


Überblick

- Graphische Modelle: Syntax und Semantik
- Graphische Modelle im Maschinellen Lernen
- Inferenz in Graphischen Modellen (exakt, approximativ)
- Sequenzmodelle


Problemstellung Inferenz

- Gegeben graphisches Modell über Menge von ZV $\{X_1, \dots, X_N\}$.
- Problemstellung Inferenz:
 - ◆ Variablen mit Evidenz X_{i_1}, \dots, X_{i_m} $\{i_1, \dots, i_m\} \subseteq \{1, \dots, N\}$
 - ◆ Anfrage-Variable X_a $a \in \{1, \dots, N\} \setminus \{i_1, \dots, i_m\}$
 - ◆ Berechne Verteilung über Anfrage-Variable gegeben Evidenz



Graphische Modelle: Inferenz

- Beispiel „Alarm“ Domäne
 - ◆ Variablen mit Evidenz: N, R
 - ◆ Anfrage-Variablen: B



Wahrscheinlichkeit für Einbruch gegeben dass der Nachbar uns angerufen hat?

Zum Beispiel:

$$p(B = 1 \mid N = 1, R = 0) = 0.7$$

$$p(B = 0 \mid N = 1, R = 0) = 0.3$$

$$p(B = 1 \mid N = 1, R = 1) = 0.2$$

$$p(B = 0 \mid N = 1, R = 1) = 0.8$$

- Posterior über Parameter, Bayessche Vorhersage, ...

Graphische Modelle: Inferenz

- Inferenz schwieriges Problem
 - ◆ Allgemeine graphische Modelle: exakte Inferenz NP-hart
 - ◆ Es gibt Algorithmen für exakte Inferenz in allgemeinen graphischen Modellen, deren Laufzeit von den Eigenschaften der Graphstruktur abhängt („Message-Passing“)
 - ◆ Es gibt verschiedene Techniken für approximative Inferenz (Sampling, Variational Inference, Expectation Propagation)
- Wir betrachten
 - ◆ Message-Passing Algorithmus: in Spezialfällen
 - ◆ Sampling-basierte approximative Inferenz

Inferenz: Diskrete vs. Kontinuierliche Variablen

- Wir diskutieren Inferenz nur für diskrete Variablen
- Betrachtete Inferenzalgorithmen sind auch auf kontinuierliche Variablen anwendbar
 - ◆ Summen ersetzen durch Integrale
 - ◆ Verteilungen müssen so gewählt sein, dass sich die entsprechenden Integrale in geschlossener Form ausrechnen lassen

Überblick

- Graphische Modelle: Syntax und Semantik
- Graphische Modelle im Maschinellen Lernen
- Inferenz in Graphischen Modellen
 - ◆ Exakte Inferenz
 - ◆ Approximative Inferenz
- Sequenzmodelle

Exakte Inferenz: Naiv

- Graphisches Modell: Repräsentation von $p(X_1, \dots, X_N)$

- Naive Inferenz:

$$\text{Notation : } \{X_1, \dots, X_N\} = \{ \underbrace{X_a}_{\text{Anfrage-Variable}}, \underbrace{X_{i_1}, \dots, X_{i_m}}_{\text{Evidenz-Variablen}}, \underbrace{X_{j_1}, \dots, X_{j_k}}_{\text{restliche Variablen}} \}$$



$$\begin{aligned} \text{Berechne für jeden Wert } x_a: \quad p(x_a | x_{i_1}, \dots, x_{i_m}) &= \frac{p(x_a, x_{i_1}, \dots, x_{i_m})}{p(x_{i_1}, \dots, x_{i_m})} \\ &= \frac{1}{Z} p(x_a, x_{i_1}, \dots, x_{i_m}) \\ &= \frac{1}{Z} \sum_{x_{j_1}} \sum_{x_{j_2}} \cdots \sum_{x_{j_k}} p(x_1, \dots, x_N) \end{aligned}$$

Z Normalisierungsfaktor,
leicht explizit zu berechnen
bei univariaten Verteilungen

Zentrales Problem: Aussummieren aller restlichen Variablen (exponentiell, wenn naiv gelöst)


Effizientere Inferenzmethoden?

