

Universität Potsdam
Institut für Informatik
Lehrstuhl Maschinelles Lernen

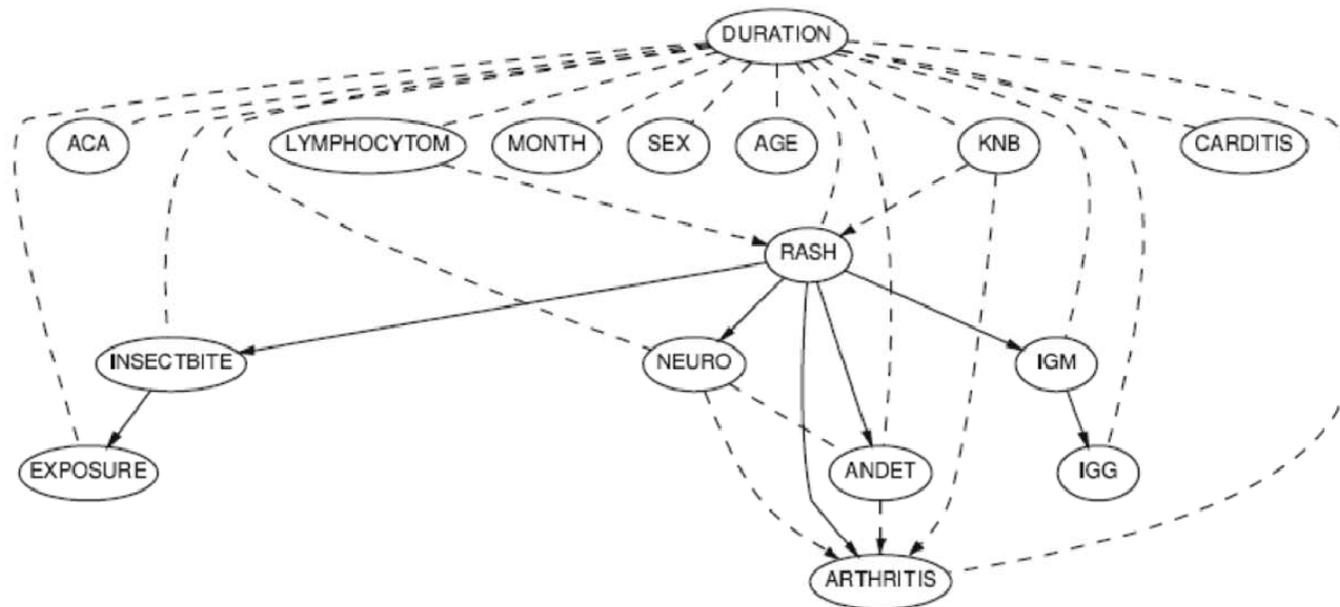


Graphische Modelle

Christoph Sawade/Niels Landwehr/Tobias Scheffer

Graphische Modelle: Inferenz

- Wir haben eine Domäne durch gemeinsame Verteilung aller Zufallsgrößen modelliert
- Inferenz: Wahrscheinlichkeit dafür, dass Variablen bestimmte Werte annehmen, gegeben Informationen über andere Variablen?



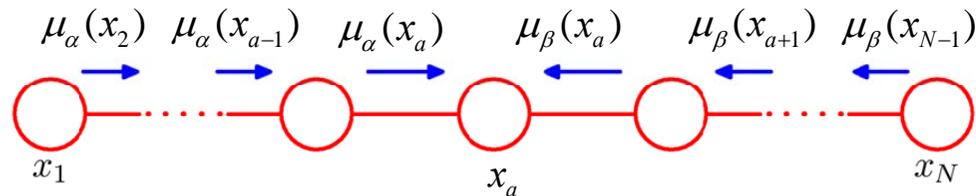
Überblick

- Gerichtete Graphische Modelle: Bayessche Netze
- Graphische Modelle im Maschinellen Lernen
- Inferenz in Graphischen Modellen
 - ◆ Exakte Inferenz: Message-Passing
 - ◆ Approximative Inferenz: Sampling

Exakte Inferenz: Message-Passing

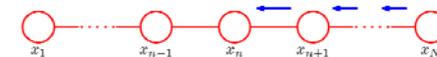
- Message Passing Algorithmus auf linearer Kette

$$p(\mathbf{x}) = \prod_{i=1}^N \psi_{i,i+1}(x_i, x_{i+1})$$



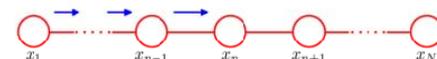
$$\mu_\beta(x_N) = \mathbf{1}$$

Für $k = N-1, \dots, a$:
$$\mu_\beta(x_k) = \sum_{x_{k+1}} \psi_{k,k+1}(x_k, x_{k+1}) \mu_\beta(x_{k+1})$$



$$\mu_\alpha(x_1) = \mathbf{1}$$

Für $k = 2, \dots, a$:
$$\mu_\alpha(x_k) = \sum_{x_{k-1}} \psi_{k-1,k}(x_{k-1}, x_k) \mu_\alpha(x_{k-1})$$



$p(x_a) = \mu_\beta(x_a) \mu_\alpha(x_a) \leftarrow$ Randverteilung über Anfragevariable x_a :
Produkt der Nachrichten

Message-Passing mit Evidenz

- Bisher Randverteilung $p(x_a)$ ohne Evidenz bestimmt
- Was ist wenn wir Evidenz haben?

$$\text{Notation: } \{x_1, \dots, x_N\} = \left\{ \underbrace{x_a}_{\text{Anfrage-Variable}}, \underbrace{x_{i_1}, \dots, x_{i_m}}_{\text{Evidenz-Variablen}}, \underbrace{x_{j_1}, \dots, x_{j_k}}_{\text{restliche Variablen}} \right\}$$

- Bedingte Verteilung

$$p(x_a | x_{i_1}, \dots, x_{i_m}) = \frac{p(x_a, x_{i_1}, \dots, x_{i_m})}{p(x_{i_1}, \dots, x_{i_m})}$$
$$= \frac{1}{Z} p(x_a, x_{i_1}, \dots, x_{i_m})$$

Z einfach zu berechnen

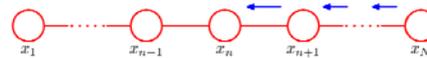
(Normalisierter univariate Verteilung)

$$= \frac{1}{Z} \sum_{x_{j_1}} \dots \sum_{x_{j_k}} p(\underbrace{x_{j_1}, \dots, x_{j_k}}_{\text{aussummieren}}, \underbrace{x_a, x_{i_1}, \dots, x_{i_m}}_{\text{fest}})$$

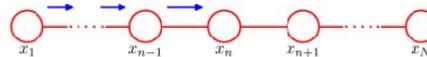
Message-Passing mit Evidenz

- Ziel: $p(x_a, x_{i_1}, \dots, x_{i_m}) = ?$
- Leichte Modifikation des Message-Passing Algorithmus
 - ◆ Wir berechnen wie bisher Nachrichten

$$\mu_\beta(x_{N-1}), \dots, \mu_\beta(x_a)$$



$$\mu_\alpha(x_2), \dots, \mu_\alpha(x_a)$$



- ◆ Falls x_{k+1} unbeobachtet ist, summieren wir diesen Knoten aus

$$k+1 \notin \{i_1, \dots, i_m\} \Rightarrow \mu_\beta(x_k) = \sum_{x_{k+1}} \psi_{k,k+1}(x_k, x_{k+1}) \mu_\beta(x_{k+1})$$

- ◆ Falls x_{k+1} beobachtet ist, verwenden wir nur den entsprechenden Summanden

x_{k+1} beobachteter Wert (Evidenz)

$$k+1 \in \{i_1, \dots, i_m\} \Rightarrow \mu_\beta(x_k) = \psi_{k,k+1}(x_k, x_{k+1}) \mu_\beta(x_{k+1})$$

