

Bayesnetzmodelle (BNM) in der Kardiologie

Vorgehensmodell - Ergebnisse

Claus Möbus - Heiko Seebold

**Jan-Ole Janssen, Andreas Lüdtkke,
Iris Najman, Heinz-Jürgen Thole**

Besonderen Dank an:

**Herrn Reinke (Münster)
und Herrn Dr. Rulands (Aachen)**

Vorgehensmodell

Claus Möbus

**Jan-Ole Janssen, Andreas Lüdtkke,
Iris Najman, Heiko Seebold, Heinz-Jürgen Thole**

- **Nennung aller Variablen (Entitäten)**
 - Expositionen, Krankheiten, Syndrome, Symptome, Alternativerklärungen, Folgekrankheiten, ..., etc
 - Problem der vorzeitigen Festlegung auf konkrete Begriffe
 - *Problem der Generierung neuer Variablen bzw. Ausprägungen (zB. latenter Variablen, Faktoren, Folgen, etc)
- *Erhebung „kausal vor-“ bzw. „kausal nach-“Relation
 - reflexive
 - transitive
 - Antisymmetrische
- *Prüfung der Dreiecksgestalt der Relationentabelle
- *Berechnung des Hassediagramms der Relation

- *Hassediagramm ist minimaler DAG des BN
- *Prüfung der Berechtigung der Minimalität auf Grund der „Markov Blanket (MB)“-Eigenschaft
 - 1. Richtung: $X_i \Rightarrow MB \Rightarrow \text{Restnetz}$
 - 2. Richtung: $X_i \Leftarrow MB \Leftarrow \text{Restnetz}$
- bei Verletzung der MB-Eigenschaft Einzug neuer Kanten

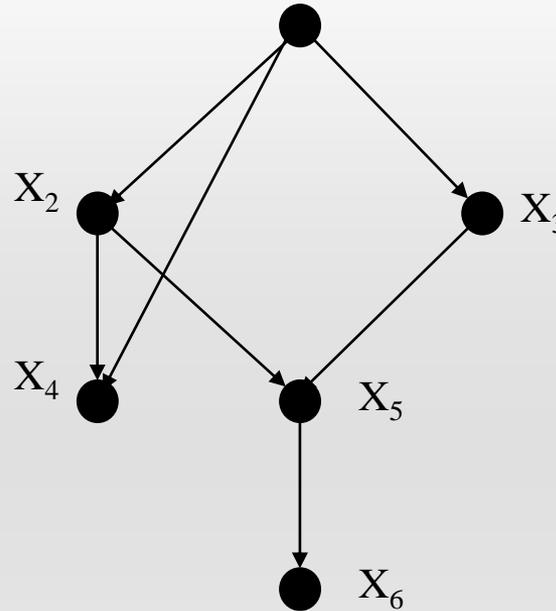
- **Erhebung probabilistischer Regeln**
 - in „Kausal-“richtung
 - in diagnostischer Richtung
 - in gemischter Richtung

- **Schätzung des Restmodells nach dem Prinzip der maximalen Entropie (ME)**

- set of *variables* $\mathbf{X} = \{X_1, \dots, X_n\}$
- set of *directed edges* between variables
- each variable has a finite set of *mutually exclusive states*
- variables together with the directed edges form a *DAG*
- to each variable Y with parents X_1, \dots, X_n , there is attached the *conditional potential table* $P(Y | X_1, \dots, X_n)$
- the joint probability distribution $P(\mathbf{X})$ is the *product of all potentials* specified in BN