- Effizientere Methode als naive Inferenz?
 - ◆ Für allgemeine Graphen (vollständig verbunden) nicht möglich!
 - ◆ Aber wenn es Struktur im Modell gibt (Unabhängigkeiten), können wir diese unter Umständen ausnutzen
- Idee: Lokale Berechnungen, die entlang der Graphstruktur propagiert werden
 - ◆ Knoten schicken sich gegenseitig „Nachrichten“, die Ergebnisse von Teilberechnungen enthalten
 - ◆ „Message Passing“, „Belief Propagation“
 - ◆ Laufzeit der Verfahren hängt von Graphstruktur ab (exponentiell im worst-case)



Graphische Modelle: Inferenz auf linearer Kette


- Wir betrachten jetzt den Message-Passing Algorithmus in einem Spezialfall mit besonders einfacher Struktur: lineare Kette von Zufallsvariablen



$$p(x_1, \dots, x_N) = p(x_1) p(x_2 | x_1) p(x_3 | x_2) \cdot \dots \cdot p(x_N | x_{N-1})$$

- Notation: Darstellung der gemeinsamen Verteilung als Produkt von *Potenzialfunktionen* über Paare von ZV

$$p(x_1, \dots, x_N) = \underbrace{p(x_1)p(x_2|x_1)}_{\psi_{1,2}(x_1, x_2)} \underbrace{p(x_3|x_2)}_{\psi_{2,3}(x_2, x_3)} \cdot \dots \cdot \underbrace{p(x_N|x_{N-1})}_{\psi_{N-1,N}(x_{N-1}, x_N)}$$



Inferenz: lineare Kette von ZV

- Einführung des Message-Passing Algorithmus am Beispiel
- Lineare Kette von 5 Zufallsvariablen:



- Randverteilung der 3. Zufallsvariable berechnen (keine Evidenz)

Anfrage-Variable \swarrow

Restliche Variablen (aussummieren) \swarrow

$$p(x_3) = \sum_{x_1} \sum_{x_2} \sum_{x_4} \sum_{x_5} p(x_1, x_2, x_3, x_4, x_5)$$
$$= \sum_{x_1} \sum_{x_2} \sum_{x_4} \sum_{x_5} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \psi_{4,5}(x_4, x_5)$$

- Naive Berechnung exponentiell (Mehrfachsumme)
- Idee: Struktur (lineare Kette) ausnutzen, um Berechnung effizienter durchzuführen

Inferenz: Message-Passing

- Nutze Faktorisierung der gemeinsamen Verteilung in Potenziale (Unabhängigkeiten)

$$\begin{aligned}
 p(x_3) &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \sum_{x_5} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \psi_{4,5}(x_4, x_5) \\
 &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \underbrace{\sum_{x_5} \psi_{4,5}(x_4, x_5)}
 \end{aligned}$$

Lokale Teilberechnung: "Nachricht" $\mu_\beta(x_4)$

- Lokale Teilberechnung: „Nachricht“ $\mu_\beta(x_4)$
 - ◆ Berechne für alle Werte von x_4 : $\mu_\beta(x_4) = \sum_{x_5} \psi_{4,5}(x_4, x_5)$
 - ◆ Nachricht ist Funktion in Abhängigkeit vom Zustand x_4 (z.B. kodiert als Vektor)
 - ◆ In der Nachricht ist der Knoten X_5 aussummiert

Inferenz: Message-Passing

- Nutze Faktorisierung der gemeinsamen Verteilung in Potenziale (Unabhängigkeiten)

$$\begin{aligned}
 p(x_3) &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \sum_{x_5} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \psi_{4,5}(x_4, x_5) \\
 &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \underbrace{\sum_{x_5} \psi_{4,5}(x_4, x_5)}_{\text{Lokale Teilberechnung: "Nachricht" } \mu_\beta(x_4)}
 \end{aligned}$$

Lokale Teilberechnung: "Nachricht" $\mu_\beta(x_4)$

- Lokale Teilberechnung

Kodierung z.B. als Vektor: $\mu_\beta(x_4) = \begin{pmatrix} \sum_{x_5} \psi_{4,5}(0, x_5) \\ \sum_{x_5} \psi_{4,5}(1, x_5) \end{pmatrix}$

- ◆ Berechne für
- ◆ Nachricht ist Funktion in Abhängigkeit vom Zustand x_4 (z.B. kodiert als Vektor)
- ◆ In der Nachricht ist der Knoten X_5 aussummiert

Inferenz: Message-Passing

- Nutze Faktorisierung der gemeinsamen Verteilung in Potenziale (Unabhängigkeiten)


$$\begin{aligned}
 p(x_3) &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \sum_{x_5} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \psi_{4,5}(x_4, x_5) \\
 &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \underbrace{\sum_{x_5} \psi_{4,5}(x_4, x_5)}
 \end{aligned}$$

Lokale Teilberechnung: "Nachricht" $\mu_\beta(x_4)$

- Lokale Teilberechnung: „Nachricht“ $\mu_\beta(x_4)$
 - ◆ Berechne für alle Werte von x_4 : $\mu_\beta(x_4) = \sum_{x_5} \psi_{4,5}(x_4, x_5)$
 - ◆ Nachricht ist Funktion in Abhängigkeit vom Zustand x_4 (z.B. kodiert als Vektor)
 - ◆ In der Nachricht ist der Knoten X_5 aussummiert

