV MODELS - BEISPIEL

Decoding - Viterbi-Algorithmus



Zuletzt: Backtracing des optimalen Pfades ($N \rightarrow Ad \rightarrow V \rightarrow N$ für „N V Ad N“)

ZUSAMMENFASSUNG

Heute besprochen:

- Markov Chains
- Hidden Markov Models
- Viterbi-Algorithmus

Quelle:

Danke fürs Zuhören!

D. Jurafsky, J. H. Martin: *Speech and Language Processing* (3rd ed. Draft),
<https://web.stanford.edu/~jurafsky/slp3/>, 2021