$$P(\mathbf{X}) = \prod_i P(X_i | \text{parents}(X_i))$$

Gemeinsame Verteilung als Produkt bedingter Verteilungen

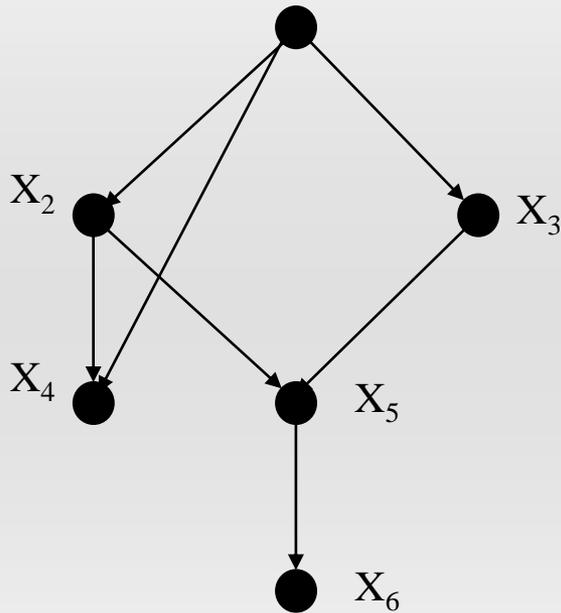


$$\begin{aligned}
 &P(X_6, X_5, X_4, X_3, X_2, X_1) \\
 &= P(X_6 | X_5) P(X_5 | X_3, X_2) P(X_4 | X_2, X_1) P(X_3 | X_1) P(X_2 | X_1) P(X_1) \\
 &= \prod_i P(X_i | \Pi_{X_i})
 \end{aligned}$$

wobei : Π_{X_i} = direkte Vorgänger von X_i

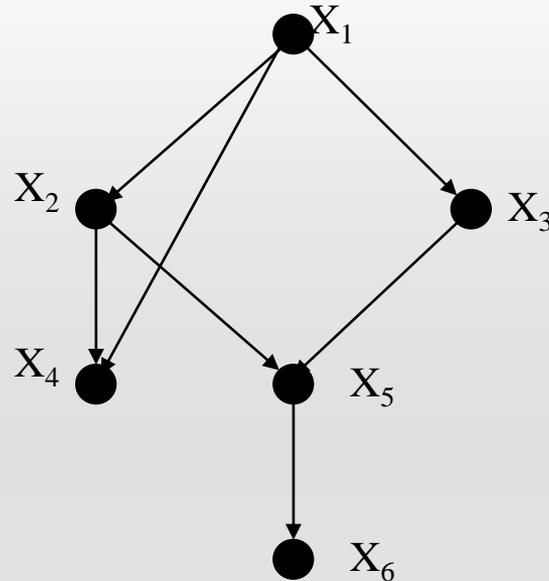
- set of *parents* of $Y = \{X_1, \dots, X_m\}$
- set of *children* of $Y = \{Z_1, \dots, Z_n\}$
- set of *lovers* of $Y = \{U_1, \dots, U_p\}$, sharing a child with Y
- If all variables in the MB for Y are instantiated, the Y is d-separated from the rest of the network

$$\{X \perp N - MB \mid MB\}$$



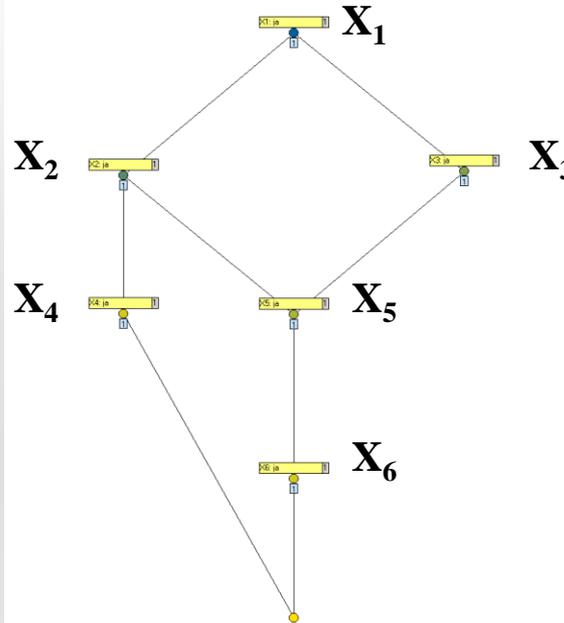
MB(X_i)	parents	children	lover
X1		X2,X3,X4	X2
X2	X1	X4,X5	X1,X3
X3	X1	X5	X2
X4	X1,X2		
X5	X2,X3	X6	
X6	X5		