Inferenz: Message-Passing

- **Anschauung:** Wir summieren den Knoten X_5 aus, und schicken das Ergebnis weiter an den Knoten X_4



Inferenz: Message-Passing

- Wir wenden dieselbe Idee auf die nächste auszusummierenden Variable an


$$\begin{aligned}
 p(x_3) &= \sum_{x_1} \sum_{x_2} \sum_{x_4} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \psi_{3,4}(x_3, x_4) \mu_\beta(x_4) \\
 &= \sum_{x_1} \sum_{x_2} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \underbrace{\sum_{x_4} \psi_{3,4}(x_3, x_4) \mu_\beta(x_4)}
 \end{aligned}$$

Lokale Teilberechnung: "Nachricht" $\mu_\beta(x_3)$

- Lokale Teilberechnung: „Nachricht“ $\mu_\beta(x_3)$
 - ◆ Berechne für alle Werte von x_3 : $\mu_\beta(x_3) = \sum_{x_4} \psi_{3,4}(x_3, x_4) \mu_\beta(x_4)$
 - ◆ Nachricht ist Funktion in Abhängigkeit vom Zustand x_3
 - ◆ In der Nachricht sind die Knoten X_5, X_4 aussummiert

Inferenz: Message-Passing

- **Anschauung:** Wir summieren den Knoten X_4 aus, und schicken das Ergebnis weiter an den Knoten X_3



- X_3 ist Anfrageknoten, also nicht aussummieren

Inferenz: Message-Passing


- Gleiches Prinzip anwenden auf die Variablen links vom Anfrageknoten

$$\begin{aligned}
 p(x_3) &= \sum_{x_1} \sum_{x_2} \psi_{1,2}(x_1, x_2) \psi_{2,3}(x_2, x_3) \mu_\beta(x_3) \\
 &= \mu_\beta(x_3) \sum_{x_2} \sum_{x_1} \psi_{2,3}(x_2, x_3) \psi_{1,2}(x_1, x_2) \\
 &= \mu_\beta(x_3) \sum_{x_2} \psi_{2,3}(x_2, x_3) \underbrace{\sum_{x_1} \psi_{1,2}(x_1, x_2)}_{\text{"Nachricht" } \mu_\alpha(x_2)}
 \end{aligned}$$

- Teilberechnung: „Nachricht“ $\mu_\alpha(x_2)$
 - ◆ Berechne für alle Werte von x_2 : $\mu_\alpha(x_2) = \sum_{x_1} \psi_{1,2}(x_1, x_2)$
 - ◆ Nachricht ist Funktion in Abhängigkeit vom Zustand x_2
 - ◆ In der Nachricht ist der Knoten X_1 aussummiert

Inferenz: Message-Passing

- **Anschauung:** Wir summieren den Knoten X_1 aus, und schicken das Ergebnis weiter an den Knoten X_2



Inferenz: Message-Passing

- Letzte Variable X_2 aussummieren


$$p(x_3) = \mu_\beta(x_3) \underbrace{\sum_{x_2} \psi_{2,3}(x_2, x_3) \mu_\alpha(x_2)}_{\text{"Nachricht" } \mu_\alpha(x_3)}$$
$$= \mu_\beta(x_3) \mu_\alpha(x_3)$$

- ◆ Gesuchte Randverteilung ist Produkt der Nachrichten im Anfrageknoten:

$$p(x_3) = \mu_\beta(x_3) \mu_\alpha(x_3)$$

Inferenz: Message-Passing

- Nachrichten-Austausch Schema:



$$p(x_3) = \mu_\beta(x_3)\mu_\alpha(x_3)$$

Endergebnis: gesuchte Randverteilung ist Produkt der Nachrichten

Inferenz: Message-Passing

- Laufzeit:

- ◆ Berechnung einer Nachricht:

Berechne für alle Werte von x_3 :
$$\mu_\beta(x_3) = \sum_{x_4} \psi_{3,4}(x_3, x_4) \mu_\beta(x_4)$$

$\Rightarrow O(M^2)$ für Berechnung einer Nachricht (Variablen mit M diskreten Zuständen)

- ◆ $N-1$ Nachrichten insgesamt

$\Rightarrow O(NM^2)$ Gesamtlaufzeit

- ◆ Viel besser als naive Inferenz mit $O(M^N)$

Inferenz: Message-Passing Algorithmus

- Algorithmus: Message-Passing auf linearer Kette

- ◆ Eingabe:


$$p(x_1, \dots, x_N) = \psi_{1,2}(x_1, x_2), \dots, \psi_{N-1,N}(x_{N-1}, x_N)$$

Gesucht: $p(x_a) = ?$

- ◆ Berechne Nachrichten (rekursiv):


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

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



- ◆ Ausgabe:

$$p(x_a) = \mu_\alpha(x_a) \mu_\beta(x_a) \quad (\text{Verteilung})$$

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
(Normalisierer univariate Verteilung)


