

Bayesnetze

Seminar “Kognitive Robotik”

Markus Kaiser

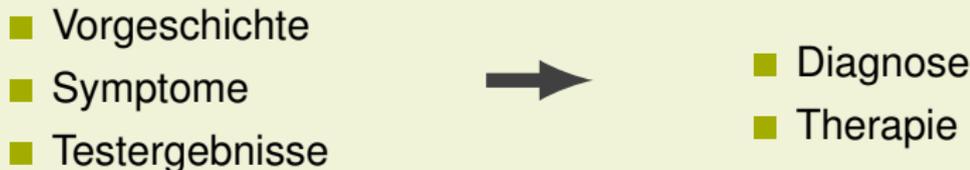
Technische Universität München

12-12-12

Wissen ist selten **sicher** oder vollständig.

Beispiel (Medizinische Diagnose)

Software soll mögliche Ursachen für Beschwerden finden.



Mögliche Unsicherheiten

- Vorgeschichte **unvollständig**, Symptome **vage**
- Symptome und Tests lassen mehrere **Alternativen** zu
- Das Wissen ist **fehlerbehaftet**

Definition (Wahrscheinlichkeitsraum)

Ein **Wahrscheinlichkeitsraum** P besteht aus einer Menge von **Elementarereignissen** Ω , **Ereignissen** A und einem **Wahrscheinlichkeitsmaß** Pr .

- A ist σ -Algebra über Ω
- $\text{Pr} : A \mapsto [0, 1]$
- $P = (\Omega, A, \text{Pr})$

- $\text{Pr}[\Omega] = 1$
- $A \cap B = \emptyset \Rightarrow \text{Pr}[A \cup B] = \text{Pr}[A] + \text{Pr}[B]$

Definition (Bedingte Wahrscheinlichkeit)

A und B seien Ereignisse mit $\Pr[B] > 0$. Die **bedingte Wahrscheinlichkeit** von A unter der Bedingung B ist dann

$$\Pr[A | B] = \frac{\Pr[A \cap B]}{\Pr[B]}$$

Definition (Unabhängigkeit)

Zwei Ereignisse A und B sind **unabhängig** wenn gilt

$$\Pr[A \cap B] = \Pr[A] \cdot \Pr[B] = \Pr[A | B] \cdot \Pr[B]$$

Satz (Produktsatz)

Für unabhängige Ereignisse A_i gilt

$$\Pr \left[\bigcap_{i=1}^n A_i \right] = \prod_{i=1}^n \Pr \left[A_i \mid \bigcap_{k=1}^{i-1} A_k \right]$$

Also zum Beispiel

$$\Pr[A, B, C] = \Pr[A \mid B, C] \cdot \Pr[B \mid C] \cdot \Pr[B]$$

und

$$\Pr[A \mid B] = \frac{\Pr[A, B]}{\Pr[B]} = \alpha \cdot \Pr[A, B]$$

Satz (Satz über die totale Wahrscheinlichkeit)

Sind die Ereignisse A_i paarweise disjunkt und möglich, dann gilt für ein Ereignis B mit $\Pr[B] > 0$

$$\Pr[B] = \sum_{i=1}^n \Pr[B | A_i] \cdot \Pr[A_i]$$

Satz (Satz von Bayes)

Für zwei Ereignisse A und B mit $\Pr[B] > 0$ ist

$$\Pr[A | B] = \frac{\Pr[B | A] \cdot \Pr[A]}{\Pr[B]}$$

Beispiel (Nachmittagsplanung)

Ich habe einen Nachmittag lang Zeit. Ich könnte **Lebensmittel kaufen**, **Sport machen** oder **Lernen**. Ich habe genug Zeit für alle drei. Da ich ein sehr unentschlossener Mensch bin **würfle** ich mittags mit einem **W20**.



Kaufen

$\text{Pr}[K]$
0.5



Sport

$\text{Pr}[S]$
0.4



Lernen

$\text{Pr}[L]$
0.2



Wie groß ist die Wahrscheinlichkeit,

- dass ich **lerne**, **einkaufen** gehe, aber **keinen Sport** mache?

$$\Pr[K, \neg S, L] = \Pr[K] \cdot \Pr[\neg S] \cdot \Pr[L] = 0.5 \cdot 0.6 \cdot 0.2 = 0.06$$

- dass ich **nicht lerne**, aber **Sport mache**?

$$\Pr[S, \neg L] = \sum_k \Pr[k] \cdot \Pr[S] \cdot \Pr[\neg L] = \Pr[S] \cdot \Pr[\neg L] = 0.32$$

Kaufen

$$\frac{\Pr[K]}{0.5}$$

Sport

$$\frac{\Pr[S]}{0.4}$$

Lernen

$$\frac{\Pr[L]}{0.2}$$

- Alle möglichen Belegungen lassen sich in einer gemeinsamen Verteilung (**joint distribution**) darstellen.
- Für n binäre Zufallsgrößen hat diese aber 2^n Einträge.

K	S	L	Pr	K	S	L	Pr
F	F	F	0.24	T	F	F	0.24
F	F	T	0.06	T	F	T	0.06
F	T	F	0.16	T	T	F	0.16
F	T	T	0.04	T	T	T	0.04

Beispiel (Erweiterte Nachmittagsplanung)

Ich möchte das Haus nicht verlassen müssen, wenn es regnet. Deshalb halbiere ich bei **Regen** die Wahrscheinlichkeit für Aktivitäten außer Haus.

Wenn ich weder Sport mache noch lerne bekomme ich ein **schlechtes Gewissen**. Nach meinem Würfelergebnis möchte ich wissen, wie groß die Wahrscheinlichkeit ist, am Abend schlecht gelaunt zu sein.