„wahres“ BN und „Kausal-vor-“Relation



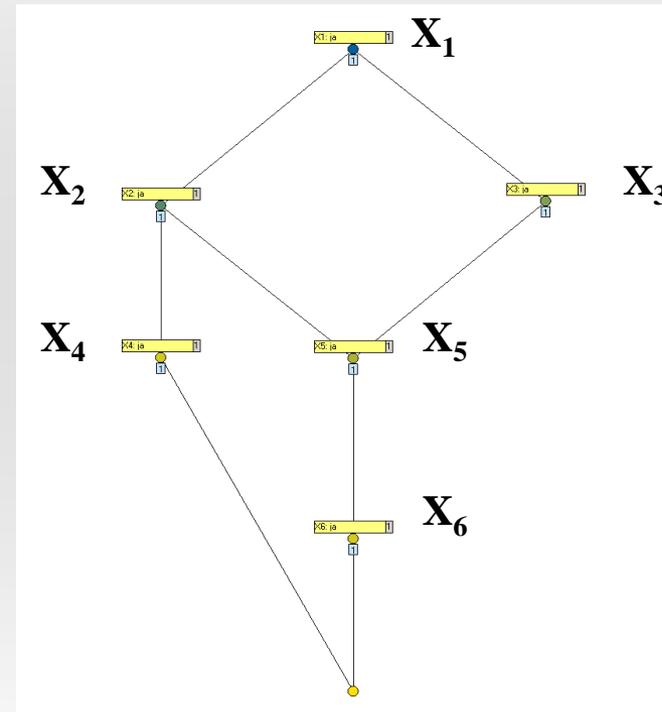
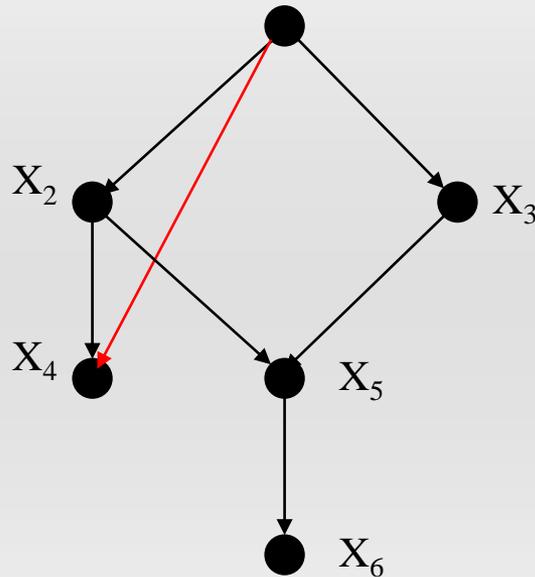
Objekt 1 von 6 Eigenschaft 1 von 6	X1	X2	X3	X4	X5	X6
	kausal_vor	kausal_vor	kausal_vor	kausal_vor	kausal_vor	kausal_vor
X1	ja					
X2	ja	ja				
X3	ja	nein	ja			
X4	ja	ja	nein	ja		
X5	ja	ja	ja	nein	ja	
X6	ja	ja	ja	nein	ja	ja

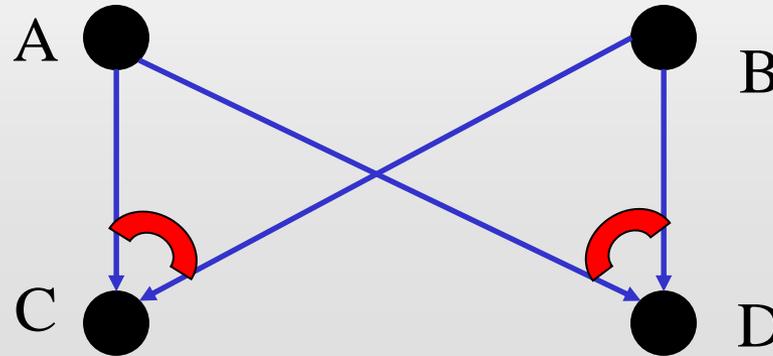
aus „Daten“ konstruiertes Hassediagramm



Objekt 1 von 6 Eigenschaft 1 von 6	X1	X2	X3	X4	X5	X6
	kausal_vor	kausal_vor	kausal_vor	kausal_vor	kausal_vor	kausal_vor
X1	ja					
X2	ja	ja				
X3	ja	nein	ja			
X4	ja	ja	nein	ja		
X5	ja	ja	ja	nein	ja	
X6	ja	ja	ja	nein	ja	ja

