



OTTO VON GUERICKE  
UNIVERSITÄT  
MAGDEBURG

INF

FAKULTÄT FÜR  
INFORMATIK

# Intelligente Systeme

## Unsicheres Wissen

**Prof. Dr. R. Kruse    C. Braune**

{rudolf.kruse, christian.braune}@ovgu.de

Institut für Intelligente Kooperierende Systeme  
Fakultät für Informatik

Otto-von-Guericke-Universität Magdeburg

# Motivation

In vielen Fällen ist unser Wissen über die Welt

unvollständig: **Wissensumfang ist nicht hinreichend**

z.B.: „Ich weiß nicht, wie der Bus an Feiertagen fährt, da ich nur werktags fahre!“

unscharf: **Wissen ist nicht präzise genug**

z.B.: „Der Bus fährt ungefähr zu jeder vollen Stunde!“

oder unsicher: **Wissen ist unzuverlässig**

z.B.: „Der Bus fährt wahrscheinlich um 9 : 00 ab.“

Wir müssen trotzdem agieren!

Schließen unter Unsicherheit

Schließen über Eintretenswahrscheinlichkeiten

... und Kosten/Nutzen

## Beispiel

**Ziel:** Um 9:15 Uhr in der Uni sein, um an einer Vorlesung teilzunehmen.

Es gibt mehrere **Pläne**, um das Ziel zu erreichen:

$P_1$ : 8:00 Uhr aufstehen, 8:55 Uhr Haus verlassen, 9:00 Uhr Bus...

$P_2$ : 7:30 Uhr aufstehen, 8:25 Uhr Haus verlassen, 8:30 Uhr Bus...

...

Alle Pläne sind *korrekt*, aber

sie implizieren verschiedene **Kosten** und verschiedene **Wahrscheinlichkeiten** Ziel *tatsächlich* zu erreichen.

$P_2$  am besten, denn Vorlesung ist wichtig, und Erfolgsrate bei  $P_1$  liegt nur bei ca. 85–95%.

# Grade der Überzeugung

- Wir (oder andere Agenten) sind von Regeln und Fakten nur bis zu gewissem Grad überzeugt
- Eine Möglichkeit, **Grad der Überzeugung auszudrücken**: Benutzung von **Wahrscheinlichkeiten**
- Die Aussage „Agent ist von Sensorinformation zu 0,9 überzeugt.“ bedeutet: Der Agent glaubt in 9 von 10 Fällen an Richtigkeit der Information
- Wahrscheinlichkeiten fassen „Unsicherheit“ bedingt durch Unwissen zusammen
- Unsicherheit nicht mit *Unschärfe (Impräzision)* verwechseln (→ Fuzzy-Logik)
- Das Prädikat *groß* ist **unscharf**, wohingegen die Aussage „*Das könnte Peters Uhr sein.*“ **unsicher** ist

# Rationale Entscheidungen unter Unsicherheit

Verschiedene *Aktionen* oder *Pläne* zur Auswahl können mit verschiedenen *Wahrscheinlichkeiten* zu verschiedenen Ergebnissen führen

*Aktionen* verursachen verschiedene – ggf. subjektive – **Kosten**

*Ergebnisse* haben verschiedenen – ggf. subjektiven – **Nutzen**

Rational: wähle Aktion, die größten **zu erwartenden Gesamtnutzen** hat

**Entscheidungstheorie = Nutzentheorie + Wahrscheinlichkeitstheorie**

# Entscheidungstheoretischer Agent

---

## Algorithmus 1 DT-Agent

---

**Eingabe:** eine *Wahrnehmung*

**Ausgabe:** eine *Aktion*

- 1: static: eine Menge probabilistischer Überzeugungen über den Zustand der Welt
  - 2: Berechne aktualisierte Wahrscheinlichkeiten für den aktuellen Zustand auf Basis vorliegender Evidenzen inkl. der aktuellen Wahrnehmung und vorheriger Aktionen
  - 3: Berechne Ausgabewahrscheinlichkeiten für Aktionen, gegebene Aktionsbeschreibungen und Wahrscheinlichkeiten der aktuellen Zustände
  - 4: Wähle *Aktion* mit höchstem erwarteten Nutzen, gegeben die Ausgabewahrscheinlichkeiten und Informationen über die Nützlichkeit
  - 5: **return** *Aktion*
-

# Sicherheitsfaktoren in Mycin

**Ziel:** Entwicklung eines Systems, das Ärzte bei der Diagnose bakterieller Infektionen unterstützt und geeignete Antibiotika empfiehlt

**Features:** Unsicheres Wissen wurde durch sog. *Unsicherheitsfaktoren* (*uncertainty factors*) repräsentiert.

**Wissen:** 500 (unsichere) Entscheidungsregeln als Wissensbasis.

## Fallspezifisches Wissen:

- statisch: Patientendaten
- dynamisch: Zwischenergebnisse (Fakten)

## Stärken:

- Diagnose-orientierte Befragung
- Hypothesengenerierung
- Therapieempfehlung
- Erklärung des Inferenzpfades

# Unsicherheitsfaktoren

Unsicherheitsfaktor  $CF \in [-1, 1] \approx$  Überzeugungsgrad.

Regeln:

$$CF(A \rightarrow B) \left\{ \begin{array}{ll} = 1 & B \text{ ist sicher wahr gegeben } A \\ > 0 & A \text{ unterstützt } B \\ = 0 & A \text{ hat keinen Einfluss auf } B \\ < 0 & A \text{ widerspricht } B \\ = -1 & B \text{ ist sicherlich falsch gegeben } A \end{array} \right.$$



# Eine Mycin Regel


RULE035

PREMISE:     (\$AND       (SAME CNTXT GRAM GRAMNEG)  
                              (SAME CNTXT MORPH ROD)  
                              (SAME CNTXT AIR ANAEROBIC))  
ACTION:       (CONCL.CNTXT IDENTITY BACTEROIDES TALLY .6)

Wenn   1) die *Gram-Färbung* des Organismus *gramneg* ist, und  
       2) die *Morphologie* des Organismus *rod* ist, und  
       3) die *Aerobizität* des Organismus *anaerob* ist  
dann   gibt es starke Hinweise (0.6) dafür, dass  
       die *Identität* des Organismus *bacteroid* ist.