Probleme:

- $\Pr[R, S] \neq \Pr[R] \cdot \Pr[S]$
- Alle Sätze brauchen **Unabhängigkeit**

Es sind immernoch Unabhängigkeiten vorhanden:

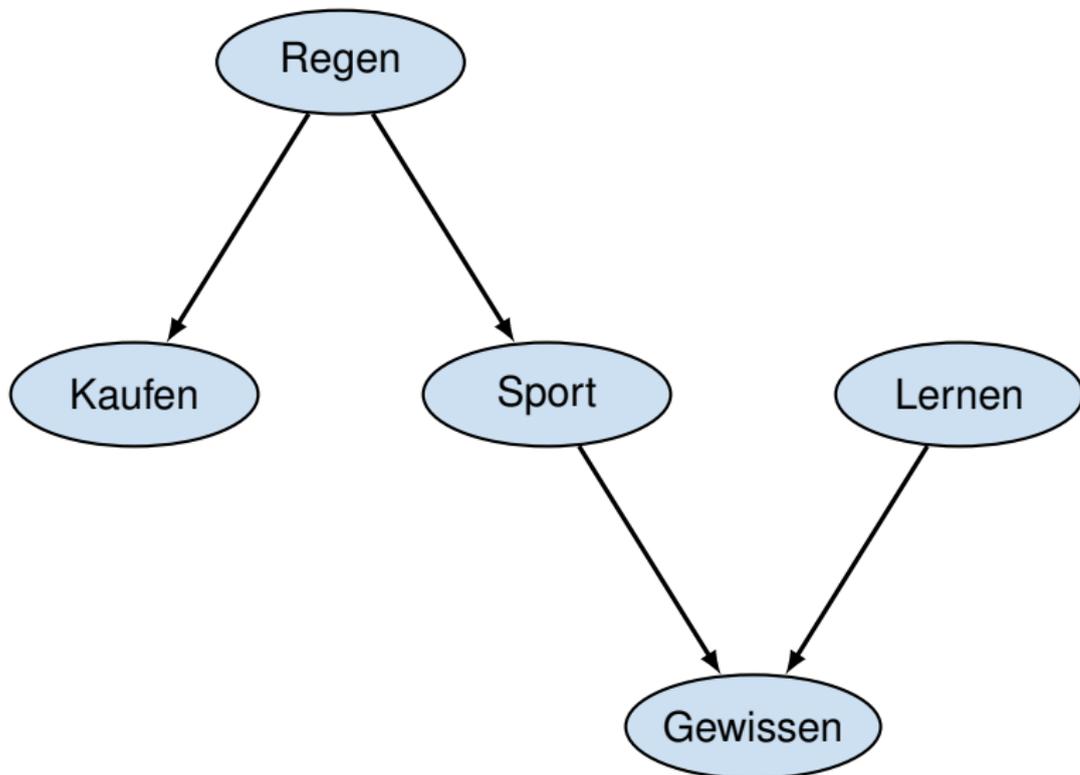
- Regen beeinflusst das Lernen nicht
- Einkaufen und Sport beeinflussen sich nicht

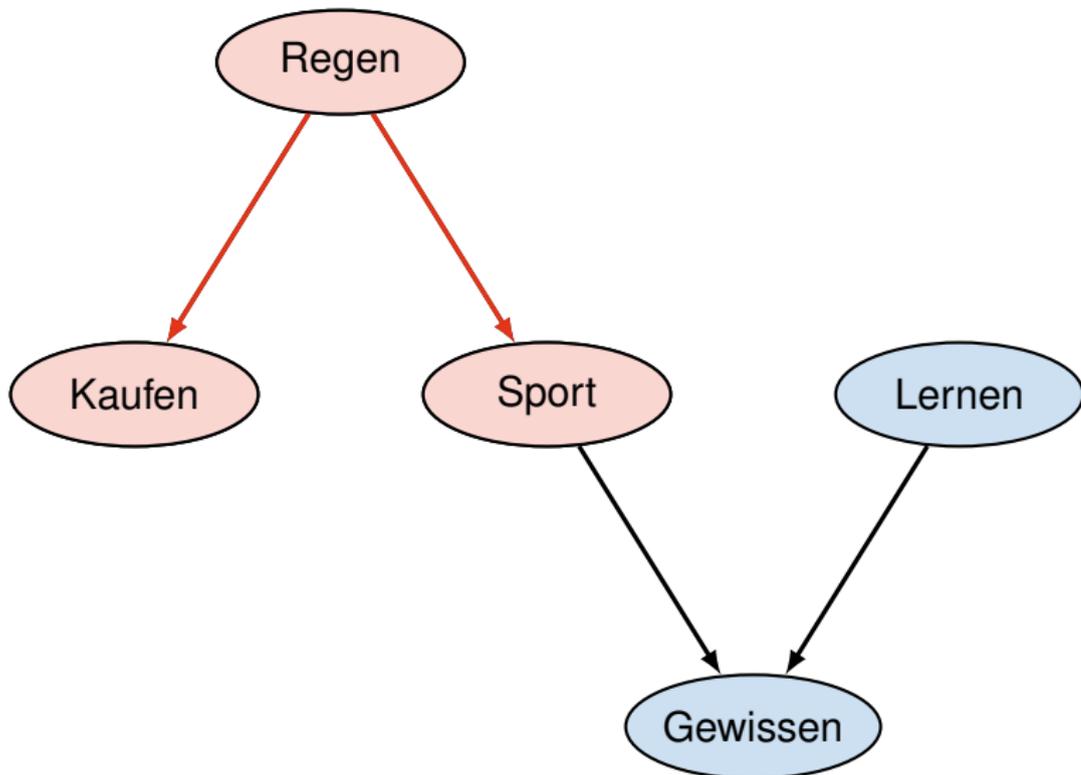
Definition (Bedingte Unabhängigkeit)