„wahres“ BN und Begriffsverband der Variablen

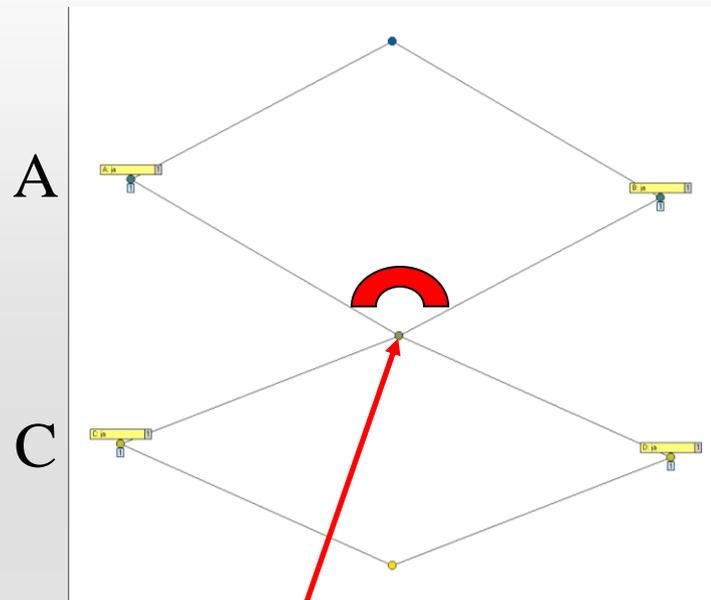




BN mit $2+2+8+8=20$
 Params;
 4 explizite Knoten

Objekt 4 von 4 Eigenschaft 2 von	A	B	C	D
kausal vor				
A	ja			
B		ja		
C	ja	ja	ja	
D	ja	ja		ja

minimales BN durch Hassedigramm 4-Knoten-Problem



B BN mit $2+2+8+2+2=16$ Params;
 4 explizite Knoten;
D 1 neuer latenter Knoten

Objekt 4 von 4	A	B	C	D
igenschaft 2 von	kausal vor	kausal vor	kausal vor	kausal vor
A	ja			
B		ja		
C	ja	ja	ja	
D	ja	ja		ja

- **Erhebung probabilistischer Regeln**
 - in „Kausal-“richtung
 - in diagnostischer Richtung
 - in gemischter Richtung

- **Schätzung des Restmodells nach dem Prinzip der maximalen Entropie (ME)**

- Menge R probabilistischer Regeln

$$R = \{A_1 \square > B_1 [x_1], \dots, A_n \square > B_n [x_n]\}$$

- erfüllende Verteilung P

$$P \models A \square > B [x] \quad \text{gdw.} \quad P(B | A) = x \quad \text{mit} \quad P(A) > 0$$

- bedingte Schätzung P^* der Verteilung P unter ME

$$\max_{P \models R} H(P) = - \sum_{\omega} P(\omega) \cdot \log_2 P(\omega)$$

- Eindeutig lösbares Optimierungsproblem (Csiszár, 1975)