# Beispiel

$A \rightarrow B$ [0.80]	$A$ [1.00]
$C \rightarrow D$ [0.50]	$C$ [0.50]
$B \wedge D \rightarrow E$ [0.90]	$F$ [0.80]
$E \vee F \rightarrow G$ [0.25]	$H$ [0.90]
$H \rightarrow G$ [0.30]	



# Propagationsregeln

**Konjunktion:**  $CF(A \wedge B) = \min\{CF(A), CF(B)\}$

**Diskjunktion:**  $CF(A \vee B) = \max\{CF(A), CF(B)\}$

**Serielle Komb.:**  $CF(B, \{A\}) = CF(A \rightarrow B) \cdot \max\{0, CF(A)\}$

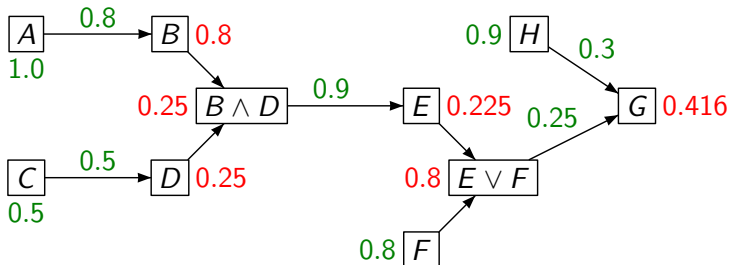
**Parallele Komb.:** for  $n > 1$  :

$$CF(B, \{A_1, \dots, A_n\}) = \\ f(CF(B, \{A_1, \dots, A_{n-1}\}), CF(B, \{A_n\}))$$

mit

$$f(x, y) = \begin{cases} x + y - xy & \text{wenn } x, y > 0 \\ x + y + xy & \text{wenn } x, y < 0 \\ \frac{x + y}{1 - \min\{|x|, |y|\}} & \text{sonst} \end{cases}$$

## Beispiel (Fortsetzung)




$$f(0.3 \cdot 0.9, 0.25 \cdot 0.8) = 0.27 + 0.2 - 0.27 \cdot 0.2 = 0.416$$

# War Mycin ein Fehlschlag?

MYCIN funktionierte, wegen baumartiger Struktur der Regeln.  
Das Schema, mit dem Regeln kombiniert werden, ist inkonsistent.

**Beispiel:**  $CF(A) = 0.9$ ,  $CF(D) = ?$



Sicherheitsfaktor wurde nur erhöht, weil (die selbe) Information über unterschiedliche (parallele) Pfade transferiert wurde!

# Axiomatische Wahrscheinlichkeitstheorie

Gegeben eine Ereignisalgebra  $\mathcal{E}$ , wird jedem Ereignis  $E \in \mathcal{E}$  seine Wahrscheinlichkeit durch eine

**Wahrscheinlichkeitsfunktion**  $P : \mathcal{E} \rightarrow [0, 1]$  zugewiesen.

$P$  muss dabei die sogenannten **Kolmogorov Axiome** erfüllen:

- $\forall E \in \mathcal{E} : 0 \leq P(E) \leq 1$
- $P(\Omega) = 1$
- Für paarweise disjunkte Ereignisse  $E_1, E_2, \dots \in \mathcal{E}$  gilt:

$$P\left(\bigcup_{i=1}^{\infty} E_i\right) = \sum_{i=1}^{\infty} P(E_i)$$

Aus diesen Axiomen lassen sich u.a. die folgenden Eigenschaften ableiten:

- $\forall E \in \mathcal{E} : P(\bar{E}) = 1 - P(E)$
- $P(\emptyset) = 0$
- Wenn  $E_1, E_2 \in \mathcal{E}$  sich gegenseitig ausschließen, dann  $P(E_1 \cup E_2) = P(E_1) + P(E_2)$ .

## Wieso sind die Axiome sinnvoll?

- Wenn  $P$  objektiv beobachtbare Wahrscheinlichkeiten beschreibt (z.B. Würfelexperiment), dann machen die Axiome natürlich Sinn
- Aber wieso sollte ein Agent Axiome beachten, wenn er den *Grad seiner (subjektiven) Überzeugung* modelliert?
- Axiome schränken Menge der Überzeugungen ein, die Agent aufrechterhalten kann
- Eines der überzeugendsten Argumente, warum subjektive Überzeugungen den Axiome genügen sollten, stammt von de Finetti (1931):  
Verhält sich ein Agent in einer unsicheren Umgebung nicht gemäß den Axiomen, so hat er auf lange Sicht in der Umgebung Nachteile.

# Unbedingte Wahrscheinlichkeiten

$P(A)$  bezeichnet **unbedingte** oder **a priori** Wahrscheinlichkeit, dass Ereignis  $A$  eintritt, falls *keine* zusätzliche Information verfügbar, wobei  $A$  eine Menge ist

Man kann Wahrscheinlichkeiten auch für Aussagen nutzen:

$$P(\text{Karies} = \text{wahr}) = 0.1, P(\text{Karies} = \text{falsch}) = 0.9$$

*Karies* ist eine binäre Zufallsvariable

Wahrscheinlichkeiten werden durch statistische Analysen oder aus allgemeinen Regeln gewonnen



# Unbedingte Wahrscheinlichkeiten

Eine Zufallsvariable kann nicht nur die Werte wahr und falsch annehmen, sondern mehrere Werte

