


Map Matching

Problem:

GPS-Punkte der Trajektorie weisen einen relativ großen Abstand zueinander auf.




Map Matching

Problem:

GPS-Punkte der Trajektorie weisen einen relativ großen Abstand zueinander auf.


→ Direkte Verbindung zwischen Punkten ist schlechte Näherung



Map Matching

Problem:

GPS-Punkte der Trajektorie weisen einen relativ großen Abstand zueinander auf.



Ergebnis mit minimaler
Fréchet-Distanz


Idee:

Fahrer wählen bevorzugt **kürzeste Wege** im Straßennetz.

Map Matching

Problem:

GPS-Punkte der Trajektorie weisen einen relativ großen Abstand zueinander auf.



Idee:

Fahrer wählen bevorzugt **kürzeste Wege** im Straßennetz.

Map Matching

Ansatz über kürzeste Wege

Lou et al.:

Map-Matching for Low-Sampling-Rate GPS Trajectories,
Proc. ACM GIS 2009.

P. Newson und J. Krum:
Hidden Markov Map Matching
Proc. ACM GIS 2009

**Ein Punkt etwa alle zwei Minuten
(z.B. zur Aufzeichnung & Analyse von
Taxirouten)**

Eisner et al.:

Algorithms for Matching and Predicting Trajectories,
Proc. ALENEX 2011

Map Matching

Ansatz über kürzeste Wege

Lou et al.:

Map-Matching for Low-Sampling-Rate GPS Trajectories,
Proc. ACM GIS 2009.

P. Newson und J. Krum:

Hidden Markov Map Matching Through Noise and Sparseness,
Proc. ACM GIS 2009

= Maximum-likelihood estimation + Markov Chains + Hidden Markov Models

Eisner et al.:

Algorithms for Matching and Predicting Trajectories,
Proc. ALENEX 2011

Maximum-likelihood estimation

Probability versus Likelihood

- Flipping a coin:

- $P[\textit{heads}] = p$

- $P[\textit{tails}] = 1 - p$

- Do three independent flips.

- The coin is fair ($p = \frac{1}{2}$).

- What is the **probability** of getting outcome $x=(H,H,T)$?

Model

Parameter value

Outcome?



p is not a random variable!

$$P[x = (H, H, T) ; p = \frac{1}{2}] \quad \cancel{P[x = (H, H, T) ; p = \frac{1}{2}]} = \frac{1}{2} \cdot \frac{1}{2} \cdot (1 - \frac{1}{2}) = 0.125$$

Maximum-likelihood estimation

Probability versus Likelihood

- Flipping a coin:

- $P[\textit{heads}] = p$

- $P[\textit{tails}] = 1 - p$

Model

- Did three independent flips.

Parameter value?


- The result was $\mathbf{x}=(\mathbf{H},\mathbf{H},\mathbf{T})$.

Outcome

- What is the **likelihood** that the coin is fair ($\mathbf{p} = \mathbf{1/2}$)?

Maximum-likelihood estimation

Likelihood functions

- Given the outcome x ,
how “likely” is a certain parameter value θ ?
 - Assuming parameter value θ ,
what is the probability of outcome x ?
 - Define *likelihood function* $\mathcal{L}(\theta|x) = P[x; \theta]$
 - The result was **(H,H,T)**.
 - What is the **likelihood** that the coin is fair (**$p = 1/2$**)?
 - $\mathcal{L}[p = 1/2 | x = (H, H, T)] = 1/2 \cdot 1/2 \cdot 1/2 = 0.125$
 - $\mathcal{L}[p = 0.1 | x = (H, H, T)] = 0.1 \cdot 0.1 \cdot 0.9 = 0.009$
 - $\mathcal{L}[p = 2/3 | x = (H, H, T)] = 2/3 \cdot 2/3 \cdot 1/3 = 0.\overline{148}$
- 
- Not a probability!

Maximum-likelihood estimation

Predictions versus Estimates

- *Most probable outcome*
 - Given parameter $p = 2/3$...
 - ... the most probable outcome is (H, H, H) .
- *Maximum-Likelihood Estimate (“MLE”)*
 - Given outcome (T, H, T) ...
 - ...maximum-likelihood estimate is $p = 1/3$.
 - This value of p “best explains the observed outcome.”
 - This value of p makes the outcome “least surprising.”