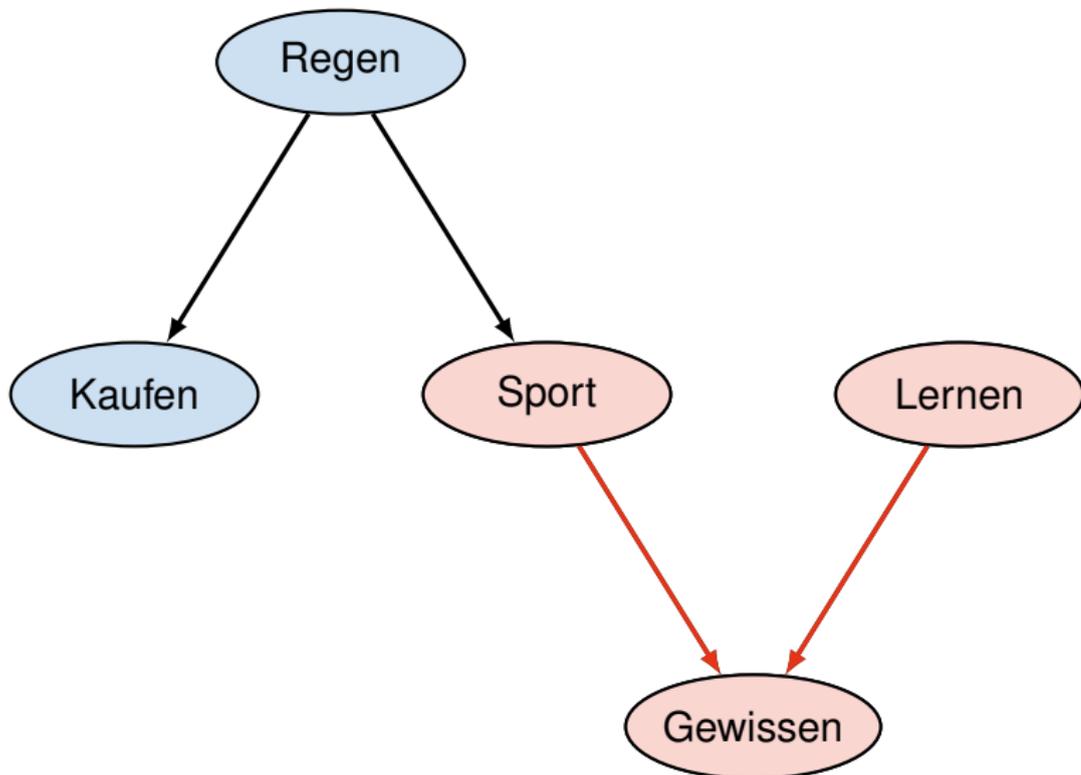
Zwei Ereignisse A und B sind **bedingt unabhängig** unter einem Ereignis C wenn gilt

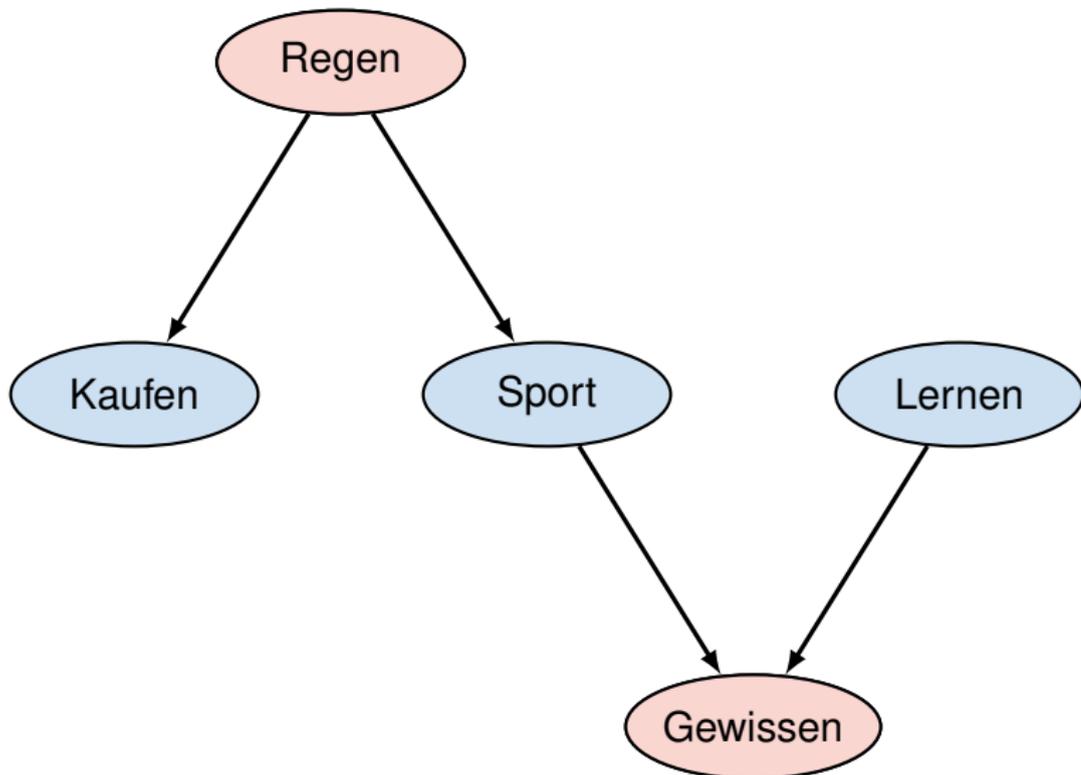
$$\Pr[A, B \mid C] = \Pr[A \mid C] \cdot \Pr[B \mid C]$$

Einkaufen und Sport sind **bedingt unabhängig** unter Regen.