Message-Passing mit Evidenz

- Ebenso für $\mu_\alpha(x_k)$

$$\mu_\alpha(x_k) = \begin{cases} \sum_{x_{k-1}} \psi_{k-1,k}(x_{k-1}, x_k) \mu_\alpha(x_{k-1}) : k-1 \notin \{i_1, \dots, i_m\} & \text{(Knoten nicht beobachtet)} \\ \psi_{k-1,k}(x_{k-1}, x_k) \mu_\alpha(x_{k-1}) : k-1 \in \{i_1, \dots, i_m\} & \text{(Knoten beobachtet)} \end{cases}$$

- Jetzt gilt

$$p(x_a, x_{i_1}, \dots, x_{i_m}) = \mu_\alpha(x_a) \mu_\beta(x_a)$$

- Laufzeit für Inferenz mit Evidenz immer noch $O(NK^2)$

Beispiel: Markov Modelle

- Beispiel für Inferenz auf linearer Kette: Markov Modelle
- Markov Modelle: einfache Modelle für dynamische probabilistische Prozesse
 - ◆ Prozess, der verschiedene Zustände annehmen kann
 - ◆ Zufallsvariable X_t repräsentiert den Zustand zur Zeit t
 - ◆ Diskrete Zeitpunkte $t=1, \dots, T$
- Beispiel: Wetter
 - ◆ Zufallsvariable $X_t =$ Wetter am Tag t
 - ◆ Zwei mögliche Zustände, Regen und Sonne

Beispiel: Markov Modelle

- Modellierung:

- ◆ Prozess wird in einem zufällig gewählten Zustand gestartet:

Verteilung über Startzustände $p(x_1)$

- ◆ In jedem Schritt geht der Prozess in einen neuen Zustand über, abhängig nur vom gegenwärtigen Zustand (vereinfachende Annahme!)

Verteilung über nächsten Zustand $p(x_{t+1} | x_t)$

- Unabhängigkeitsannahme:

$$\forall t: p(x_{t+1} | x_1, \dots, x_t) = p(x_{t+1} | x_t) \quad \text{"Markov" Eigenschaft}$$

- Übergangswahrscheinlichkeiten hängen nicht von t ab:

$$\forall t: p(x_{t+1} | x_t) = p(x_t | x_{t-1}) \quad \text{"Homogener" Prozess}$$

Beispiel: Markov Modelle

- Gemeinsame Wahrscheinlichkeit über alle Zustände

$$\begin{aligned} p(x_1, \dots, x_T) &= \prod_{t=1}^T p(x_t | x_1, \dots, x_{t-1}) \\ &= p(x_1) \prod_{t=2}^T p(x_t | x_{t-1}) \end{aligned}$$

„Zukunft ist unabhängig von der Vergangenheit gegeben Gegenwart“

- Darstellung als graphisches Modell:

Beispiel: Markov Modelle

- Gemeinsame Wahrscheinlichkeit über alle Zustände

$$p(x_1, \dots, x_T) = \prod_{t=1}^T p(x_t | x_1, \dots, x_{t-1})$$

$$= p(x_1) \prod_{t=2}^T p(x_t | x_{t-1})$$

„Zukunft ist unabhängig von der Vergangenheit gegeben Gegenwart“

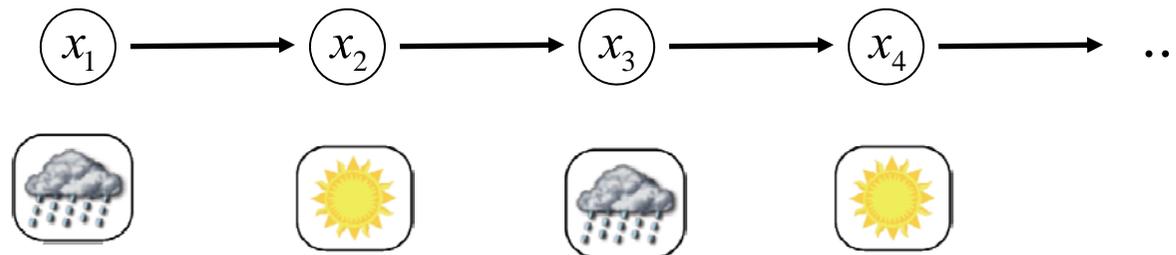
- Darstellung als graphisches Modell:



Beispiel: Markov Modelle

- Beispiel Markov Modell:

- ◆ Zustand $x_t =$ Wetter am Tag t
- ◆ Zwei mögliche Zustände, Regen und Sonne



- ◆ Verteilungen

$$p(x_1 = s) = 0.5$$

$$p(x_1 = r) = 0.5$$

$$p(x_t = s | x_{t-1} = s) = 0.8$$

$$p(x_t = r | x_{t-1} = s) = 0.2$$

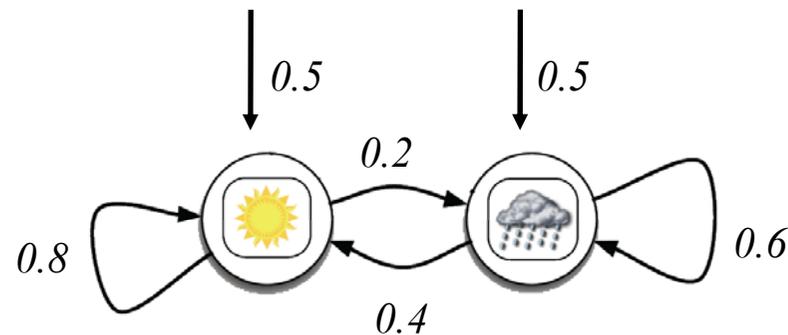
$$p(x_t = s | x_{t-1} = r) = 0.4$$

$$p(x_t = r | x_{t-1} = r) = 0.6$$

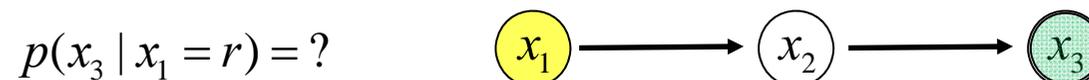
Wahrscheinlichkeit, dass morgen die Sonne scheint, gegeben dass es heute regnet.

Beispiel: Markov Modelle

- Markov Modelle entsprechen probabilistischen endlichen Automaten



- Beispiel Inferenzproblem:
 - ◆ Wie ist das Wetter übermorgen, gegeben dass es heute regnet?



Beispiel: Markov Modelle

- Berechnung mit Message-Passing Algorithmus



- Zu berechnende Nachrichten: $\mu_\alpha(x_1), \mu_\alpha(x_2), \mu_\alpha(x_3); \mu_\beta(x_3)$

$$\mu_\alpha(x_k) = \begin{cases} \sum_{x_{k-1}} \psi_{k-1,k}(x_{k-1}, x_k) \mu_\alpha(x_{k-1}) : k-1 \notin \{i_1, \dots, i_m\} & \text{(Knoten nicht beobachtet)} \\ \psi_{k-1,k}(x_{k-1}, x_k) \mu_\alpha(x_{k-1}) : k-1 \in \{i_1, \dots, i_m\} & \text{(Knoten beobachtet)} \end{cases}$$

Initialisierung: $\mu_\alpha(x_1) = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$

x_1 beob. Knoten: $\mu_\alpha(x_2) = p(x_1)p(x_2 | x_1)\mu_\alpha(x_1) = \begin{pmatrix} 0.5 \cdot 0.4 \\ 0.5 \cdot 0.6 \end{pmatrix} = \begin{pmatrix} 0.2 \\ 0.3 \end{pmatrix}$

$\swarrow \mu_\alpha(x_2 = s)$
 $\swarrow \mu_\alpha(x_2 = r)$

x_2 unbeob. Knoten: $\mu_\alpha(x_3) = \sum_{x_2 \in \{s,r\}} p(x_3 | x_2)\mu_\alpha(x_2) = \begin{pmatrix} 0.8 \cdot 0.2 + 0.4 \cdot 0.3 \\ 0.2 \cdot 0.2 + 0.6 \cdot 0.3 \end{pmatrix} = \begin{pmatrix} 0.28 \\ 0.22 \end{pmatrix}$