Zufallsvariable Wetter mit  $P(\text{Wetter} = \text{sonnig})$  als Kurzform für  $P(\{\omega \mid \text{Wetter}(\omega) = \text{sonnig}\})$

$$P(\text{Wetter} = \text{sonnig}) = 0.7$$

$$P(\text{Wetter} = \text{Regen}) = 0.2$$

$$P(\text{Wetter} = \text{bewölkt}) = 0.08$$

$$P(\text{Wetter} = \text{Schnee}) = 0.02$$

# Verbundwahrscheinlichkeit I

$P(X)$ : Vektor der Wahrscheinlichkeiten für (geordneten) Wertebereich der Zufallsvariable  $X$ :

$$P(\text{Schmerz}) = \langle 0.1, 0.9 \rangle$$

$$P(\text{Wetter}) = \langle 0.7, 0.2, 0.08, 0.02 \rangle$$

Vektoren definieren Wahrscheinlichkeitsverteilung der Zufallsvariablen *Schmerz* und *Wetter*

$P(\text{Schmerz}, \text{Wetter})$  ist  $(4 \times 2)$ -Tabelle von Wahrscheinlichkeiten aller Kombinationen der Werte einer Zufallsvariablen

	Schmerz = wahr $\hat{=}$ $S$	Schmerz = falsch $\hat{=}$ $\neg S$
Wetter = sonnig	$P(\text{Wetter} = \text{sonnig} \wedge S)$	$P(\text{Wetter} = \text{sonnig} \wedge \neg S)$
Wetter = Regen	$P(\text{Wetter} = \text{Regen} \wedge S)$	$P(\text{Wetter} = \text{Regen} \wedge \neg S)$
Wetter = bewölkt	$P(\text{Wetter} = \text{bewölkt} \wedge S)$	$P(\text{Wetter} = \text{bewölkt} \wedge \neg S)$
Wetter = Schnee	$P(\text{Wetter} = \text{Schnee} \wedge S)$	$P(\text{Wetter} = \text{Schnee} \wedge \neg S)$

## Verbundwahrscheinlichkeit II

**Verbundwahrscheinlichkeitsverteilung**  $P(X_1, \dots, X_n)$  weist jedem atomaren Ereignis eine Wahrscheinlichkeit zu:

	Schmerz=wahr	Schmerz=falsch
Karies=wahr	0.04	0.06
Karies=falsch	0.01	0.89

Da alle atomaren Ereignisse disjunkt, ist die Summe über alle Felder 1 (Disjunktion der Ereignisse)


Alle interessanten Wahrscheinlichkeiten sind aus dieser Tabelle berechenbar, z.B.:

$$P(\text{Karies=wahr}) =$$

$$P(\text{Karies=wahr} \wedge \text{Schmerz=wahr}) + P(\text{Karies=wahr} \wedge \text{Schmerz=falsch})$$

# Bedingte Wahrscheinlichkeiten I

$$P(A | B) = \frac{P(A \wedge B)}{P(B)}$$



Produktregel:  $P(A \wedge B) = P(A | B)P(B)$

analog:  $P(A \wedge B) = P(B | A)P(A)$

$A$  und  $B$  heißen **unabhängig** voneinander, falls  $P(A | B) = P(A)$  und  $P(B | A) = P(B)$

$A$  und  $B$  unabhängig  $\iff P(A \wedge B) = P(A)P(B)$

# Interpretation bedingter Wahrscheinlichkeiten

Die Interpretation:

„ $P(A | B) = 0.8$  bedeutet, dass  $P(A) = 0.8$  ist  
falls  $B$  wahr ist“

ist falsch!

$P(A)$  ist immer die a priori Wahrscheinlichkeit, nicht die a posteriori Wahrscheinlichkeit  $P(A | B)$ , gegeben eine Evidenz ( $B$  wahr)

# Bedingte Wahrscheinlichkeiten II

Neue Information kann die (bedingte) Wahrscheinlichkeit eines Ereignisses ändern.

Beispiel: Wahrscheinlichkeit von Zahnlöchern erhöht sich, wenn man weiß, dass Patient Zahnschmerzen hat.

Bei Zusatzinformation: nicht mehr mit a priori Wahrscheinlichkeiten rechnen!

$P(A | B)$  bezeichnet **bedingte** oder **a posteriori** Wahrscheinlichkeit von  $A$ , sofern alleinige Beobachtung (Evidenz)  $B$  gegeben.

$P(X | Y)$ : Tabelle aller bedingten Wahrscheinlichkeiten über alle Werte von  $X$  und  $Y$

## Bedingte Wahrscheinlichkeiten III

Beispiel:  $P(\text{Schmerz, Karies})$  ist die gemeinsame Wahrscheinlichkeitsverteilung von beiden Zufallsvariablen und besteht aus der folgenden Tabelle:

	$S \hat{=} \text{Schmerz} = \text{wahr}$	$\neg S \hat{=} \text{Schmerz} = \text{falsch}$
$K \hat{=} \text{Karies} = \text{wahr}$	$P(K \wedge S) = 0.04$	$P(K \wedge \neg S) = 0.06$
$\neg K \hat{=} \text{Karies} = \text{falsch}$	$P(\neg K \wedge S) = 0.01$	$P(\neg K \wedge \neg S) = 0.89$

Alle Zellen summieren sich zu 1 auf.

# Die Bayes'sche Regel

Es gilt

$$P(A \wedge B) = P(A | B)P(B) \quad \text{und} \quad P(A \wedge B) = P(B | A)P(A)$$

Durch Gleichsetzen der rechten Seiten folgt:

$$\begin{aligned} P(A | B)P(B) &= P(B | A)P(A) \\ \implies P(A | B) &= \frac{P(B | A)P(A)}{P(B)} \end{aligned}$$

Für mehrwertige Variablen erhält man mehrere Gleichungen:

$$P(Y | X) = \frac{P(X | Y)P(Y)}{P(X)}$$

Verallgemeinerung (bzgl. Hintergrundevidenzen):

$$P(Y | X, E) = \frac{P(X | Y, E)P(Y | E)}{P(X | E)}$$



# Anwendung der Bayes'schen Regel I

$$P(\text{Schmerz}=\text{wahr} \mid \text{Karies}=\text{wahr}) = 0.4$$

$$P(\text{Karies}=\text{wahr}) = 0.1$$

$$P(\text{Schmerz}=\text{wahr}) = 0.05$$

$$P(\text{Karies}=\text{wahr} \mid \text{Schmerz}=\text{wahr}) = \frac{0.4 \cdot 0.1}{0.05} = 0.8$$

Warum nicht gleich  $P(\text{Karies}=\text{wahr} \mid \text{Schmerz}=\text{wahr})$  schätzen?