Maximum-likelihood estimation

Maximum-likelihood map matching?

- **Model? Parameter? Outcome?**
- *Most probable outcome*
 - Given a path in a road network ...
 - ... what is the most probable GPS trajectory to observe? (Noisy.)
- *Maximum-Likelihood Estimate (MLE)*
 - Given the observed GPS trajectory (noisy) ...
 - ... what is the most likely path through the road network?
 - “Which path through the network best explains the observed GPS trajectory?”

Пафну́тий Чебышёв

1821 - 1894

Ма́рков Chains



Андре́й Ма́рков

1856 - 1922

Георгі́й Воро́ний

1868 - 1908

Бори́с Делоне́

1890 - 1980

Wacław Sierpiński

1882 - 1969

Chebyshev
1821 - 1894

Мáркoв Chains



Markov
1856 - 1922

Voronoi
1856 - 1922

Delaunay
1890 - 1980

Sierpinski
1882 - 1969



Markov Chains



- Sequence of random variables X_1, X_2, X_3, \dots
- **Markov Property:**
$$\Pr[X_{n+1} \mid X_n = x_n, X_{n-1} = x_{n-1}, \dots, X_1 = x_1]$$
$$= \Pr[X_{n+1} \mid X_n = x_n]$$
- “Given the present,
the future is independent of the past.”
- Represent as $\Pr[X_1], \Pr[X_2|X_1], \Pr[X_3|X_2], \dots$

Markov Chains

Example

- Possible states $Z = \{Sonne, Regen\}$
- $\Pr[X_1 = Regen] = 0.3$
- $\Pr[X_1 = Sonne] = 0.7$
- $\Pr[X_{n+1} = Regen \mid X_n = Regen] = 0.7$
- $\Pr[X_{n+1} = Sonne \mid X_n = Regen] = 0.3$
- $\Pr[X_{n+1} = Regen \mid X_n = Sonne] = 0.2$
- $\Pr[X_{n+1} = Sonne \mid X_n = Sonne] = 0.8$

Markov Chains


Example

- Possible states $Z = \{Sonne, Regen\}$

- $\Pr[X_1 = Regen] = 0.3$

$\Pr[X_2 = Sonne] ?$

- $\Pr[X_1 = Sonne] = 0.7$



Markov Chains


Example

- Possible states $Z = \{Sonne, Regen\}$

- $\Pr[X_2 = Regen] = 0.35$

$\Pr[X_3 = Regen] ?$

- $\Pr[X_2 = Sonne] = 0.65$



Hidden Markov Models

- Markov Chain
 - At every time step, it has a certain **state**
- But the states are **hidden**
 - We cannot “see” its state
- Emission (“output”)
 - At every time step, get an **observation**
 - Probability distribution depends on state
 - Emission at each step is independent

Hidden Markov Model

Hidden Markov Model

Gegeben:

- Beobachtungen $O = \langle o_1, \dots, o_n \rangle$, je eine pro Zeitpunkt

Hidden Markov Model

Gegeben:

- Beobachtungen $O = \langle o_1, \dots, o_n \rangle$, je eine pro Zeitpunkt
- mögliche Systemzustände Z

Hidden Markov Model

Gegeben:

- Beobachtungen $O = \langle o_1, \dots, o_n \rangle$, je eine pro Zeitpunkt
- mögliche Systemzustände Z
- für jeden Systemzustand $z \in Z$ und jede Beobachtung o
 - die Wahrscheinlichkeit $\Pr(o \mid z)$ oder
 - die Wahrscheinlichkeitsdichte $f(o \mid z)$,dass o bei Zustand z beobachtet wird

Hidden Markov Model

Gegeben:

- Beobachtungen $O = \langle o_1, \dots, o_n \rangle$, je eine pro Zeitpunkt
- mögliche Systemzustände Z
- für jeden Systemzustand $z \in Z$ und jede Beobachtung o
 - die Wahrscheinlichkeit $\Pr(o \mid z)$ oder
 - die Wahrscheinlichkeitsdichte $f(o \mid z)$,dass o bei Zustand z beobachtet wird
- für jedes Paar von Zuständen $z_1, z_2 \in Z$ die Wahrscheinlichkeit $\Pr(z_2 \mid \text{was } z_1 \text{ before})$,
also die Wahrscheinlichkeit für z_2 bei Kenntnis, dass zuvor z_1 vorherrschte (*Übergangswahrscheinlichkeit*)