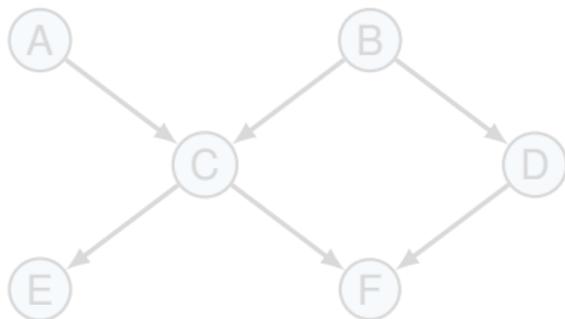




Definition (d-Separation)

Zwei Knotenmengen X und Y sind in einem DAG G durch Z **d-separiert** $\langle X \mid Z \mid Y \rangle_G$ wenn es **keinen** (ungerichteten) Pfad zwischen X und Y gibt für den gilt

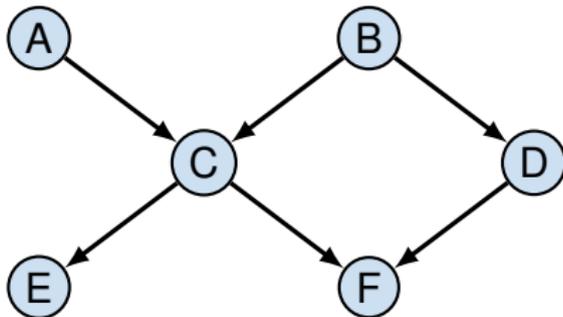
- 1 Jeder Knoten an dem Kanten **zusammenlaufen** ist selbst in Z oder hat einen Nachfahren in Z
- 2 Jeder **andere Knoten** ist nicht in Z



Definition (d-Separation)

Zwei Knotenmengen X und Y sind in einem DAG G durch Z **d-separiert** $\langle X \mid Z \mid Y \rangle_G$ wenn es **keinen** (ungerichteten) Pfad zwischen X und Y gibt für den gilt

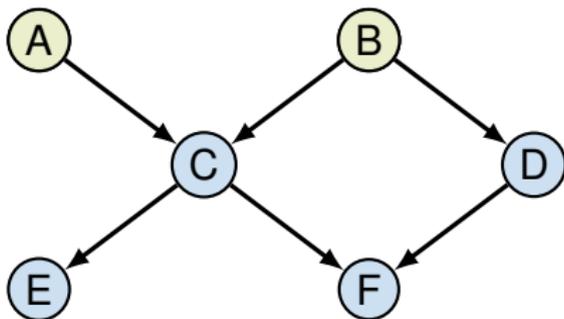
- 1 Jeder Knoten an dem Kanten **zusammenlaufen** ist selbst in Z oder hat einen Nachfahren in Z
- 2 Jeder **andere Knoten** ist nicht in Z



Definition (d-Separation)

Zwei Knotenmengen X und Y sind in einem DAG G durch Z **d-separiert** $\langle X \mid Z \mid Y \rangle_G$ wenn es **keinen** (ungerichteten) Pfad zwischen X und Y gibt für den gilt

- 1 Jeder Knoten an dem Kanten **zusammenlaufen** ist selbst in Z oder hat einen Nachfahren in Z
- 2 Jeder **andere Knoten** ist nicht in Z

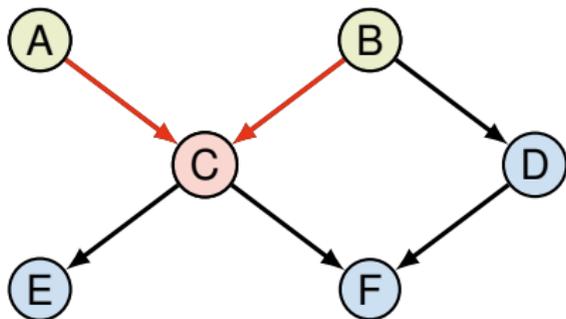
 $\langle A \mid \emptyset \mid B \rangle$ 

Definition (d-Separation)

Zwei Knotenmengen X und Y sind in einem DAG G durch Z **d-separiert** $\langle X \mid Z \mid Y \rangle_G$ wenn es **keinen** (ungerichteten) Pfad zwischen X und Y gibt für den gilt

- 1 Jeder Knoten an dem Kanten **zusammenlaufen** ist selbst in Z oder hat einen Nachfahren in Z
- 2 Jeder **andere Knoten** ist nicht in Z

$$\neg \langle A \mid F \mid B \rangle$$

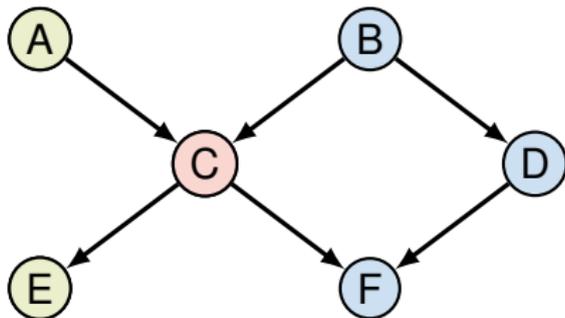


Definition (d-Separation)

Zwei Knotenmengen X und Y sind in einem DAG G durch Z **d-separiert** $\langle X \mid Z \mid Y \rangle_G$ wenn es **keinen** (ungerichteten) Pfad zwischen X und Y gibt für den gilt

- 1 Jeder Knoten an dem Kanten **zusammenlaufen** ist selbst in Z oder hat einen Nachfahren in Z
- 2 Jeder **andere Knoten** ist nicht in Z

$\langle A \mid C \mid E \rangle$



Satz (Unabhängigkeiten in Bayes-Netzen)