$$P^* = ME(R)$$

Ergebnisse

Heiko Seebold

**Jan-Ole Janssen, Andreas Lüdtkke,
Claus Möbus, Iris Najman, Heinz-Jürgen Thole**

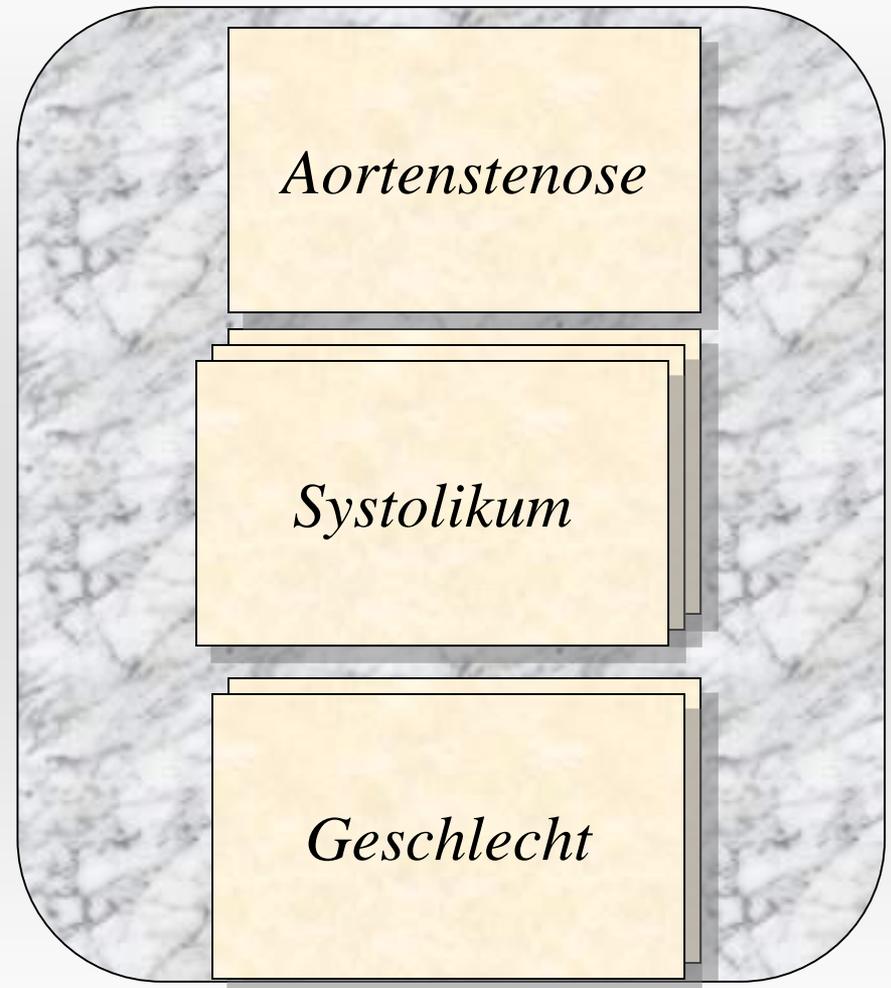
Besonderen Dank an:

**Herrn Reinke (Münster)
und Herrn Dr. Rulands (Aachen)**

- **Mediziner :**
 - Herr Reinke (Münster),
 - Herr Dr. Rulands (Aachen)
- **Modellierte Krankheit :**
Aortenstenose
- **Modellierung wurde**
getrennt durchgeführt



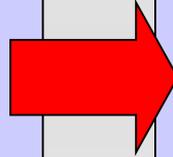
- **Variablen können Symptome, Expositionen, Krankheiten, etc. sein.**
- **Pro Netz ca. 30 verschiedene Variablen erhoben**
- **Iteratives Betrachten einzelner Variablen**
- **Ordnung der restlichen Variablen mittels der Relation „*kausal vor*“**



1. Schritt

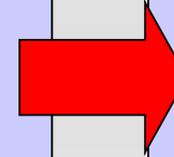
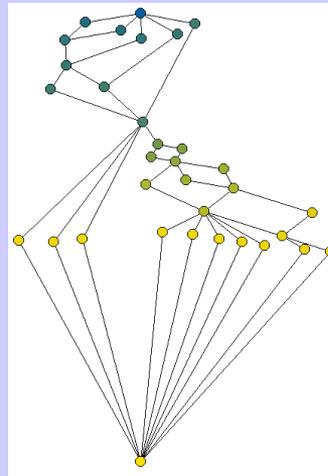
- Eingabe der Relationen in eine Tabelle
- Prüfung der Dreiecksgestalt

The screenshot shows a spreadsheet with a grid of cells. The columns are labeled with variables like 'Blutdruck', 'Cholesterin', etc. The rows contain data points or relationships between these variables, with some cells highlighted in yellow.