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 $O(NM^2)$

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

$$\forall t: p(x_{t+1} | x_1, \dots, x_t) = p(x_{t+1} | x_t)$$

"Markov" Eigenschaft

- Übergangswahrscheinlichkeiten hängen nicht von t ab:


$$\forall t: p(x_{t+1} | x_t) = p(x_t | x_{t-1})$$

"Stationärer" Prozess

Beispiel: Markov Modelle

■ Beispiel Markov Modell:

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



◆ Verteilungen

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

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

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


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

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

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

Beispiel: Markov Modelle

- Markov Modelle entsprechen probabilistischen endlichen Automaten




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

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

A sequence of three states: x_1 (yellow), x_2 (white), and x_3 (green), connected by arrows from left to right.

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 $\mu_\alpha(x_1)$:

$$\mu_\alpha(x_1 = s) = 1$$

$$\mu_\alpha(x_1 = r) = 1$$

Beispiel: Markov Modelle

- Berechnung mit Message-Passing Algorithmus
- Nachrichten: $\mu_\alpha(x_1), \mu_\alpha(x_2), \mu_\alpha(x_3); \mu_\beta(x_3)$



- Berechnung $\mu_\alpha(x_2)$: Linker Knoten $x_1 = r$ beobachtet


$$\mu_\alpha(x_2) = \Psi_{1,2}(x_1, x_2) \mu_\alpha(x_1) = p(x_1) p(x_2 | x_1) \mu_\alpha(x_1)$$

$$\mu_\alpha(x_2 = s) = p(x_1 = r) p(x_2 = s | x_1 = r) \mu_\alpha(x_1 = r) = 0.5 \cdot 0.4 \cdot 1 = 0.2$$

$$\mu_\alpha(x_2 = r) = p(x_1 = r) p(x_2 = r | x_1 = r) \mu_\alpha(x_1 = r) = 0.5 \cdot 0.6 \cdot 1 = 0.3$$

Beispiel: Markov Modelle

- Berechnung mit Message-Passing Algorithmus
- Nachrichten: $\mu_\alpha(x_1), \mu_\alpha(x_2), \mu_\alpha(x_3); \mu_\beta(x_3)$



- Berechnung $\mu_\alpha(x_3)$: Linker Knoten x_2 nicht beobachtet.


$$\mu_\alpha(x_3) = \sum_{x_2} \Psi_{2,3}(x_2, x_3) \mu_\alpha(x_2) = \sum_{x_2} p(x_3 | x_2) \mu_\alpha(x_2)$$

$$\begin{aligned} \mu_\alpha(x_3 = s) &= p(x_3 = s | x_2 = s) \mu_\alpha(x_2 = s) + p(x_3 = s | x_2 = r) \mu_\alpha(x_2 = r) \\ &= 0.8 \cdot 0.2 + 0.4 \cdot 0.3 = 0.28 \end{aligned}$$

$$\begin{aligned} \mu_\alpha(x_3 = r) &= p(x_3 = r | x_2 = s) \mu_\alpha(x_2 = s) + p(x_3 = r | x_2 = r) \mu_\alpha(x_2 = r) \\ &= 0.2 \cdot 0.2 + 0.6 \cdot 0.3 = 0.22 \end{aligned}$$

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:

$$\mu_\beta(x_3 = s) = 1$$

$$\mu_\beta(x_3 = r) = 1$$

Beispiel: Markov Modelle

- Berechnung mit Message-Passing Algorithmus
- Nachrichten: $\mu_\alpha(x_1), \mu_\alpha(x_2), \mu_\alpha(x_3); \mu_\beta(x_3)$



- Ergebnis: Nachrichten im Anfrageknoten multiplizieren

$$p(x_3 = s | x_1 = r) = \frac{1}{Z} \mu_\alpha(x_3 = s) \mu_\beta(x_3 = s) = \frac{1}{Z} 0.28$$

$$p(x_3 = r | x_1 = r) = \frac{1}{Z} \mu_\alpha(x_3 = r) \mu_\beta(x_3 = r) = \frac{1}{Z} 0.22$$

$$Z = 0.28 + 0.22 = 0.5$$



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

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

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 zykelfrei).



- 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
- Details im Bishop-Textbuch („Sum-Product“ Algorithmus)

Inferenz in Allgemeinen Graphen

- Inferenz in Graphen, die keine Polytrees sind?
- Iteratives Message-Passing Schema, wegen Zyklen im Graph nicht exakt (=approximativer Algorithmus)



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



„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

- Graphische Modelle: Syntax und Semantik
- Graphische Modelle im Maschinellen Lernen
- Exakte Inferenz in Graphischen Modellen
- **Approximative Inferenz in Graphischen Modellen**
- Sequenzmodelle