$\swarrow \mu_\alpha(x_3 = s)$
 $\swarrow \mu_\alpha(x_3 = r)$

Beispiel: Markov Modelle

- Berechnung mit Message-Passing Algorithmus



- Nachrichten: $\mu_\alpha(x_1), \mu_\alpha(x_2), \mu_\alpha(x_3); \mu_\beta(x_3)$

Initialisierung: $\mu_\beta(x_3) = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$

$$p(x_3 | x_1 = r) = \frac{1}{Z} \mu_\alpha(x_3) \mu_\beta(x_3) = \frac{1}{Z} \begin{pmatrix} 0.28 \\ 0.22 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \frac{1}{Z} \begin{pmatrix} 0.28 \\ 0.22 \end{pmatrix}$$

$$Z = 0.28 + 0.22 = 0.5$$

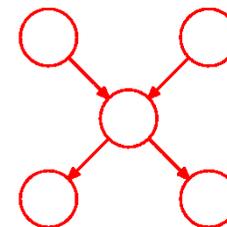
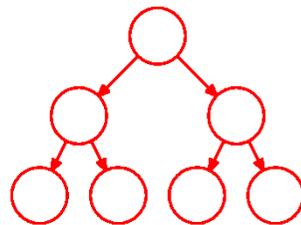
$$p(x_3 = s | x_1 = r) = 0.56$$

$$p(x_3 = r | x_1 = r) = 0.44$$

Inferenz in Allgemeinen Graphen

- Bisher nur Spezialfall: Inferenz auf linearer Kette
- Die Grundidee des Message-Passing funktioniert auch auf allgemeineren Graphen
- Erweiterung: Exakte Inferenz auf *Polytrees*
 - ◆ Polytree: Gerichteter Graph, in dem es zwischen zwei Knoten immer genau einen ungerichteten Pfad gibt
 - ◆ Etwas allgemeiner als gerichteter Baum

Gerichteter
Baum

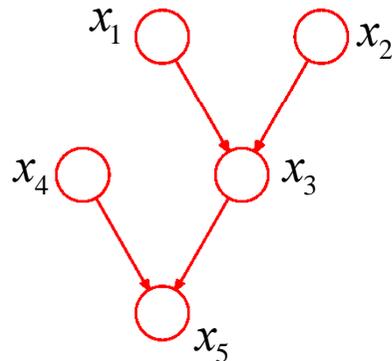


Polytree

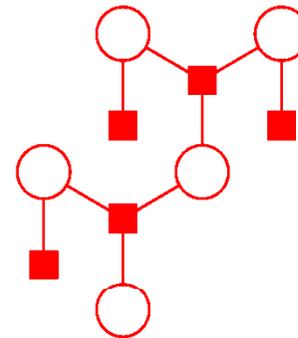
Inferenz in Allgemeinen Graphen

- Grundidee Message-Passing auf Polytrees:
 - ◆ Umwandlung in *Faktor-Graph* (ungerichteter Baum)

Ursprünglicher Graph



Faktor-Graph



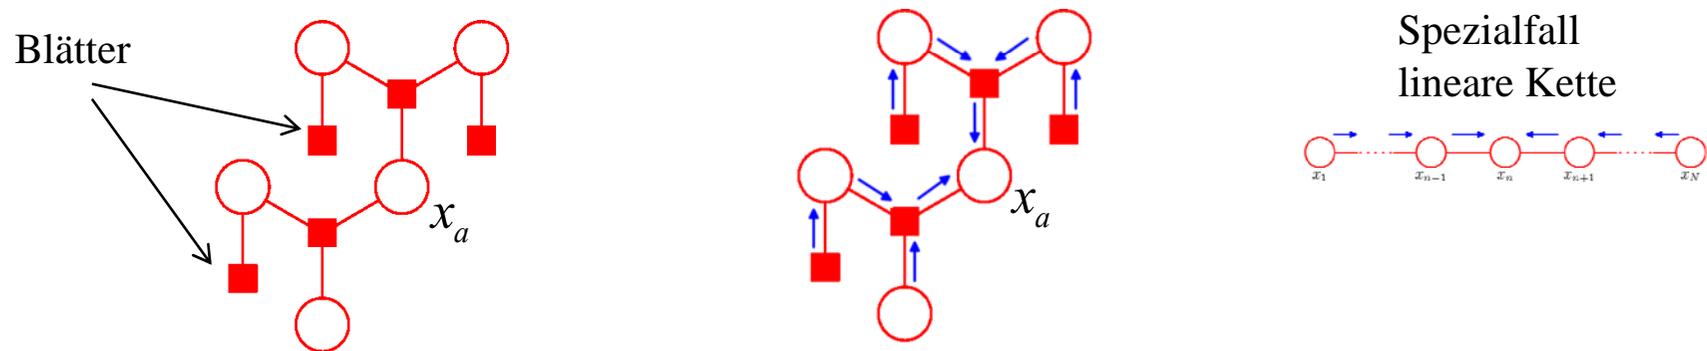
Gemeinsame Verteilung

$$p(x_1, x_2, x_3, x_4, x_5) = p(x_1)p(x_2)p(x_3 | x_1, x_2)p(x_4) \underbrace{p(x_5 | x_3, x_4)}_{\text{Faktor}}$$

- Faktor-Knoten
 - Für jeden Faktor in der gemeinsamen Verteilung gibt es einen Faktor-Knoten
 - Ungerichtete Kanten von den Faktor-Knoten zu den im Faktor auftauchenden Variablen

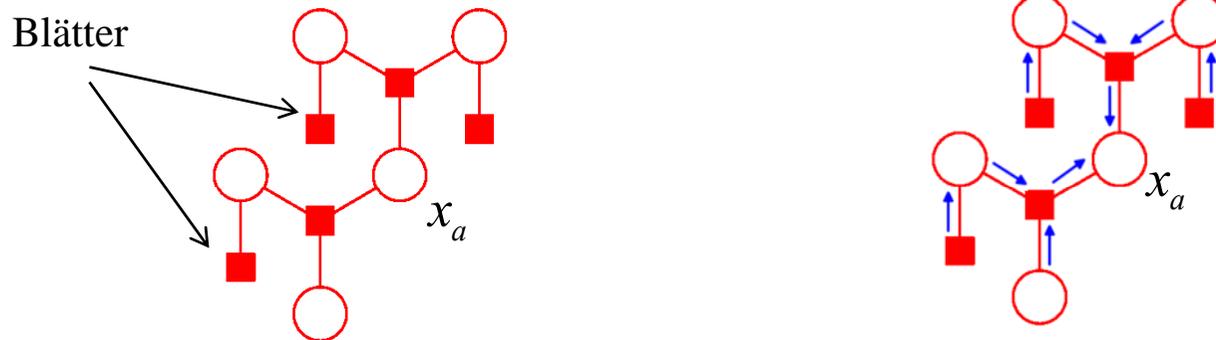
Inferenz in Allgemeinen Graphen (Skizze)

- Falls der ursprüngliche Graph ein Polytree war, ist der Faktor-Graph ein ungerichteter Baum (dh zyklfrei).