2. Schritt

- Erzeugung des minimalen Graphen (Hasse-Diagramm)
- ➔ Revision durch Unabhängigkeitsdialog notwendig

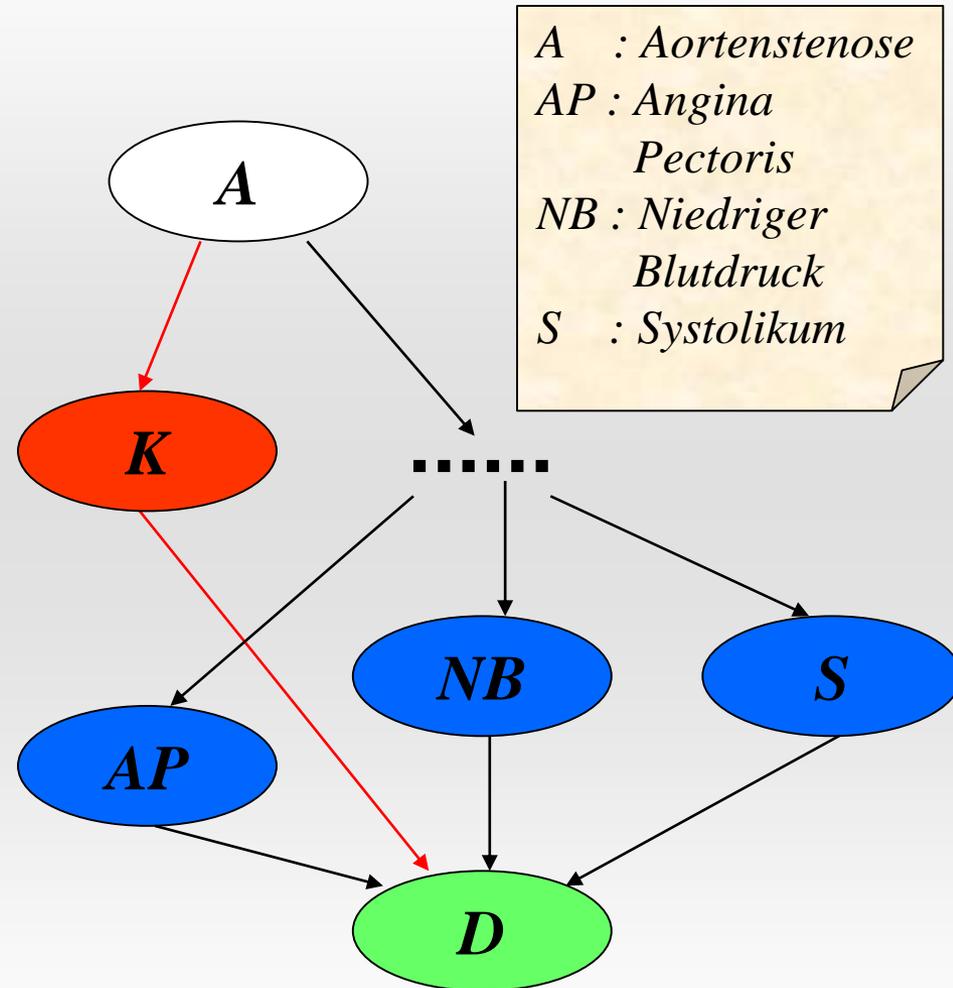


3. Schritt

- Übertragung in ein Modellierungswerkzeug für Bayes-Netze nach praktikablen Gesichtspunkten
- Entwickelt von unserer Abteilung
- Unterstützt den Entropieansatz zur Berechnung fehlender Wahrscheinlichkeiten

Medikus

- „Stellen Sie sich vor, dass bekannt ist, ob **Angina Pectoris**, **Niedriger Blutdruck** und **Systolikum** vorliegen. Gibt es andere Variablen im Netz, die zusätzliche Informationen zur Wahrscheinlichkeit von **Dyspnoe** liefern?“
- Antwort „Ja“ führt zur Modellrevision
- Neuer Knoten **Kontraktilität (K)**



- **Problematisch, da oft nicht alle Wahrscheinlichkeiten bekannt**
- **Kausal Wahrscheinlichkeiten schwieriger anzugeben als diagnostische**
- **Leichter Umgangssprachliche Aussagen zu treffen, als konkrete Zahlen zu nennen**
- **Problem: Durchschnittliche Werte**
- **Berechnung fehlender Wahrscheinlichkeiten nach dem Prinzip der maximalen Entropie**