## Anwendung der Bayes'schen Regel II

Kausales Wissen wie  $P(\text{Schmerz}=\text{wahr} \mid \text{Karies}=\text{wahr})$  ist i.A. robuster als diagnostisches Wissen  $P(\text{Karies}=\text{wahr} \mid \text{Schmerz}=\text{wahr})$ .

Wahrscheinlichkeit  $P(\text{Schmerz}=\text{wahr} \mid \text{Karies}=\text{wahr})$  ist unabhängig von den a priori Wahrscheinlichkeiten  $P(\text{Schmerz}=\text{wahr})$  und  $P(\text{Karies}=\text{wahr})$ .

Nähme  $P(\text{Karies}=\text{wahr})$  bei Karies-Epidemie zu, so bliebe Kausalität  $P(\text{Schmerz}=\text{wahr} \mid \text{Karies}=\text{wahr})$  unverändert, während sich  $P(\text{Schmerz}=\text{wahr})$  proportional mit  $P(\text{Schmerz}=\text{wahr})$  und  $P(\text{Karies}=\text{wahr})$  änderte.

Ein Arzt, der  $P(\text{Karies}=\text{wahr} \mid \text{Schmerz}=\text{wahr})$  geschätzt hätte, wüsste keine Regel zum Update.

Ein Arzt, der Bayes'sche Regel benutzt hätte, wüsste um proportionales Verhalten zwischen  $P(\text{Schmerz}=\text{wahr} \mid \text{Karies}=\text{wahr})$  und  $P(\text{Karies}=\text{wahr})$ .

# Normierung I

Wenn absolute Wahrscheinlichkeit von  $P(K | S)$  zu bestimmen und  $P(S)$  nicht bekannt, dann vollständige Fallanalyse durchführen (z.B. für  $K$  und  $\neg K$ ) und Zusammenhang  $P(K | S) + P(\neg K | S) = 1$  (hier boole'sche Variable) ausnutzen:

$$P(K | S) = \frac{P(S | K)P(K)}{P(S)}$$

$$P(\neg K | S) = \frac{P(S | \neg K)P(\neg K)}{P(S)}$$

$$P(K | S) + P(\neg K | S) = \frac{P(S | K)P(K)}{P(S)} + \frac{P(S | \neg K)P(\neg K)}{P(S)}$$

$$P(S) = P(S | K)P(K) + P(S | \neg K)P(\neg K)$$

## Normierung II

Durch Einsetzen in oberste Gleichung folgt


$$P(K | S) = \frac{P(S | K)P(K)}{P(S | K)P(K) + P(S | \neg K)P(\neg K)}$$

## Bayes Theorem — mit ganzen Zahlen

$$P(\text{Schmerz} \mid \text{Karies}) = 0.4$$

$$P(\text{Karies}) = 0.1$$

$$P(\text{Schmerz} \mid \neg\text{Karies}) = \frac{1}{90}$$



$$P(\text{Karies} \mid \text{Schmerz}) = \frac{40}{40 + 10} = 0.8$$

# Multiple Evidenzen I

Patient bejaht Frage nach Zahnschmerzen.  
Aus dieser ersten Evidenz schließt Zahnarzt:

$$P(\text{Karies} \mid \text{Schmerz}) = 0.8$$

Zahnarzt ertastet bei Untersuchung mit Haken Loch im Zahn.  
Aus dieser zweiten Evidenz schließt er:

$$P(\text{Karies} \mid \text{Loch}) = 0.95$$

$$P(\text{Karies} \mid \text{Schmerz} \wedge \text{Loch}) = \frac{P(\text{Schmerz} \wedge \text{Loch} \mid \text{Karies}) \cdot P(\text{Karies})}{P(\text{Schmerz} \wedge \text{Loch})}$$

## Multiple Evidenzen


**Problem:** Er braucht  $P(\text{Schmerz} \wedge \text{Loch} \mid \text{Karies})$ , d.h. Diagnosewissen für alle Kombinationen von Symptomen. Besser: Evidenzen mit Hilfe der Evidenzregel schrittweise aufnehmen

$$P(Y \mid X, E) = \frac{P(X \mid Y, E)P(Y \mid E)}{P(X \mid E)}$$

Abkürzungen:

$K$  — Karies,  $S$  — Schmerz

$L$  — Loch



**Ziel:** Berechne  $P(K \mid S, L)$  nur mit Hilfe von kausalen Aussagen der Form  $P(\cdot \mid K)$  und unter Ausnutzung von Unabhängigkeiten zwischen den Variablen.

# Multiple Evidenzen

A priori:  $P(K)$

Evidenz Schmerz:  $P(K | S) = P(K) \frac{P(S | K)}{P(S)}$

Evidenz Loch:  $P(K | S, L) = P(K | S) \frac{P(L | K, S)}{P(L | S)}$

S und L unabhängig von K  $\Leftrightarrow P(L | K, S) = P(L | K)$



# Multiple Evidenzen

Zusammengesetzte Gleichung von vorheriger Folie:

$$\begin{aligned} P(K | S, L) &= P(K) \frac{P(S | K) P(L | K)}{P(S) P(L | S)} \\ &= P(L) \frac{P(S | K) P(L | K)}{P(L, S)} \end{aligned}$$

$P(L, S)$  ist eine Normalisierungskonstante und kann berechnet werden, wenn  $P(L | \neg K)$  und  $P(S | \neg K)$  bekannt sind:

$$P(L, S) = \underbrace{P(L, S | K)}_{P(L|K)P(S|K)} P(K) + \underbrace{P(L, S | \neg K)}_{P(L|\neg K)P(S|\neg K)} P(\neg K)$$

# Multiple Evidenzen

$$P(K | L, S) = \frac{P(K) P(S | K) P(L | K)}{P(L | K) P(S | K) P(K) + P(L | \neg K) P(S | \neg K) P(\neg K)}$$

Man beachte, dass wir nur die bedingten Wahrscheinlichkeiten  $P(\cdot | K)$  zusammen mit den Apriori-(Marginal-)Wahrscheinlichkeiten  $P(K)$  and  $P(\neg K)$  verwendet werden.