- Betrachten Anfragevariable x_a als Wurzel des Baumes
- Nachrichten von den Blättern zur Wurzel schicken (immer eindeutiger Pfad, weil Baum)
- Es gibt zwei Typen von Nachrichten: Faktor-Nachrichten und Variablen-Nachrichten

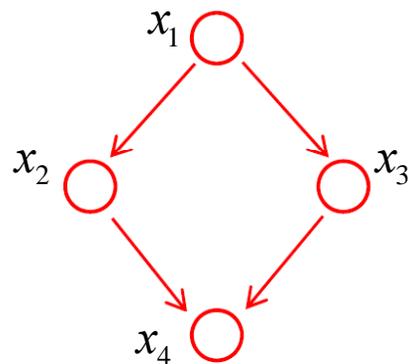
Inferenz in Allgemeinen Graphen (Skizze)



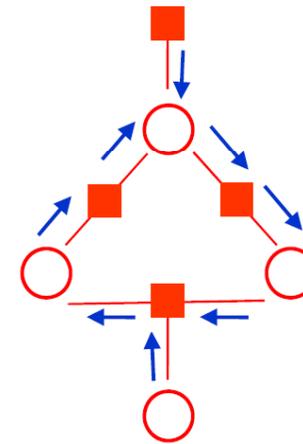
- Nachrichten werden „verschmolzen“, dabei müssen wir über mehrere Variablen summieren
- Grundidee dieselbe wie bei Inferenz auf der linearen Kette: geschicktes Aussummieren
- Laufzeit abhängig von Graphstruktur, exponentiell im worst-case
- Details im Bishop-Textbuch („Sum-Product“ Algorithmus)

Inferenz in Allgemeinen Graphen

- Inferenz in Graphen, die keine Polytrees sind?
- Approximativer Ansatz: Iteratives Message-Passing Schema, wegen Zyklen im Graph nicht exakt



$$p(\mathbf{x}) = p(x_1)p(x_2 | x_1)p(x_3 | x_1)p(x_4 | x_2, x_3)$$



„Loopy Belief Propagation“

- Alternative für exakte Inferenz in allgemeinen Graphen:
 - ◆ Graph in einen äquivalenten azyklischen Graphen umwandeln
 - ◆ „Junction Tree“ Algorithmus, (i.A. exponentielle Laufzeit)

Überblick

- Gerichtete Graphische Modelle: Bayessche Netze
- Graphische Modelle im Maschinellen Lernen
- Inferenz in Graphischen Modellen
 - ◆ Exakte Inferenz: Message-Passing
 - ◆ Approximative Inferenz: Sampling

Approximative Inferenz

- Exakte Inferenz NP-hart: In der Praxis spielen *approximative* Inferenzverfahren wichtige Rolle
- Wir betrachten Sampling-basierte Verfahren
 - ◆ Relativ einfach zu verstehen/implementieren
 - ◆ Anytime-Algorithmen (je länger die Laufzeit, desto genauer)

Inferenz: Sampling-basiert

- Grundidee Sampling:

- ◆ Wir interessieren uns für eine Verteilung $p(\mathbf{z})$, \mathbf{z} ist eine Menge von Zufallsvariablen (z.B. bedingte Verteilung über Anfragevariablen in graphischem Modell)
- ◆ Es ist schwierig, $p(\mathbf{z})$ direkt auszurechnen
- ◆ Stattdessen ziehen wir „Samples“ (Stichproben)

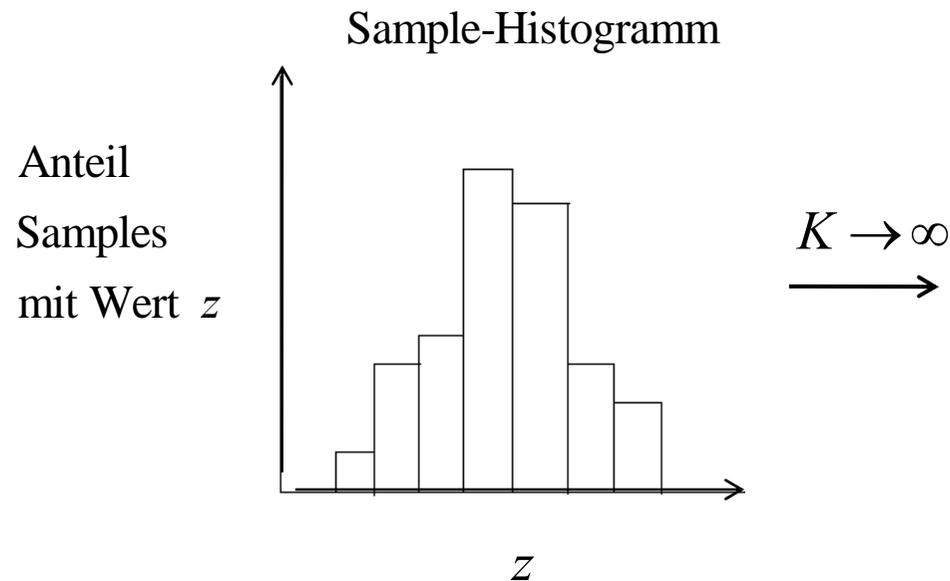
$$\mathbf{z}^{(k)} \sim p(\mathbf{z}) \quad \text{i.i.d., } k = 1, \dots, K,$$

jedes Sample $\mathbf{z}^{(k)}$ ist eine vollständige Belegung der Zufallsvariablen in \mathbf{z}

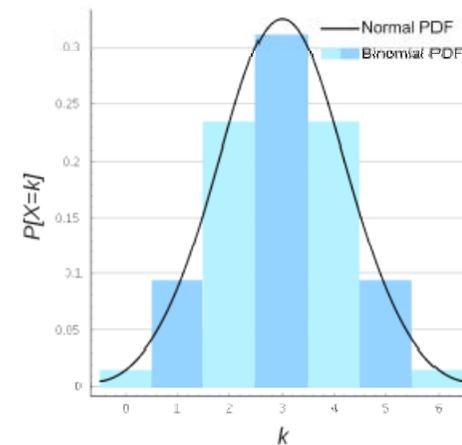
- Die Samples $\mathbf{z}^{(1)}, \mathbf{z}^{(2)}, \dots, \mathbf{z}^{(K)}$ approximieren die Verteilung $p(\mathbf{z})$

Inferenz: Sampling-basiert

- Beispiel:
 - ◆ Eindimensionale Verteilung, $\mathbf{z} = \{z\}$
 - ◆ Diskrete Variable mit Zuständen $\{0, \dots, 6\}$: Anzahl „Kopf“ bei 6 Münzwürfen



Echte Verteilung (Binomial)



Sampling-Inferenz für Graphische Modelle

- Gegeben graphisches Modell, repräsentiert Verteilung durch

$$p(x_1, \dots, x_N) = \prod_{i=1}^N p(x_i \mid pa(x_i))$$

- Etwas allgemeinere Inferenz-Problemstellung: Menge von Anfragevariablen

$$p(\mathbf{x}_I \mid \mathbf{x}_D) \approx ?$$

$\mathbf{x}_I \subseteq \mathbf{x} = \{x_1, \dots, x_N\}$	Menge von Anfragevariablen
$\mathbf{x}_D \subseteq \mathbf{x} = \{x_1, \dots, x_N\}$	Menge von Evidenzvariablen

- Wir betrachten zunächst den Fall ohne Evidenz:

$$p(\mathbf{x}_I) \approx ? \quad \mathbf{x}_I = \{x_{i_1}, \dots, x_{i_m}\} \subseteq \{x_1, \dots, x_N\}$$

Sampling-Inferenz für Graphische Modelle

- Ziel: Samples aus der Randverteilung $p(\mathbf{x}_I) = p(x_{i_1}, \dots, x_{i_m})$

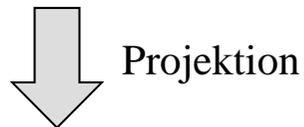
$$\mathbf{x}_I^{(k)} \sim p(\mathbf{x}_I) \quad k = 1, \dots, K$$

- Es genügt, Samples aus der Gesamtverteilung $p(\mathbf{x}) = p(x_1, \dots, x_N)$ zu ziehen:

$$\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_N^{(k)}) \sim p(x_1, \dots, x_N) \quad k = 1, \dots, K$$

- Samples aus der Randverteilung $p(x_{i_1}, \dots, x_{i_m})$ erhalten wir einfach durch Projektion der Samples auf die Menge $\{x_{i_1}, \dots, x_{i_m}\}$

$$\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_N^{(k)}) \sim p(x_1, \dots, x_N) \quad k = 1, \dots, K$$



$$\mathbf{x}_I^{(k)} = (x_{i_1}^{(k)}, \dots, x_{i_m}^{(k)}) \sim p(x_{i_1}, \dots, x_{i_m}) \quad k = 1, \dots, K$$