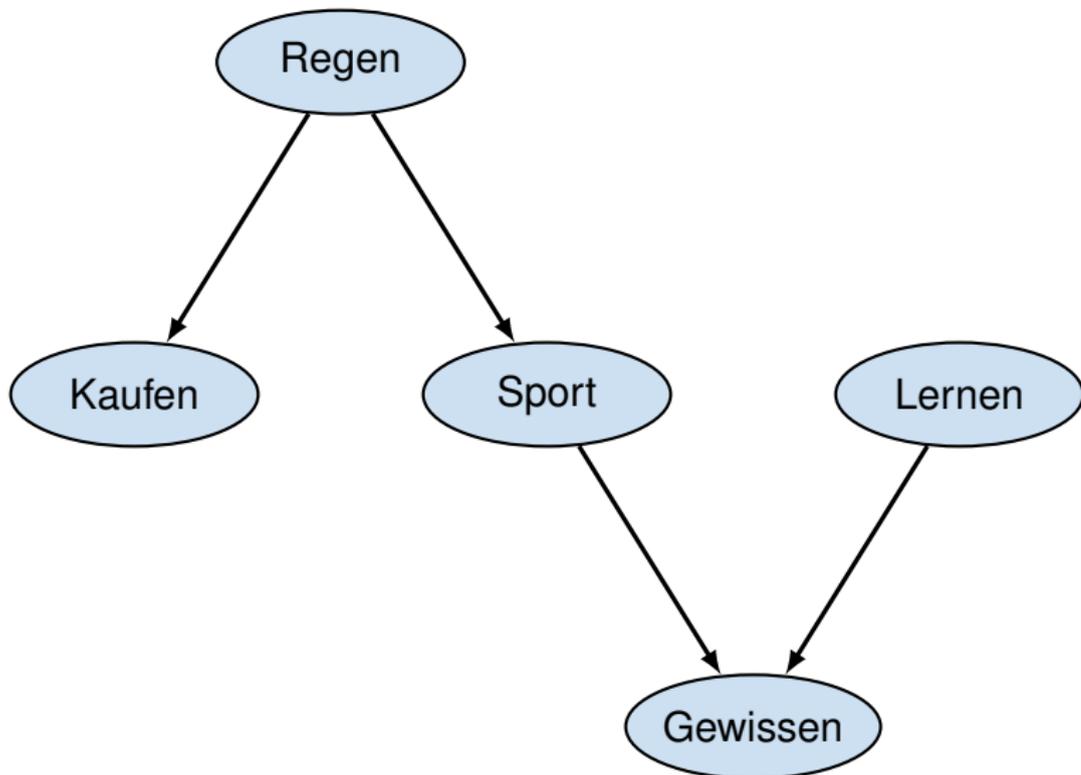
Zufallsvariablen X und Y sind in einem Bayes-Netz **bedingt unabhängig** unter E wenn $\langle X \mid E \mid Y \rangle$.

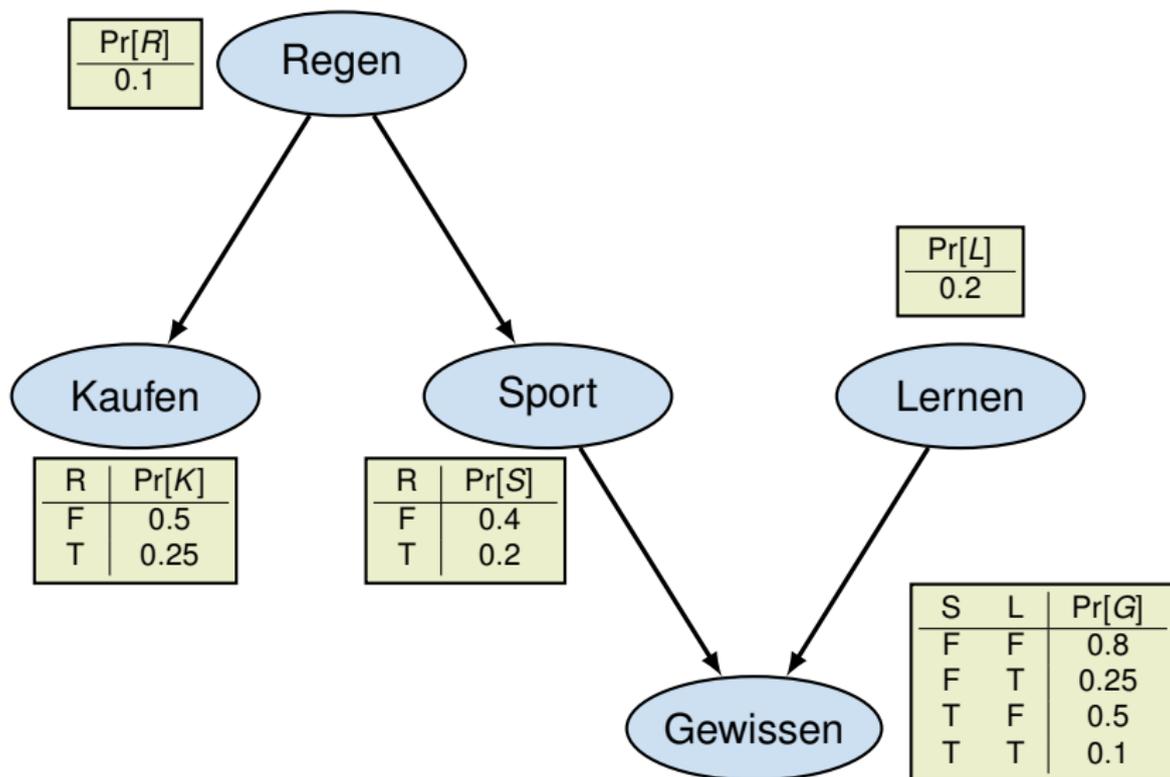
Speziell ist jeder Knoten **bedingt unabhängig** von

- **allen nicht-Nachfahren** gegeben seine Eltern
- **allen Knoten** gegeben seine Markov-Einbettung

Definition (Markov-Einbettung)

Die **Markov-Einbettung** (Markov blanket) eines Knotens ist die Menge all seiner **Eltern**, **Kinder** und den **Eltern aller Kinder**.