## Multiple Evidenzen — Zusammenfassung

Mehrfache Evidenzen sind berechenbar durch Reduktion auf a priori Wahrscheinlichkeiten und (kausale) bedingte Wahrscheinlichkeiten für Evidenz. Zusätzlich werden gewisse bedingte Unabhängigkeiten vorausgesetzt.

Allgemeine Kombinationsregel:

$$P(Z | X, Y) = \alpha P(Z)P(X | Z)P(Y | Z)$$

für  $X$  und  $Y$  bedingt unabhängig bei gegebenem  $Z$  und mit Normierungskonstante  $\alpha$

# Zusammenfassung

**Unsicherheit** ist unvermeidbar in komplexen und dynamischen Welten, in denen Agenten zur Ignoranz gezwungen sind

**Wahrscheinlichkeiten** formulieren Unfähigkeit eines Agenten, definitive Entscheidung zu fällen und drücken Grad seiner Überzeugung aus

Falls ein Agent die wahrscheinlichkeitstheoretischen **Axiome** verletzt, so wird er unter Umständen irrationales Verhalten zeigen


**Bayessche Regel** ermöglicht es, unbekannte Wahrscheinlichkeiten aus bekannten Wahrscheinlichkeiten zu berechnen

**Multiple Evidenzen** können bei bedingter Unabhängigkeit effektiv in Berechnung einbezogen werden

# Probabilistic Dependency Networks

Probabilistische Abhängigkeitsnetzwerke sind gerichtete azyklische Graphen (DAGs), wobei die Knoten Variablen darstellen und die gerichteten Kanten direkte kausale Abhängigkeiten modellieren. Die Stärke der Abhängigkeiten wird durch bedingte Wkts definiert.

Gemäß Graph (Unabhängigkeitsstruktur):



$$\begin{aligned}
 P(X_1, \dots, X_6) &= P(X_6 \mid X_5) \cdot \\
 &P(X_5 \mid X_2, X_3) \cdot \\
 &P(X_4 \mid X_2) \cdot \\
 &P(X_3 \mid X_1) \cdot \\
 &P(X_2 \mid X_1) \cdot \\
 &P(X_1)
 \end{aligned}$$

# Formal Framework

Nomenklatur für die folgenden Folien:

$$X_1, \dots, X_n$$

Variablen

(Eigenschaften, Attribute, Zufallsvariablen, Annahmen)

$$\Omega_1, \dots, \Omega_n$$

dazugehörige endliche Domänen  
(auch benannt als  $\text{dom}(X_i)$ )

$$\Omega = \prod_{i=1}^n \Omega_i$$

Universe of Discourse (Tupel, die Objekte charakterisieren, die durch  $X_1, \dots, X_n$  beschrieben werden)

$$\Omega_i = \{x_i^{(1)}, \dots, x_i^{(n_i)}\} \quad n = 1, \dots, n, \quad n_i \in \mathbb{N}$$

# Formal Framework

Der Produktraum  $(\Omega, 2^\Omega, P)$  ist genau dann eindeutig, wenn  $P(\{(x_1, \dots, x_n)\})$  für alle  $x_i \in \{x_i^{(1)}, \dots, x_i^{(n_i)}\}$ ,  $i = 1, \dots, n$  spezifiziert ist.

Wenn die Verteilung  $P(X_1, \dots, X_n)$  in Tabellenform gegeben ist, dann sind  $\prod_{i=1}^n |\Omega_i|$  Einträge nötig.

Für Variablen mit  $|\Omega_i| \geq 2$  also mindestens  $2^n$  Einträge.

Die Benutzung von DAGs erlaubt die Repräsentation vorhandener (Un)Abhängigkeiten.

# Konstruktion eines DAG

**Eingabe:**  $P(X_1, \dots, X_n)$

**Ausgabe:** a DAG  $G$

- 1: Nutze als Knoten von  $G$  die Variablen  $\{X_1, \dots, X_n\}$ .
- 2: Wähle eine totale Ordnung auf der Menge der Variablen  
(e.g.  $X_1 \prec X_2 \prec \dots \prec X_n$ )
- 3: Finde für  $X_i$  die kleinste (eindeutig bestimmbare) Menge  
 $S_i \subseteq \{X_1, \dots, X_n\}$  so, dass  $P(X_i | S_i) = P(X_i | X_1 \dots, X_{i-1})$ .
- 4: Verbinde alle Knoten in  $S_i$  mit  $X_i$  und speichere  $P(X_i | S_i)$  als  
Quantisierung der Abhängigkeiten für den Knoten  $X_i$  (gegeben  
seine Eltern).
- 5: **return**  $G$



## Belief Netzwerk

Ein *Belief Netzwerk*  $(V, E, P)$  besteht aus einer Menge  $V = \{X_1, \dots, X_n\}$  von Zufallsvariablen und einer Menge  $E$  von gerichteten Kanten zwischen den Variablen.

Jede Variable hat eine endliche Menge von sich gegenseitig ausschließenden und in ihrer Gesamtheit vollständigen Zuständen.

Die Variablen und Kanten bilden zusammen einen DAG.

Jeder Variablen mit Elternknoten  $B_1, \dots, B_m$  wird eine Tabelle  $P(A | B_1, \dots, B_m)$  zugeordnet.

Man beachte, dass die Verbindungen zwischen den Knoten nicht notwendigerweise eine kausale Beziehung ausdrücken.