Inferenz: Ancestral Sampling

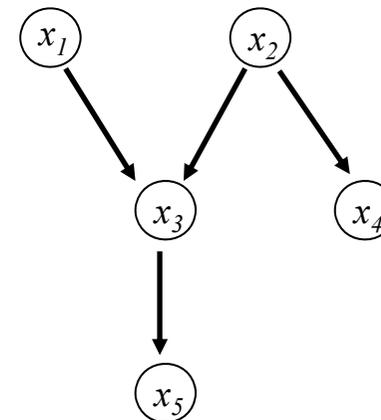
- Wie ziehen wir Samples $\mathbf{x}^{(k)} \sim p(\mathbf{x})$?
- Einfach bei gerichteten graphischen Modellen:
„Ancestral Sampling“
 - ◆ Nutze Faktorisierung der gemeinsamen Verteilung

$$\mathbf{x}^{(k)} \sim p(\mathbf{x}) = p(x_1, \dots, x_N)$$

$$= \prod_{n=1}^N p(x_n \mid pa(x_n))$$

- ◆ Annahme: $pa(x_n) \subseteq \{x_1, \dots, x_{n-1}\}$
(sonst umbenennen)
- ◆ „Ziehen entlang der Kanten“

„Ziehen entlang der Kanten“



Inferenz: Ancestral Sampling

- Wir ziehen ein Sample $(x_1^{(k)}, \dots, x_N^{(k)})$, indem wir nacheinander die einzelnen $x_i^{(k)}$ ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 | pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N | pa(x_N))$$

Schon gezogene Werte

$$\mathbf{x}^{(k)} \sim p(\mathbf{x}) = p(x_1, \dots, x_N)$$

$$= \prod_{n=1}^N p(x_n | pa(x_n))$$

- Beispiel

$$x_1^{(k)} \sim p(x_1)$$

$$\rightarrow x_1 = 1$$

$$x_2^{(k)} \sim p(x_2)$$

$$\rightarrow x_2 = 0$$

$$x_3^{(k)} \sim p(x_3 | x_1 = 1, x_2 = 0)$$

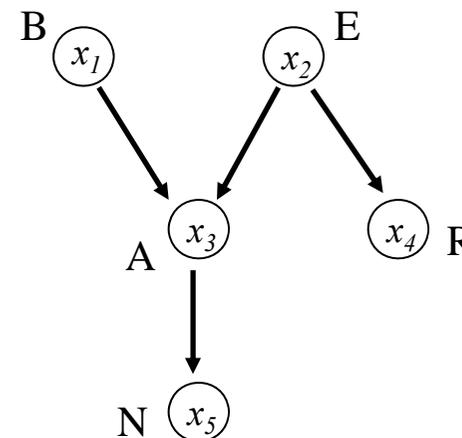
$$\rightarrow x_3 = 1$$

$$x_4^{(k)} \sim p(x_4 | x_2 = 0)$$

$$\rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 | x_3 = 1)$$

$$\rightarrow x_5 = 1$$



Inferenz: Ancestral Sampling

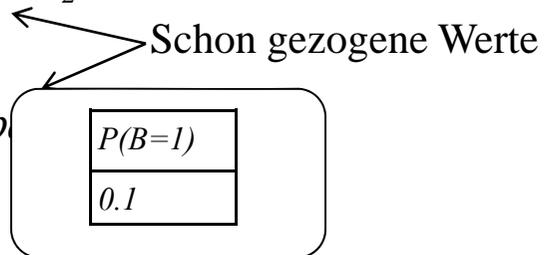
- Wir ziehen ein Sample $(x_1, \dots, x_N)^{(k)}$, indem wir nacheinander die einzelnen x_i ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 | pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N | pa(x_N))$$



$$\begin{aligned} \mathbf{x}^{(k)} &\sim p(\mathbf{x}) = p(x_1, \dots, x_N) \\ &= \prod_{n=1}^N p(x_n | pa(x_n)) \end{aligned}$$

- Beispiel**

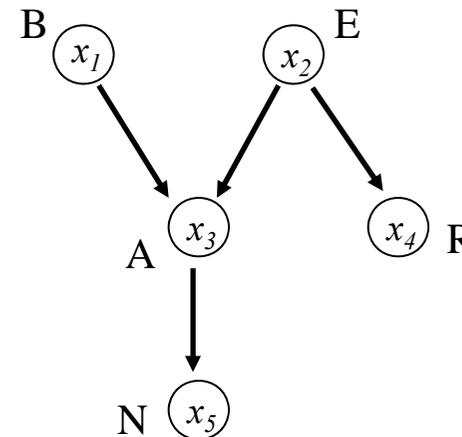
$$x_1^{(k)} \sim p(x_1) \quad \rightarrow x_1 = 1$$

$$x_2^{(k)} \sim p(x_2) \quad \rightarrow x_2 = 0$$

$$x_3^{(k)} \sim p(x_3 | x_1 = 1, x_2 = 0) \quad \rightarrow x_3 = 1$$

$$x_4^{(k)} \sim p(x_4 | x_2 = 0) \quad \rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 | x_3 = 1) \quad \rightarrow x_5 = 1$$



Inferenz: Ancestral Sampling

- Wir ziehen ein Sample $(x_1, \dots, x_N)^{(k)}$, indem wir nacheinander die einzelnen x_i ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 \mid pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N \mid pa(x_N))$$

Schon gezogene Werte

$$\mathbf{x}^{(k)} \sim p(\mathbf{x}) = p(x_1, \dots, x_N)$$

$$= \prod_{n=1}^N p(x_n \mid pa(x_n))$$

- Beispiel**

$P(E=1)$
0.2

$$x_1^{(k)} \sim p(x_1)$$

$$\rightarrow x_1 = 1$$

$$x_2^{(k)} \sim p(x_2)$$

$$\rightarrow x_2 = 0$$

$$x_3^{(k)} \sim p(x_3 \mid x_1 = 1, x_2 = 0)$$

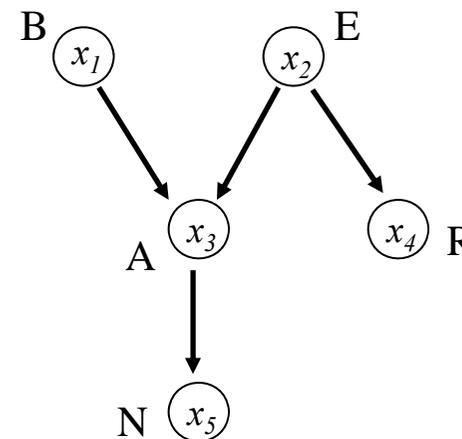
$$\rightarrow x_3 = 1$$

$$x_4^{(k)} \sim p(x_4 \mid x_2 = 0)$$

$$\rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 \mid x_3 = 1)$$

$$\rightarrow x_5 = 1$$



Inferenz: Ancestral Sampling

- Wir ziehen ein Sample $(x_1, \dots, x_N)^{(k)}$, indem wir nacheinander die einzelnen x_i ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 | pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N | pa(x_N))$$

B	E	$P(A=1 B,E)$
0	0	0.01
0	1	0.5
1	0	0.9
1	1	0.95

Beispiel

$$x_1^{(k)} \sim p(x_1)$$

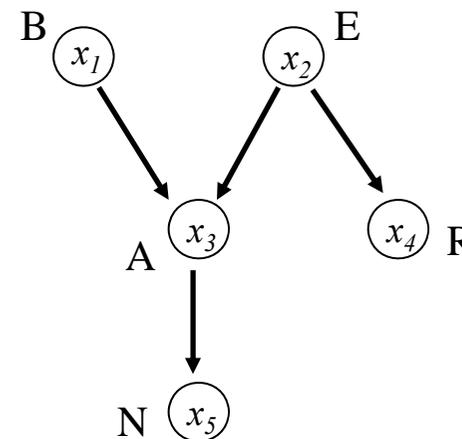
$$x_2^{(k)} \sim p(x_2) \rightarrow x_2 = 0$$

$$x_3^{(k)} \sim p(x_3 | x_1 = 1, x_2 = 0) \rightarrow x_3 = 1$$

$$x_4^{(k)} \sim p(x_4 | x_2 = 0) \rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 | x_3 = 1) \rightarrow x_5 = 1$$

$$\begin{aligned} \mathbf{x}^{(k)} \sim p(\mathbf{x}) &= p(x_1, \dots, x_N) \\ &= \prod_{n=1}^N p(x_n | pa(x_n)) \end{aligned}$$