Hidden Markov Model

Gegeben:

- Beobachtungen $O = \langle o_1, \dots, o_n \rangle$, je eine pro Zeitpunkt
- mögliche Systemzustände Z
- für jeden Systemzustand $z \in Z$ und jede Beobachtung o
 - die Wahrscheinlichkeit $\Pr(o \mid z)$ oder
 - die Wahrscheinlichkeitsdichte $f(o \mid z)$,dass o bei Zustand z beobachtet wird
- für jedes Paar von Zuständen $z_1, z_2 \in Z$ die Wahrscheinlichkeit $\Pr(z_2 \mid \text{was } z_1 \text{ before})$,
also die Wahrscheinlichkeit für z_2 bei Kenntnis, dass zuvor z_1 vorherrschte (*Übergangswahrscheinlichkeit*)
- für jeden Zustand $z \in Z$ die (a-priori-)Wahrscheinlichkeit $\Pr(z)$

Hidden Markov Model

Gesucht:

Folge $S = \langle z_1, \dots, z_n \rangle$ von Zuständen, die sich am besten mit gegebenen Beobachtungen erklären lässt, also $\Pr(S | O)$ maximiert.

$$\Pr(S | O) =$$

Hidden Markov Model

Gesucht:

Folge $S = \langle z_1, \dots, z_n \rangle$ von Zuständen, die sich am besten mit gegebenen Beobachtungen erklären lässt, also $\Pr(S | O)$ maximiert.

$$\Pr(S | O) = f(O | S) \cdot \Pr(S) / f(O)$$

Hidden Markov Model

Gesucht:

Folge $S = \langle z_1, \dots, z_n \rangle$ von Zuständen, die sich am besten mit gegebenen Beobachtungen erklären lässt, also $\Pr(S | O)$ maximiert.

$$\Pr(S | O) = f(O | S) \cdot \Pr(S) / f(O)$$



$$f(O | S) = f(o_1 | z_1) \cdot \dots \cdot f(o_n | z_n)$$

Hidden Markov Model

Gesucht:

Folge $S = \langle z_1, \dots, z_n \rangle$ von Zuständen, die sich am besten mit gegebenen Beobachtungen erklären lässt, also $\Pr(S | O)$ maximiert.

$$\Pr(S | O) = f(O | S) \cdot \Pr(S) / f(O)$$



$$\Pr(S) = \Pr(z_1) \cdot \Pr(z_2 | \text{was } z_1 \text{ before}) \cdot \dots \cdot \Pr(z_n | \text{was } z_{n-1} \text{ before})$$

Hidden Markov Model

$$f(o_1 | z_1^0) \cdot \Pr(z_2^0 | \text{was } z_1^0 \text{ before}) \quad f(o_2 | z_2^0) \cdot \Pr(z_3^0 | \text{was } z_2^0 \text{ before})$$


$$\Pr(z_1^0)$$

$$f(o_3 | z_3^0)$$




Hidden Markov Model

$$f(o_1 | z_1^0) \cdot \Pr(z_2^0 | \text{was } z_1^0 \text{ before}) \quad f(o_2 | z_2^0) \cdot \Pr(z_3^0 | \text{was } z_2^0 \text{ before})$$



s - t -path of maximum weight product
= state sequence S that maximizes $\Pr(S | O)$



Hidden Markov Model – ein Beispiel

Gegeben:

- Folge von Beobachtungen

$$O = \langle o_1, \dots, o_n \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$$

- Menge möglicher Systemzustände: $Z = \{\text{Sonne, Regen}\}$

- Beobachtungswahrscheinlichkeiten:

$$\Pr(\text{nass} \mid \text{Sonne}) = 0.1$$

$$\Pr(\text{trocken} \mid \text{Sonne}) = 0.9$$

$$\Pr(\text{nass} \mid \text{Regen}) = 0.95$$

$$\Pr(\text{trocken} \mid \text{Regen}) = 0.05$$

- Übergangswahrscheinlichkeiten:

$$\Pr(\text{Regen} \mid \text{zuvor Regen}) = 0.7$$

$$\Pr(\text{Sonne} \mid \text{zuvor Regen}) = 0.3$$


$$\Pr(\text{Regen} \mid \text{zuvor Sonne}) = 0.2$$

$$\Pr(\text{Sonne} \mid \text{zuvor Sonne}) = 0.8$$

- A-Priori-Wahrscheinlichkeiten: $\Pr(\text{Regen}) = 0.3$, $\Pr(\text{Sonne}) = 0.7$


Gesucht: Folge $S = \langle s_1, \dots, s_n \rangle$ von Zuständen, so dass $\Pr(S \mid O)$ maximal ist.