Satz (Gemeinsame Verteilung)

Für einen Eintrag $\Pr[x_1, \dots, x_n]$ in der gemeinsamen Verteilung eines Bayesnetzes gilt

$$\Pr[x_1, \dots, x_n] = \prod_{i=1}^n \Pr[x_i \mid \text{parents}(X_i)]$$

Was ist die Wahrscheinlichkeit, dass ich ein **schlechtes Gewissen** bei **schönem Wetter** habe, obwohl ich **Sport gemacht** habe nachdem ich **einkaufen** war?

$$\begin{aligned} \Pr[G, S, \neg L, K, \neg R] &= \Pr[G \mid S, \neg L, K, \neg R] \cdot \Pr[S \mid \neg L, K, \neg R] \cdot \dots \\ &= \Pr[G \mid S, \neg L] \cdot \Pr[S \mid \neg R] \\ &\quad \cdot \Pr[\neg L] \cdot \Pr[K \mid \neg R] \cdot \Pr[\neg R] \\ &= 0.5 \cdot 0.8 \cdot 0.4 \cdot 0.5 \cdot 0.9 = 0.072 \end{aligned}$$

Wie konstruiert man zu einer Domäne ein möglichst **kompaktes**, **lokal strukturiertes** und **natürliches** Netz?

- **Expertenwissen** notwendig
- Knoten modellieren **quantifizierbare** Ereignisse
 - Unbekanntes in Verteilungen
 - Einfachheit vs. Genauigkeit
- **Lokale Struktur** schaffen
 - Direkte Einflüsse
 - Kleine Einflüsse ignorieren
- **Kausale Reihenfolge** abbilden

- Grundsätzlich **beliebige** Verteilungen möglich
- Abwägung zwischen **effizient** und **exakt**

- Logische Verknüpfungen
- **Kanonische** Verteilungen

Beispiel (Noisy Or)

Ein Patient hat Fieber, wenn er eine Erkältung oder Grippe hat.
Hat er aber eine Krankheit, könnte er auch kein Fieber haben.

$$\Pr[\neg B \mid E, \neg G] = 0.6, \quad \Pr[\neg B \mid \neg E, G] = 0.2$$

E	G	Pr[B]	Pr[¬B]	E	G	Pr[B]	Pr[¬B]
F	F	0	1	T	F	0.4	0.6
F	T	0.8	0.2	T	T	0.88	0.12

- Grundsätzlich **beliebige** Verteilungen möglich
- Abwägung zwischen **effizient** und **exakt**

- Logische Verknüpfungen
- **Kanonische** Verteilungen

Beispiel (Noisy Or)

Ein Patient hat Fieber, wenn er eine Erkältung oder Grippe hat. Hat er aber eine Krankheit, könnte er auch kein Fieber haben.

$$\Pr[\neg B \mid E, \neg G] = 0.6, \quad \Pr[\neg B \mid \neg E, G] = 0.2$$

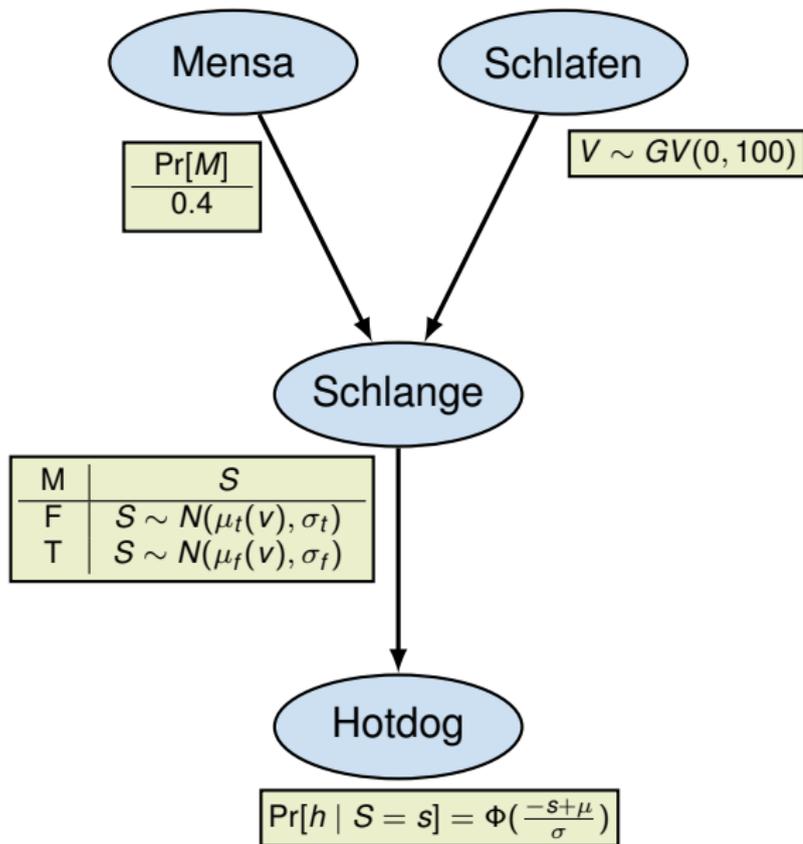
E	G	Pr[B]	Pr[¬B]	E	G	Pr[B]	Pr[¬B]
F	F	0	1	T	F	0.4	0.6
F	T	0.8	0.2	T	T	0.88	0.12