Für jedes Belief Netzwerk gilt die folgende Gleichung:

$$P(V) = \prod_{v \in V: P(c(v)) > 0} P(v | c(v))$$

wobei  $c(v)$  die Elternknoten von  $v$  sind.

## Beispiel

Seien  $a_1, a_2, a_3$  drei Blutgruppen und  $b_1, b_2, b_3$  drei Indikationen eines Blutgruppentests.

Variablen:  $A$  (Blutgruppe)       $B$  (Indikation)

Domänen:  $\Omega_A = \{a_1, a_2, a_3\}$        $\Omega_B = \{b_1, b_2, b_3\}$

Es wird vermutet, dass es eine kausale Beziehung zwischen den Variablen gibt.

$P(\{(a_i, b_j)\})$	$b_1$	$b_2$	$b_3$	$\Sigma$
$a_1$	0.64	0.08	0.08	0.8
$a_2$	0.01	0.08	0.01	0.1
$a_3$	0.01	0.01	0.08	0.1
$\Sigma$	0.66	0.17	0.17	1



$$P(A, B) = P(B | A) \cdot P(A)$$

We haben es mit einem Belief Netzwerk zu tun.

# Beispiel

## Expertenwissen

Metastasierender Krebs ist eine mögliche Ursache für einen Gehirntumor und eine Erklärung für erhöhte Kalziumwerte im Blut. Beide Phänomene zusammen können erklären, warum ein Patient ins Koma fällt. Schwere Kopfschmerzen sind mit Gehirntumoren assoziiert.

## Spezieller Fall

Der Patient hat schwere Kopfschmerzen.

## Frage


Wird der Patient ins Koma fallen?

# Beispiel

## Wahl eines Universe of Discourse

Variable	Domain	
A metastasierender Krebs	$\{a_1, a_2\}$	( $\cdot_1$ — vorh., $\cdot_2$ — n. vorh.)
B Erhöhtes Blutkalzium	$\{b_1, b_2\}$	
C Gehirntumor	$\{c_1, c_2\}$	$\Omega = \{a_1, a_2\} \times \dots \times \{e_1, e_2\}$
D Koma	$\{d_1, d_2\}$	$ \Omega  = 32$
E Kopfschmerzen	$\{e_1, e_2\}$	

## Analysis der Abhängigkeiten



# Beispiel

## Wahl der Wahrscheinlichkeitsparameter

$$P(a, b, c, d, e) \stackrel{\text{abbr.}}{=} P(A = a, B = b, C = c, D = d, E = e) \\ = P(e | c)P(d | b, c)P(c | a)P(b | a)P(a)$$

↑  
Abkürzende Notation

11 statt 31 werte müssen gespeichert werden.

Konsultiere Experten, Bücher, Fallstudien, Umfragen, etc.

**Berechne bedingte Wahrscheinlichkeiten** **Berechne**  
**Randwahrscheinlichkeiten**

# Kern der Sache

Wissensgewinnung (Woher kommen die Zahlen?)

→ Lernstrategien

Berechnungskomplexität


→ Unabhängigkeiten ausnutzen

## **Problem:**

Wann gilt die Unabhängigkeiten von  $X$  und  $Y$  gegeben  $Z$  in  $(V, E, P)$ ?

Wie kann  $P(X, Y | Z) = P(X | Z)P(Y | Z)$  bestimmt werden nur durch Nutzen der Graphstruktur?

## Beispiel



### Essensqualität

---


- A Qualität der Zutaten
- B Fähigkeiten des Kochs
- C Essensqualität

Wenn  $C$  nicht bekannt ist, dann sind  $A$  und  $B$  unabhängig.

Wenn  $C$  bekannt ist, dann werden  $A$  und  $B$  (bedingt) abhängig gegeben  $C$ .

$$A \not\perp B \mid C$$

## Beispiel (Fortsetzung)



### Essensqualität

---

- A Qualität der Zutaten
- B Fähigkeiten des Kochs
- C Essensqualität
- D Erfolg des Restaurants

Wenn über den Erfolg des Restaurant oder die Essenqualität nichts bekannt ist, dann sind die Fähigkeiten des Koch und die Qualität der Zutaten *unabhängig*.

Wenn wir jedoch beobachten, dass das Restaurant keinen Erfolg hat, können wir schließen, dass die Qualität des Essens schlecht sein könnte.

Wenn wir außerdem erfahren, dass die Zutaten von hoher Qualität sind, werden wir daraus schließen, dass der Koch schlecht sein muss. Die beiden Variablen werden also *abhängig*.

$$A \not\perp B \mid D$$




# Abhängigkeiten

## Divergierende Verbindung

### Diagnosis

---



A Körpertemperatur

B Husten

C Krankheit

Wenn  $C$  unbekannt ist, ist Wissen über  $A$  relevant für  $B$  und umgekehrt, *i.e.*  $A$  und  $B$  sind marginal abhängig.


Jedoch, wenn  $C$  bekannt wird, dann werden  $A$  und  $B$  bedingt unabhängig gegeben  $C$ .

$A$  beeinflusst  $B$  durch  $C$ . Wenn  $C$  bekannt ist, dann blockiert es den Informationsfluss von  $A$  nach  $B$  und macht  $A$  und  $B$  (bedingt) unabhängig.

# Abhängigkeiten

## Serielle Verbindung Unfälle

---



A Regen

B Unfallrisiko

C Straßenbedingungen

Analog zum Fall 2.

A beeinflusst C und C beeinflusst B. Also beeinflusst A auch B  
Wenn C bekannt ist, wird der Pfad zwischen A und B blockiert.