Hidden Markov Model – ein Beispiel



$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$


Hidden Markov Model – ein Beispiel



$$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$$

Hidden Markov Model – ein Beispiel


$$\Pr(o_1 \mid \text{Sonne}) \cdot \Pr(\text{Sonne} \mid \text{war Sonne zuvor})$$



$$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$$


Hidden Markov Model – ein Beispiel

$\Pr(\text{nass} \mid \text{Sonne}) \cdot \Pr(\text{Sonne} \mid \text{war Sonne zuvor})$




$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$

Hidden Markov Model – ein Beispiel




$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$

Hidden Markov Model – ein Beispiel




$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$

Hidden Markov Model – ein Beispiel




$$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass}, \text{nass}, \text{trocken}, \text{nass}, \text{trocken} \rangle$$

Hidden Markov Model – ein Beispiel




$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$

Hidden Markov Model – ein Beispiel



$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$


Hidden Markov Model – ein Beispiel



$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$


Hidden Markov Model – ein Beispiel

\log_2




$\langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$


Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel




Hidden Markov Model – ein Beispiel



Hidden Markov Model – ein Beispiel



Hidden Markov Model – ein Beispiel



$O = \langle o_1, o_2, o_3, o_4, o_5 \rangle = \langle \text{nass, nass, trocken, nass, trocken} \rangle$

$S = \langle \text{Regen, Regen, Sonne, Sonne, Sonne} \rangle$

Algorithmus

LongestPath(directed acyclic graph $G = (V, A)$)

Bring V in topologische Ordnung $\rightarrow v_1, \dots, v_n$

$v_1.d = 0$

$v_1.\pi = nil$

for $j = 2$ **to** n **do**

$v_j.d = -\infty$

$v_j.\pi = nil$

for $v_i v_j \in A$ **do**

if $v_i.d + w(v_i v_j) > v_j.d$ **then**

$v_j.d = v_i.d + w(v_i v_j)$

$v_j.\pi = v_i$

$u.d$: Länge des längsten Wegs von v_1 nach u

$u.\pi$: Vorgänger von u im längsten Weg von v_1 nach u

$w(uv)$: Gewicht von Kante uv

Algorithmus

LongestPath(directed acyclic graph $G = (V, A)$)

Bring V in topologische Ordnung $\rightarrow v_1, \dots, v_n$

$v_1.d = 0$

$v_1.\pi = nil$

for $j = 2$ **to** n **do**

$v_j.d = -\infty$

$v_j.\pi = nil$

for $v_i v_j \in A$ **do**

if $v_i.d + w(v_i v_j) > v_j.d$ **then**

$v_j.d = v_i.d + w(v_i v_j)$

$v_j.\pi = v_i$

$u.d$: Länge des längsten Wegs von v_1 nach u

$u.\pi$: Vorgänger von u im längsten Weg von v_1 nach u

$w(uv)$: Gewicht von Kante uv

Laufzeit: $O(|V| + |A|)$

Algorithmus

LongestPath(directed acyclic graph $G = (V, A)$)

Bring V in topologische Ordnung $\rightarrow v_1, \dots, v_n$

$v_1.d = 0$

$v_1.\pi = nil$

for $j = 2$ **to** n **do**

$v_j.d = -\infty$

$v_j.\pi = nil$

for $v_i v_j \in A$ **do**

if $v_i.d + w(v_i v_j) > v_j.d$ **then**

$v_j.d = v_i.d + w(v_i v_j)$

$v_j.\pi = v_i$

$u.d$: Länge des längsten Wegs von v_1 nach u

$u.\pi$: Vorgänger von u im längsten Weg von v_1 nach u

$w(uv)$: Gewicht von Kante uv

Laufzeit: $O(|V| + |A|)$

Laufzeit Dijkstra: $O(|V| \log |V| + |A|)$