Inferenz: Ancestral Sampling

- Wir ziehen ein Sample $(x_1, \dots, x_N)^{(k)}$, indem wir nacheinander die einzelnen x_i ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 | pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N | pa(x_N))$$

Schon gezogene Werte

E	$P(R=1 E)$
0	0.01
1	0.5

Beispiel

$$x_1^{(k)} \sim p(x_1)$$

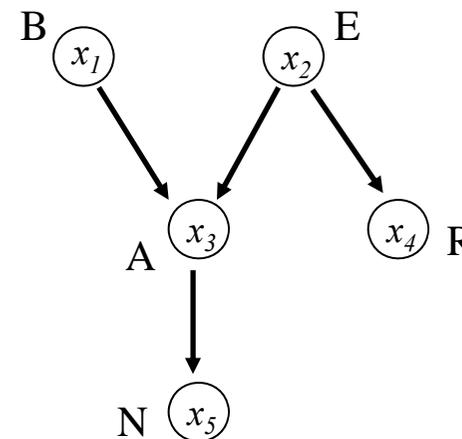
$$x_2^{(k)} \sim p(x_2)$$

$$x_3^{(k)} \sim p(x_3 | x_1=1, x_2=0) \rightarrow x_3 = 1$$

$$x_4^{(k)} \sim p(x_4 | x_2=0) \rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 | x_3=1) \rightarrow x_5 = 1$$

$$\begin{aligned} \mathbf{x}^{(k)} \sim p(\mathbf{x}) &= p(x_1, \dots, x_N) \\ &= \prod_{n=1}^N p(x_n | pa(x_n)) \end{aligned}$$



Inferenz: Ancestral Sampling

- Wir ziehen ein Sample $(x_1, \dots, x_N)^{(k)}$, indem wir nacheinander die einzelnen x_i ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 | pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N | pa(x_N))$$

Schon gezogene Werte

$$\mathbf{x}^{(k)} \sim p(\mathbf{x}) = p(x_1, \dots, x_N)$$

$$= \prod_{n=1}^N p(x_n | pa(x_n))$$

- Beispiel**

$$x_1^{(k)} \sim p(x_1)$$

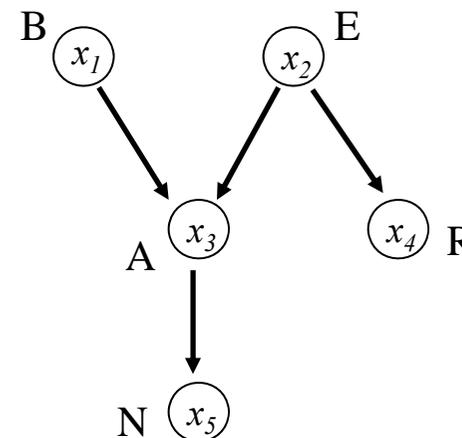
$$x_2^{(k)} \sim p(x_2)$$

$$x_3^{(k)} \sim p(x_3 | x_1 = 0)$$

$$x_4^{(k)} \sim p(x_4 | x_2 = 0) \rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 | x_3 = 1) \rightarrow x_5 = 1$$

A	$P(N=1 A)$
0	0.1
1	0.7



Inferenz: Ancestral Sampling

- Wir ziehen ein Sample $(x_1, \dots, x_N)^{(k)}$, indem wir nacheinander die einzelnen x_i ziehen

$$x_1^{(k)} \sim p(x_1)$$

$$x_2^{(k)} \sim p(x_2 \mid pa(x_2))$$

...

$$x_N^{(k)} \sim p(x_N \mid pa(x_N))$$

← Schon gezogene Werte

$$\mathbf{x}^{(k)} \sim p(\mathbf{x}) = p(x_1, \dots, x_N)$$

$$= \prod_{n=1}^N p(x_n \mid pa(x_n))$$

- Beispiel

$$x_1^{(k)} \sim p(x_1)$$

$$\rightarrow x_1 = 1$$

$$x_2^{(k)} \sim p(x_2)$$

$$\rightarrow x_2 = 0$$

$$x_3^{(k)} \sim p(x_3 \mid x_1 = 1, x_2 = 0)$$

$$\rightarrow x_3 = 1$$

$$x_4^{(k)} \sim p(x_4 \mid x_2 = 0)$$

$$\rightarrow x_4 = 0$$

$$x_5^{(k)} \sim p(x_5 \mid x_3 = 1)$$

$$\rightarrow x_5 = 1$$

$$\Rightarrow \mathbf{x}^{(k)} = (1, 0, 1, 0, 1)$$

Inferenz: Ancestral Sampling

- Beispiel für Schätzung der Randverteilungen aus Samples:

$$\mathbf{x}^{(1)} = (1, 0, 1, 0, 1)$$

$$\mathbf{x}^{(2)} = (0, 0, 0, 0, 0)$$

$$\mathbf{x}^{(3)} = (0, 1, 0, 1, 0)$$

$$\mathbf{x}^{(4)} = (0, 1, 1, 0, 1)$$

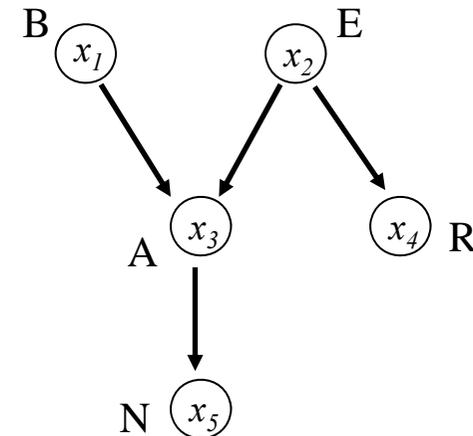
$$\mathbf{x}^{(5)} = (0, 0, 0, 0, 0)$$



$$p(x_3 = 1) \approx 0.4$$

$$p(x_4 = 1) \approx 0.2$$

$$p(x_5 = 1) \approx 0.4$$



- Analyse Ancestral Sampling
 - ◆ + Zieht direkt aus der korrekten Verteilung
 - ◆ + Effizient
 - ◆ - Funktioniert nur ohne Evidenz

Inferenz: Logic Sampling

- Wie erhalten wir Samples unter Evidenz?

$$\mathbf{x}^{(k)} \sim p(\mathbf{x}_I | \mathbf{x}_D) = p(x_{i_1}, \dots, x_{i_m} | x_{j_1}, \dots, x_{j_l})$$

Beobachtete Variablen

- Logic Sampling: Ancestral Sampling + Zurückweisung von Samples, die nicht mit der Beobachtung konsistent sind
 - ◆ Ancestral Sampling: vollständige Samples

$$\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_N^{(k)}) \sim p(\mathbf{x})$$

- ◆ Fallunterscheidung:

$(x_{j_1}^{(k)}, \dots, x_{j_l}^{(k)}) = (x_{j_1}, \dots, x_{j_l})$ [Sample konsistent mit Beobachtung]: akzeptiere $\mathbf{x}^{(k)}$

$(x_{j_1}^{(k)}, \dots, x_{j_l}^{(k)}) \neq (x_{j_1}, \dots, x_{j_l})$ [Sample inkonsistent mit Beobachtung]: weise $\mathbf{x}^{(k)}$ zurück

Inferenz: Logic Sampling

- Die im Logic Sampling akzeptierten Samples $\mathbf{x}^{(k)}$ repräsentieren die bedingte Verteilung gegeben Evidenz:

$$\mathbf{x}^{(k)} \sim p(\mathbf{x} | \mathbf{x}_D)$$

- Marginale Samples

$$\mathbf{x}_I^{(k)} \sim p(\mathbf{x}_I | \mathbf{x}_D)$$

wieder durch Projektion auf Anfragevariablen

- Problem: Oft werden fast alle Samples verworfen
 - ◆ Wahrscheinlichkeit, Sample zu generieren, das mit \mathbf{x}_D konsistent ist, sinkt meist exponentiell schnell mit Größe von D
 - ◆ Entsprechend exponentielle Laufzeit, um ausreichende Menge von Samples zu erhalten
 - ◆ In der Praxis selten anwendbar