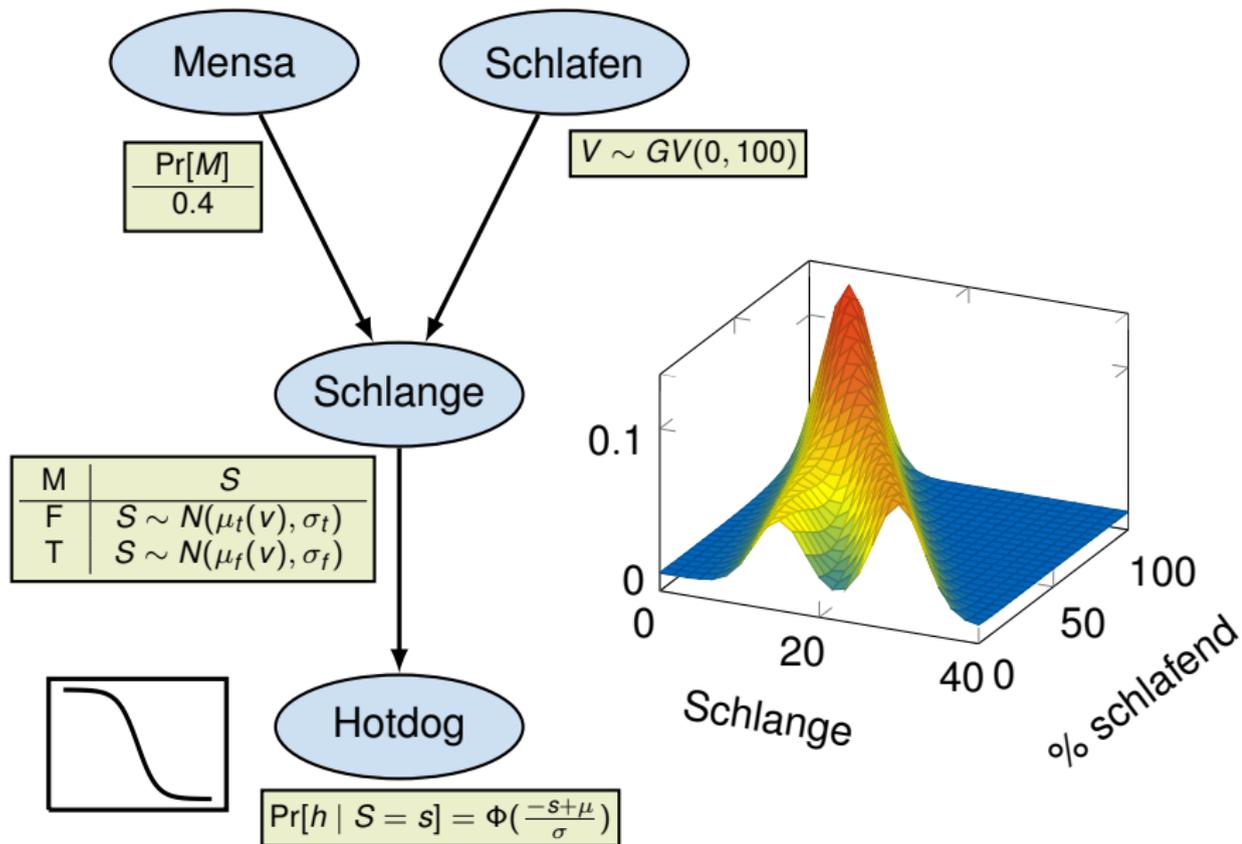
Beispiel (Hotdog zum Mittagessen)

Im MI-Gebäude gibt es jeden Dienstag Hotdogs. Um genau 12 Uhr werfe ich einen Blick auf die **Schlange** und entscheide allein anhand ihrer Länge ob ich auf mein Mittagessen **verzichte**.

Die Länge der Schlange ist abhängig davon, ob es in der **Mensa** akzeptables Essen gibt und wieviele Studenten **verschlafen** haben.

- Der Anteil der schlafenden Studenten ist **gleichverteilt**.
- Die Länge der Schlange ist **normalverteilt**.





Definition (Inferenz)

Für ein Netz mit Knotenmenge $K = \{X\} \cup E \cup Y$ soll die **Wahrscheinlichkeit** ermittelt werden, dass eine **Variable** X einen Wert annimmt, unter der Bedingung, dass für die **Evidenzvariablen** E die Werte e **beobachtet** werden und die **versteckten Variablen** Y unbekannt sind.

$$\Pr[X \mid e] = \Pr[X = x \mid E_1 = e_1, \dots, E_n = e_n] = ?$$

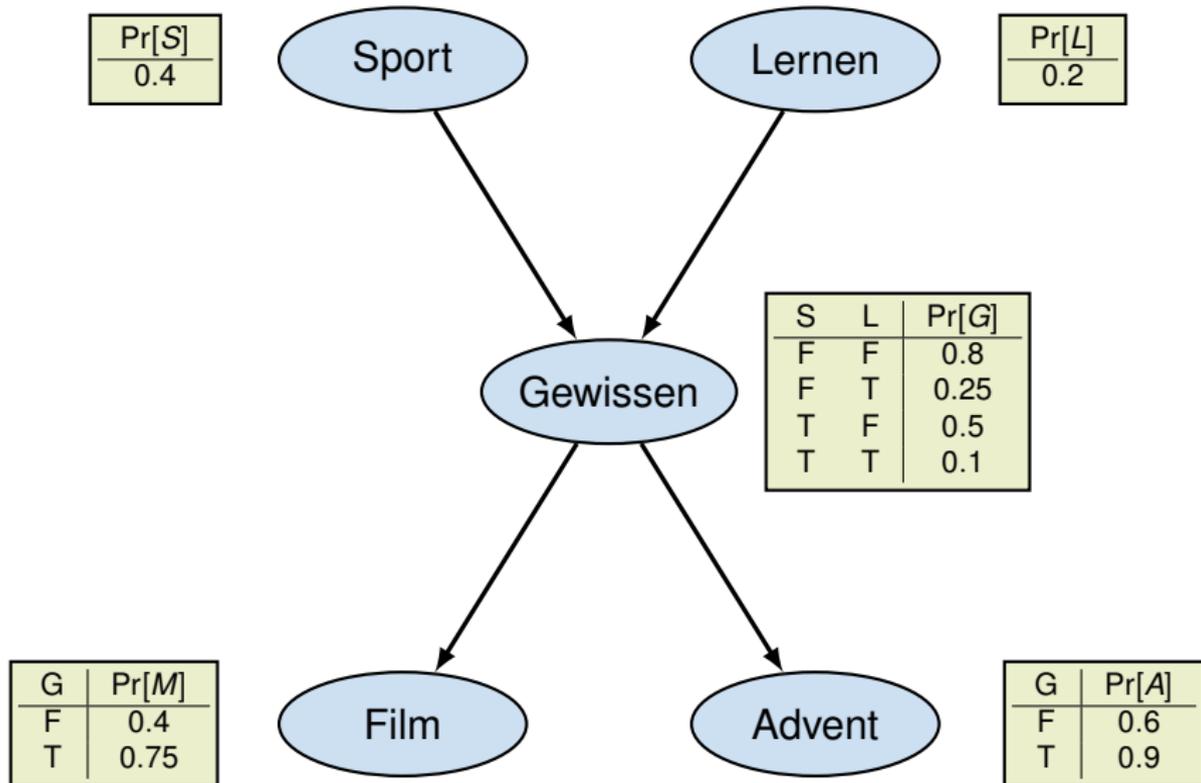
Wenn ich abends ein **schlechtes Gewissen** habe, wie groß ist die Wahrscheinlichkeit, dass ich **nicht gelernt** habe?