# Formale Darstellung

**Konvergierende Verbindung:** Marginale Unabhängigkeit  
Zerlegung gemäß Graphen:

$$P(A, B, C) = P(C \mid A, B) \cdot P(A) \cdot P(B)$$

Eingebettete Unabhängigkeit:

$$P(A, B, C) = \frac{P(A, B, C)}{P(A, B)} \cdot P(A) \cdot P(B) \quad \text{mit } P(A, B) \neq 0$$

$$P(A, B) = P(A) \cdot P(B)$$

$$\Rightarrow A \perp\!\!\!\perp B \mid \emptyset$$

# Formale Darstellung

**Divergierende Verbindung:** Bedingte Unabhängigkeit  
Zerlegung gemäß Graphen:

$$P(A, B, C) = P(A | C) \cdot P(B | C) \cdot P(C)$$

Eingebettete Unabhängigkeit:

$$P(A, B | C) = P(A | C) \cdot P(B | C)$$

$$\Rightarrow A \perp\!\!\!\perp B | C$$

Alternative Herleitung:

$$P(A, B, C) = P(A | C) \cdot P(B, C)$$

# Formale Darstellung

**Serielle Verbindung:** Bedingte Unabhängigkeit

Zerlegung gemäß Graphen:

$$P(A, B, C) = P(B | C) \cdot P(C | A) \cdot P(A)$$

Eingebettete Unabhängigkeit:

$$P(A, B, C) = P(B | C) \cdot P(C, A)$$

$$P(B | C, A) = P(B | C)$$

$$\Rightarrow A \perp\!\!\!\perp B | C$$

# Formale Darstellung

## Triviale Fälle:

Marginale Unabhängigkeit:  $(A)$   $(B)$   $P(A, B) = P(A) \cdot P(B)$

Marginale Abhängigkeit:  $(A) \longrightarrow (B)$   $P(A, B) = P(B | A) \cdot P(A)$

## Beispiel I (Wiederholung)

### Expertenwissen:

Metastasierender Krebs ist eine mögliche Ursache für einen Gehirntumor und eine Erklärung für erhöhte Kalziumwerte im Blut. Beide Phänomene zusammen können erklären, warum ein Patient ins Koma fällt. Schwere Kopfschmerzen sind mit Gehirntumoren assoziiert.

### Spezieller Fall:

Der Patient hat schwere Kopfschmerzen.

### Frage:

Wird der Patient ins Koma fallen?

# Wahl des Zustandsraums

$\Omega$  ist endliche Menge von erschöpfenden, sich gegenseitig ausschließenden Werten

## Beispiel:

Explizite Spezifikation der Zufallsvariablen und ihrer Werte


Zufallsvariable	Mögliche Werte
$A$ metastatischer Krebs	$a, \neg a$
$B$ erhöhter Calciumwert im Blut	$b, \neg b$
$C$ Hirntumor	$c, \neg c$
$D$ Koma	$d, \neg d$
$E$ schwere Kopfschmerzen	$e, \neg e$



# Wahrscheinlichkeit für geg. Abhängigkeiten I

$$\begin{aligned}
 &P(A = a, B = b, C = c, D = d, E = e) \\
 &= P(E = e \mid A = a, B = b, C = c, D = d) \\
 &\cdot P(D = d \mid A = a, B = b, C = c) \\
 &\cdot P(C = c \mid A = a, B = b) \\
 &\cdot P(B = b \mid A = a) \cdot P(A = a)
 \end{aligned}$$

$$\begin{aligned}
 &= P(E = e \mid C = c) \\
 &\cdot P(D = d \mid B = b, C = c) \\
 &\cdot P(C = c \mid A = a) \\
 &\cdot P(B = b \mid A = a) \\
 &\cdot P(A = a)
 \end{aligned}$$



Was muss vom Experten spezifiziert werden?

A priori Wahrscheinlichkeiten der Knoten ohne Eltern

Bedingte Wahrscheinlichkeiten eines Knotens bezogen auf Menge von elementaren Knoten

## Wahrscheinlichkeit für geg. Abhängigkeiten II

$P(e   c) = 0.8$ $P(e   \neg c) = 0.6$	Kopfschmerzen sind häufig, aber viel häufiger, falls Tumor vorhanden ist
$P(d   b, c) = 0.8$ $P(d   b, \neg c) = 0.8$ $P(d   \neg b, c) = 0.8$ $P(d   \neg b, \neg c) = 0.05$	Koma ist selten, aber häufig, falls einer der beiden Gründe vorliegt
$P(b   a) = 0.8$ $P(b   \neg a) = 0.2$	erhöhtes Kalzium ist ungewöhnlich, aber eine häufige Konsequenz von Metastasen
$P(c   a) = 0.2$ $P(c   \neg a) = 0.05$	Hirntumor ist selten, aber häufige Konsequenz von Metastasen
$P(a) = 0.2$	Vorkommen von metastatischem Krebs in relevanten Studien

11 Werte (anstatt 31) spezifiziert, andere berechenbar

Wahrscheinlichkeiten anhand von Fallstudien, Lehrbuchinformationen und massiven Tests

# Lösung des Problems

**Gegeben:**

Wahrscheinlichkeit  $P$

**Evidenz:**

Patient hat starke Kopfschmerzen

**Frage:**

Wie groß ist die Wahrscheinlichkeit, dass der Patient ins Koma fallen wird?

**Evidenz:**

$E = e$

**Bedingte Wahrscheinlichkeit:**

$P(\bullet \mid E = e)$

**Frage:**

$D = d?$

**Randwahrscheinlichkeit:**

$P(D = d \mid E = e)$

# Analyse dieses speziellen Falles

„Der Patient hat starke Kopfschmerzen“

**Idee:** Beschreibung der bedingten Wahrscheinlichkeiten  $P(\bullet \mid E = e)$

$$P(A = a', B = b', C = c', D = d', E = e' \mid E = e) \\ = \begin{cases} \frac{P(A=a', B=b', C=c', D=d', E=e')}{\sum_{a \in A} \sum_{b \in B} \sum_{c \in C} \sum_{d \in D} P(a, b, c, d, e)} & \text{falls } e' = e \\ 0 & \text{falls } e' = \neg e \end{cases}$$