Inferenz: MCMC

- Alternative Strategie zum Erzeugen von Samples: Markov Chain Monte Carlo („MCMC“)
- Idee:
 - ◆ Schwierig, direkt Samples aus $p(\mathbf{z})$ zu ziehen
 - ◆ Alternativstrategie: Konstruiere Folge von Samples

$$\mathbf{z}^{(0)} \rightarrow \mathbf{z}^{(1)} \rightarrow \mathbf{z}^{(2)} \rightarrow \mathbf{z}^{(3)} \rightarrow \mathbf{z}^{(4)} \rightarrow \mathbf{z}^{(5)} \rightarrow \dots$$

$$\mathbf{z}^{(0)} \text{ zufällig initialisiert} \quad \mathbf{z}^{(t+1)} = \text{update}(\mathbf{z}^t)$$

durch mehrfache probabilistische Update-Schritte

- ◆ Wenn Updates geeignet gewählt, gilt asymptotisch


ZV: T -te Variablenbelegung $\rightarrow \mathbf{z}^{(T)} \sim p(\mathbf{z})$ ungefähr, für sehr grosse T

Markov-Ketten

- Folge der Zustände

$$\mathbf{z}^{(0)} \rightarrow \mathbf{z}^{(1)} \rightarrow \mathbf{z}^{(2)} \rightarrow \mathbf{z}^{(3)} \rightarrow \mathbf{z}^{(4)} \rightarrow \mathbf{z}^{(5)} \rightarrow \dots$$

bildet Markov-Kette:



$\mathbf{z}^{(t)}$ heisst "Zustand" der Kette zum Zeitpunkt t

$$p(\mathbf{z}^{(0)}, \dots, \mathbf{z}^{(T)}) = p(\mathbf{z}^{(0)}) \prod_{t=1}^T p(\mathbf{z}^{(t)} | \mathbf{z}^{(t-1)})$$

- Dynamik beschrieben durch Transitionswahrscheinlichkeiten

$$T(\mathbf{z}^{(t)}, \mathbf{z}^{(t+1)}) = p(\mathbf{z}^{(t+1)} | \mathbf{z}^{(t)}) \quad \text{Wahrscheinlichkeit Übergang } \mathbf{z}^{(t)} \rightarrow \mathbf{z}^{(t+1)}$$

Neuer Zustand Aktueller Zustand

Markov-Ketten

- Verteilung über Folgezustand berechnen aus Verteilung über aktuellem Zustand

Folgezustand \swarrow \nwarrow Aktueller Zustand

$$\begin{aligned} p(\mathbf{z}^{(t+1)}) &= \sum_{\mathbf{z}^{(t)}} p(\mathbf{z}^{(t+1)} | \mathbf{z}^{(t)}) p(\mathbf{z}^{(t)}) \\ &= \sum_{\mathbf{z}^{(t)}} T(\mathbf{z}^{(t)}, \mathbf{z}^{(t+1)}) p(\mathbf{z}^{(t)}) \end{aligned}$$

- Stationäre Verteilung
 - ◆ Eine Verteilung $p_*(\mathbf{z})$ über die Zustände der Kette heisst „stationär“, falls sie bei einem Schritt der Markov-Kette nicht verändert wird:

$$p_*(\mathbf{z}^{(t+1)}) = \sum_{\mathbf{z}^{(t)}} T(\mathbf{z}^{(t)}, \mathbf{z}^{(t+1)}) p_*(\mathbf{z}^{(t)})$$

Markov-Ketten: Stationäre Verteilung

- Falls die Kette eine stationäre Verteilung erreicht, dh. $p(\mathbf{z}^{(T)}) = p_*(\mathbf{z}^{(T)})$ für ein geeignetes T , so bleibt diese Verteilung erhalten, dh. $p(\mathbf{z}^{(T+N)}) = p_*(\mathbf{z}^{(T+N)})$ für alle N .
 - ◆ Kette ist „konvergiert“ zur Verteilung p_*
- Unter bestimmten Bedingungen („Ergodische Ketten“) konvergiert eine Markov-Kette für $t \rightarrow \infty$ gegen eine eindeutige stationäre Verteilung, diese heisst dann „Gleichgewichtsverteilung“

Inferenz: MCMC

- Gegeben Bayessches Netz über ZV $\mathbf{x} = \{x_1, \dots, x_N\}$, definiert Verteilung $p(\mathbf{x})$
- „Markov Chain Monte Carlo“ Methoden
 - ◆ Konstruiere aus dem Bayesschen Netz eine Folge von Samples durch iterative probabilistische Updates

$$\mathbf{x}^{(0)} \rightarrow \mathbf{x}^{(1)} \rightarrow \mathbf{x}^{(2)} \rightarrow \mathbf{x}^{(3)} \rightarrow \mathbf{x}^{(4)} \rightarrow \mathbf{x}^{(5)} \rightarrow \dots$$

$\mathbf{x}^{(0)}$ zufällig initialisiert $\mathbf{x}^{(t+1)} = \text{update}(\mathbf{x}^t)$ $\mathbf{x}^{(t)}$ jeweils Belegung aller Knoten im Netz

- ◆ Ziel: Updates so wählen, dass sich ergodische Markov-Kette mit Gleichgewichtsverteilung $p(\mathbf{x})$ ergibt
- ◆ Einfachste Methode: lokales Ziehen einer Variable, gegeben Zustand der anderen Variablen („Gibbs-Sampling“)

Inferenz: Gibbs Sampling

- Gibbs Sampling: Eine Version von MCMC
- Übergangswahrscheinlichkeiten bestimmt durch wiederholtes lokales Ziehen einer ZV, gegeben den Zustand aller anderen ZV
 - ◆ Gegeben alter Zustand $\mathbf{x} = (x_1, \dots, x_N)$
 - ◆ Ziehen des neuen Zustands $\mathbf{x}' = (x_1', \dots, x_N')$:

$$\begin{aligned}x_1' &\sim p(x_1 \mid \overbrace{x_2, \dots, x_N}^{\text{Beobachtete (alte) Werte}}) \\x_2' &\sim p(x_2 \mid x_1', x_3, \dots, x_N) \\x_3' &\sim p(x_3 \mid x_1', x_2', x_4, \dots, x_N) \\&\dots \\x_N' &\sim p(x_N \mid x_1', x_2', \dots, x_{N-1}')$$

Inferenz: Gibbs Sampling

- Einzelner Gibbs-Schritt einfach, bedingte Verteilung über eine Variable gegeben Evidenz auf **allen** anderen Variablen direkt auszurechnen:

Berechnung von $p(x_1 | \overbrace{x_2, \dots, x_N}^{\text{Beobachtete (alte) Werte}})$:

Für $x_1 = 1$ berechne $p_1 = p(x_1, x_2, \dots, x_N)$

Für $x_1 = 0$ berechne $p = p(x_1, x_2, \dots, x_N) + p_1$

$$p(x_1 = 1 | x_2, \dots, x_N) = p_1 / p$$

- **Satz:** Falls $p(x_n | x_1, x_2, \dots, x_{n-1}, x_{n+1}, \dots, x_{N-1}) \neq 0$ für alle n und alle möglichen Zustände x_i , so ist die resultierende Markov-Kette ergodisch mit Gleichgewichtsverteilung $p(\mathbf{x})$.

Gibbs-Sampling mit Evidenz

- Bisher haben wir Inferenz ohne Evidenz betrachtet
- Wie erhalten wir Samples aus der bedingten Verteilung?