$$\Pr[\neg L \mid G] \approx 0.936$$

Beispiel (Bekämpfung des schlechten Gewissens)

Wenn ich ein schlechtes Gewissen habe werde ich unglücklich. Unglück kann man bekämpfen, indem man sich mit einem Film ablenkt oder passend zur Jahreszeit Schokolade aus dem Adventskalender isst.

Zur Vereinfachung soll der Einfluss des Regens nun nicht mehr beachtet werden.



Beispiel

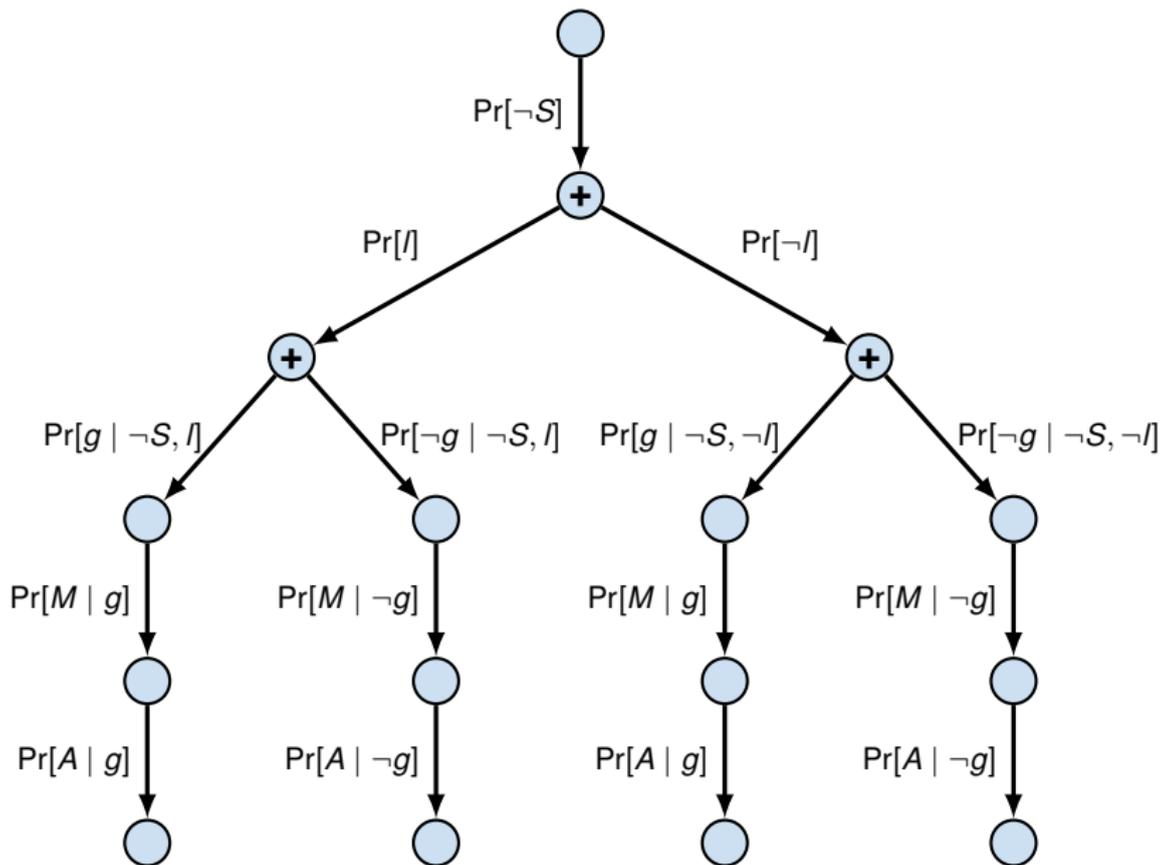
Wie groß ist die Wahrscheinlichkeit, dass ich **ohne Sport** einen **Film** schaue und dabei **Schokolade** esse?

Aus dem Satz der totalen Wahrscheinlichkeit erhalten wir

$$\Pr[X | e] = \alpha \Pr[X, e] = \alpha \sum_y \Pr[X, e, y]$$

also

$$\begin{aligned} \Pr[\neg S | M, A] &= \alpha \sum_g \sum_l \Pr[\neg S, M, A, g, l] \\ &= \alpha \cdot \Pr[\neg S] \cdot \sum_l \Pr[l] \\ &\quad \cdot \sum_g \Pr[g | \neg S, l] \cdot \Pr[M | g] \cdot \Pr[A | g] \\ &\approx 0.585 \end{aligned}$$



- Inferenz durch Aufzählen hat **exponentielle** Laufzeit
- Mit dynamischer Programmierung **linear** auf Polytrees
- Aber: Exakte Inferenz ist **NP-vollständig**

Alternative: **Approximative Algorithmen**

- Direct/Rejection Sampling
- Likelihood weighting
- Markov chain Monte Carlo (MCMC)

- Nachmittagsplanung
- Krankheitsdiagnose
- Kriminalitätsbekämpfung
- Genanalyse
- Entscheidungsfindung

Bayesnetze ...

- repräsentieren **mehrdimensionale Zufallsvariablen**
- haben eine kompakte Darstellung
- benötigen **Expertenwissen**
- modellieren **Kausalitätszusammenhänge**
- sparen Speicher
- erlauben Inferenz