# Auswertung der Daten des Patienten

## Wird der Patient ins Koma fallen?

**Idee:** berechne Randwahrscheinlichkeiten  $P(\{d\} | \{e\})$

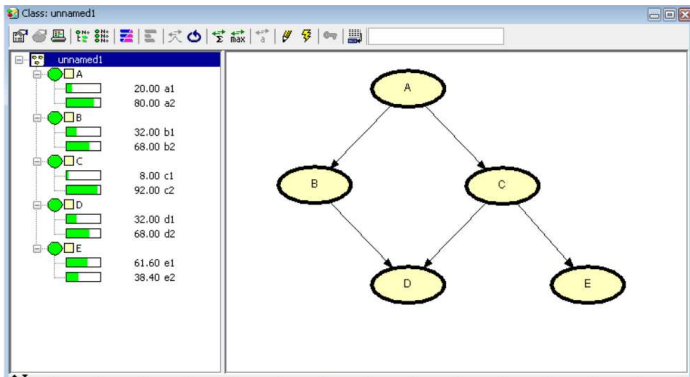
$$P(\{d\} | \{e\}) = \sum_{a' \in A} \sum_{b' \in B} \sum_{c' \in C} \sum_{e' \in E} P(a', b', c', d, e' | e)$$

### Probleme:

Komplexität der Berechnungen der bedingten  
Randwahrscheinlichkeiten (100 Zufallsvariablen mit 3 Merkmalen:  $3^{99}$   
Summationen von kleinen Werten)

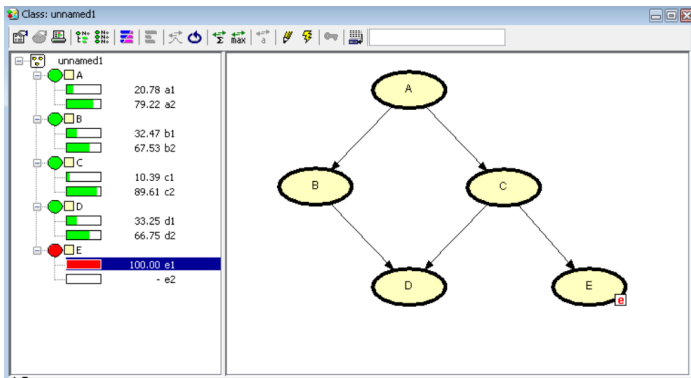
Können (oder müssen) wir erwarten, dass Nutzer mit  
Wahrscheinlichkeiten im Produktraum zurechtkommen?

# Randwahrscheinlichkeiten im HUGIN-Tool



# Bedingte Randwahrscheinlichkeiten mit Evidenz

$$E = e_1$$



# Bayes'sche Netze

Ein Bayes'sches Netz dient dazu, die gemeinsame Wahrscheinlichkeitsverteilung aller beteiligten Variablen unter Ausnutzung bekannter bedingter Unabhängigkeiten möglichst kompakt zu repräsentieren. Dabei wird die bedingte (Un)abhängigkeit von Untermengen der Variablen mit dem A-priori-Wissen kombiniert.




# Beispiel

gerichteter, azyklischer Graph

Knoten bedeuten Zufallsvariable


Kanten symbolisieren (prob.) Abhängigkeiten

beinhalten **qualitative** und **quantitative** Informationen



## Beispiel 2: Genotyp-Bestimmung des Jersey-Rinds

22 Variablen,  $6 \cdot 10^{13}$  Zustände, 324 Parameter



graphisches Modell

Knoten: Zustandsvariablen

Kanten: Bedingte Abhängigkeiten

Zerlegung:


$$P(X_1, \dots, X_{22}) = \prod_{i=1}^{22} P(X_i \mid \text{Eltern}(X_i))$$

Diagnose:  $P(\bullet \mid \text{Evidenz})$

# Bayes'sche Netze

Top-Down-Ansatz

Expertenwissen




Daten

Bottom-Up-Ansatz

Expertenwissen



Daten



## Beispiel 3: Planungssystem für Fahrzeugkonfigurationen

Etwa **200 item families** (Variablen, Merkmale)

Von **2 bis 50 items pro item family** (Werte pro Variable)

Mehr als  $2^{200}$  mögliche Fahrzeug-Spezifikationen

Wahl der gültigen Spezifikationen ist beschränkt durch **Regelsysteme** (**10.000 technische Regeln**, noch mehr marketing- und produktionsorientierte Regeln)

Beispiel:

**if** *engine* =  $e_1$  **then** *transmission* =  $t_3$

**if** *engine* =  $e_4$  **and** *auxiliary heater* =  $h_1$   
**then** *generator*  $\in \{g_3, g_4, g_5\}$



# Berechnung der bedingten Wkt. mit Hilfe von Propagationsalgorithmen

## Konsistente Zerlegung


- Verteilung nur über Cliques (bedingte Unabhängigkeiten)
- Gültigkeit aller Kombinationen registriert und verfügbar

## Fast Focussing Hyper Tree

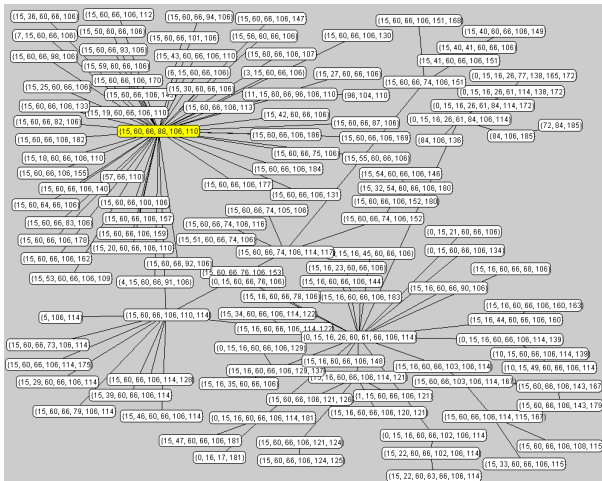
- Propagation durch zweifache Traversierung des Netzes

## Effiziente Planung

- Planung erfordert bedingte Unabhängigkeiten
- Berechnung der Häufigkeiten für beliebige Eigenschaftskombinationen



# Beispiel 4: Ungerichteter Graph der Abhängigkeiten der Merkmale



# Literatur