Ziel: $\mathbf{x}^{(T)} \sim p(\mathbf{x} | \mathbf{x}_D)$ ungefähr, für sehr grosse T

- Leichte Modifikation der Gibbs-Sampling Methode:
 - ◆ Gibbs-Sampling zieht immer eine Variable x_i neu, gegeben Zustand der anderen Variablen
 - ◆ Mit Evidenz: Nur die unbeobachteten Variablen werden jeweils neu gezogen, die beobachteten Variablen werden fest auf den beobachteten Wert gesetzt

Inferenz: Gibbs Sampling

- Zusammenfassung Gibbs Sampling Algorithmus:
 - ◆ $\mathbf{x}^{(0)}$ = zufällige Initialisierung aller ZV, konsistent mit Evidenz \mathbf{x}_D
 - ◆ Für $t = 1, \dots, T$: $\mathbf{x}^{(t)} = \text{Gibbs-update}(\mathbf{x}^{(t-1)})$
 - ◆ Die Samples $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \mathbf{x}^{(3)}, \dots$ sind asymptotisch verteilt nach $p(\mathbf{x} | \mathbf{x}_D)$
- Gibbs Sampling in vielen praktischen Anwendungen brauchbar
 - ◆ Einzelne Update-Schritte effizient
 - ◆ Garantierte Konvergenz (für $t \rightarrow \infty$)
 - ◆ Erlaubt, Samples aus $p(\mathbf{x} | \mathbf{x}_D)$ zu ziehen, ohne dass Laufzeit explodiert wenn Evidenzmenge groß (im Gegensatz zu Logic Sampling)

Inferenz: Gibbs Sampling

- Gibbs-Sampling: Konvergenz
 - ◆ Konvergenz der Markov-Kette $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \mathbf{x}^{(3)}, \dots$ ist nur garantiert für $t \rightarrow \infty$.
 - ◆ In der Praxis: „Burn-In“ Iterationen, bevor Samples verwendet werden (verwerfe Samples $\mathbf{x}^{(t)}$ für $t \leq T_{\text{Burn-in}}$)
 - ◆ Es gibt auch Konvergenztests, um Anzahl der Burn-In Iterationen zu bestimmen
- Gibbs-Sampling: Abhängigkeit
 - ◆ Einzelne aufeinander folgende Samples $\mathbf{x}^{(t)}, \mathbf{x}^{(t+1)}$ abhängig
 - ◆ Lösung: verwende Samples $\mathbf{x}^{(t)}, \mathbf{x}^{(t+L)}, \mathbf{x}^{(t+2L)}, \mathbf{x}^{(t+3L)}, \dots$
 - ◆ Samples dann weitestgehend unabhängig

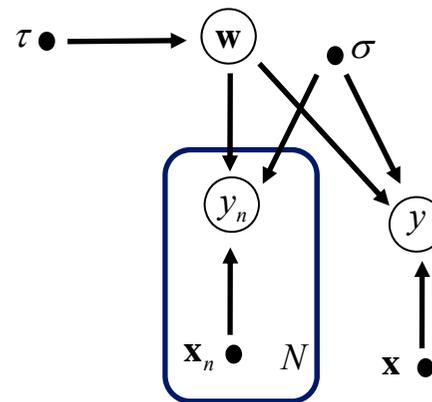
Inferenz: Zusammenfassung

- Exakte Inferenz
 - ◆ Message-Passing Algorithmen
 - ◆ Exakte Inferenz auf Polytrees (mit Junction-Tree Erweiterung auf allgemeinen Graphen)
 - ◆ Laufzeit abhängig von Graphstruktur, exponentiell im worst-case

- Approximative Inferenz
 - ◆ Sampling-Methoden: Approximation durch Menge von „Samples“, exakte Ergebnisse für $t \rightarrow \infty$.
 - ★ Ancestral Sampling: einfach, schnell, keine Evidenz
 - ★ Logic Sampling: mit Evidenz, aber selten praktikabel
 - ★ MCMC/Gibbs-Sampling: Effizientes approximatives Ziehen von Samples unter Evidenz

Lernen Graphischer Modelle aus Daten?

- Graphische Modelle im maschinellen Lernen: Problemstellung ist meist Inferenzproblem
 - ◆ MAP Parameterschätzung
 - ◆ Bayessche Vorhersage



- Auch möglich, die Verteilungen eines graphischen Modells aus Daten zu schätzen

$$p(x_1, \dots, x_N) = \prod_{i=1}^N p(x_i | pa(x_i))$$

$p(x_i | pa(x_i))$ parametrisierte Verteilung (z.B. diskrete Tabelle)

Parameter können aus Daten geschätzt werden

Maximum-Likelihood Parameterlernen

- Parametrisierung mit Parametervektor θ

$$p(x_1, \dots, x_N | \theta) = \prod_{i=1}^N p(x_i | pa(x_i), \theta)$$

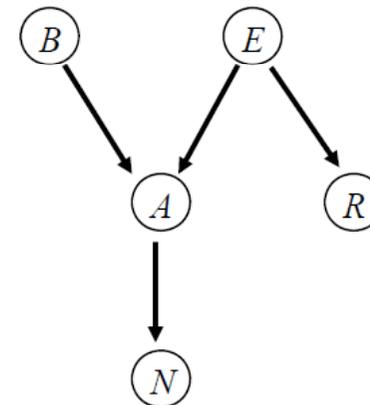
- Beobachtete Daten: Belegungen der Zufallsvariablen x_1, \dots, x_N

Daten:

i.i.d. Beispiele

$L = \{\mathbf{x}_1, \dots, \mathbf{x}_m\}$

	<i>B</i>	<i>E</i>	<i>A</i>	<i>N</i>	<i>R</i>
\mathbf{x}_1	0	0	0	0	0
\mathbf{x}_2	0	1	1	1	1
\mathbf{x}_3	0	1	0	0	0
\mathbf{x}_4	1	0	1	1	0
\mathbf{x}_5	0	0	0	1	0
\mathbf{x}_6	1	1	1	0	1



Maximum-Likelihood Parameterlernen

- Maximum-Likelihood-Ansatz

$$\theta_* = \arg \max_{\theta} p(L | \theta)$$

$$= \arg \max_{\theta} p(\mathbf{x}_1, \dots, \mathbf{x}_m | \theta)$$

$$= \arg \max_{\theta} \prod_{j=1}^m p(\mathbf{x}_j | \theta) \quad \text{i.i.d.}$$

$$= \arg \max_{\theta} \prod_{j=1}^m \prod_{i=1}^N p(x_{ji} | pa(x_{ji}), \theta) \quad \text{Faktorisierung GM}$$

Maximum-Likelihood Parameterlernen

- Lösung (diskrete Variablen):

$$p(\underbrace{x_{ji}}_{\text{Zustand } x_{ji}} \mid \underbrace{pa(x_{ji})}_{\text{Zustand } pa(x_{ji})}, \theta_*) = \frac{C(x_{ji}, pa(x_{ji}))}{C(pa(x_{ji}))}$$

$C(x_{ji}, pa(x_{ji}))$ = Wie oft wurde der gemeinsame Zustand $x_{ji}, pa(x_{ji})$ beobachtet?

$C(pa(x_{ji}))$ = Wie oft wurde der gemeinsame Zustand $pa(x_{ji})$ beobachtet?

Daten:

i.i.d. Beispiele

$L = \{\mathbf{x}_1, \dots, \mathbf{x}_m\}$

	<i>B</i>	<i>E</i>	<i>A</i>	<i>N</i>	<i>R</i>
\mathbf{x}_1	0	0	0	0	0
\mathbf{x}_2	0	1	1	1	1
\mathbf{x}_3	0	1	0	0	0
\mathbf{x}_4	1	0	1	1	0
\mathbf{x}_5	0	0	0	1	0
\mathbf{x}_6	1	1	1	0	1

$$p(N = 1 \mid A = 0, \theta_*) = \frac{1}{3}$$

$$p(N = 1 \mid A = 1, \theta_*) = \frac{2}{3}$$

Maximum-Likelihood Parameterlernen

- Einfache Lösung nur möglich bei *vollständig beobachteten* Daten
- Modelle enthalten oft Variablen, die nicht beobachtbar sind
- Maximum-Likelihood-Schätzung dann mit dem EM Algorithmus („Expectation-Maximization“)
- Später mehr!