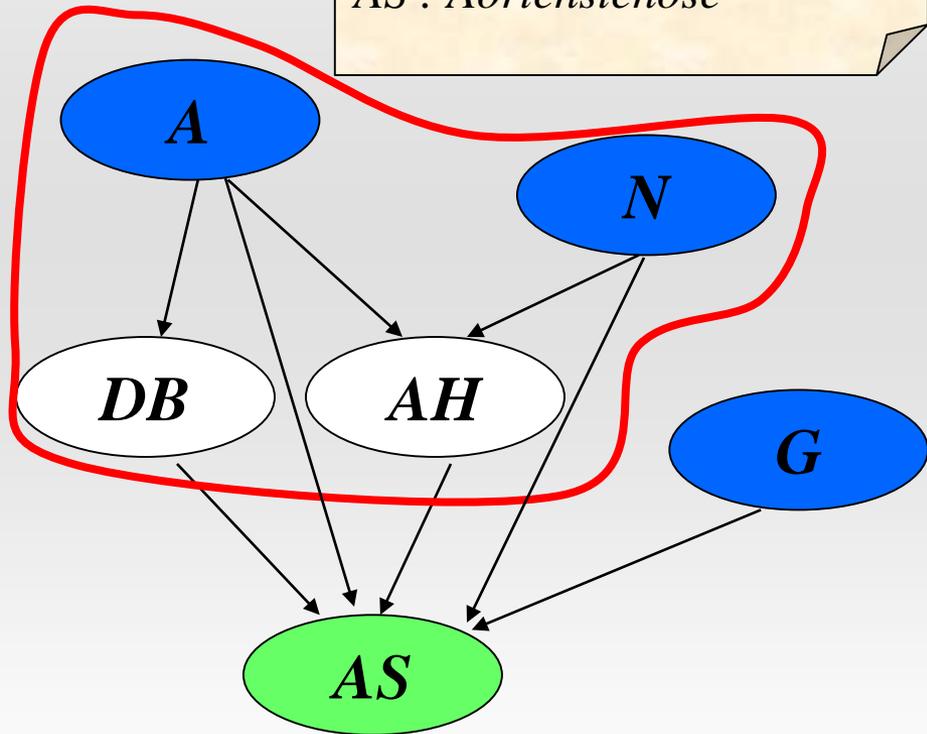


Linguistischer Term	Gültigkeitsbereich
fast sicher	0.99 - 0.91
...	...
Fünfzig zu fünfzig	0.54 – 0.46
...	...
unwahrscheinlich	0.27 – 0.19
...	...

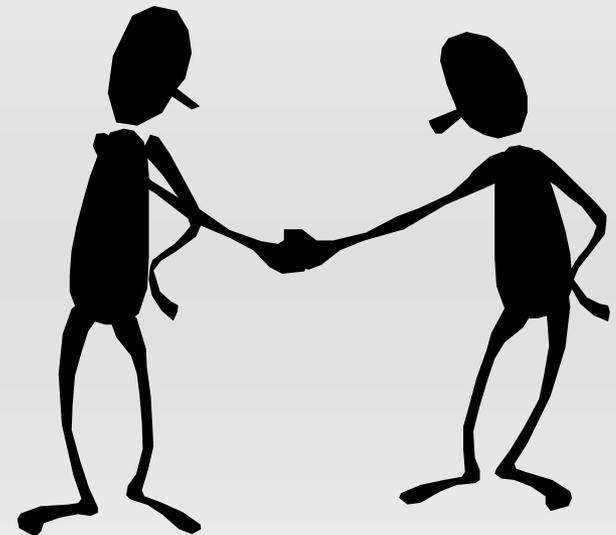
Lichtenstein, Newman - 1967

- Für $P(A)$, $P(N)$ und $P(G)$ statistische Daten notwendig
- Kontext beachten
- $P(AS | G, A, N, DB, AH)$ für alle Kombinationen schwierig anzugeben
- Leichter: Einteilung der Auslöser in Risikofaktoren (RF)
- $P(AS = \text{leicht} | RF \text{ vorhanden} \geq 3, G = \text{männlich}) = 0.28$

A : Alter
N : Nikotin
AH : Arterieller Hypertonus
DB : Diabetis
G : Geschlecht
AS : Aortenstenose



- **2 kausale Netze erstellt**
- **Ca. 30 Variablen pro Netz**
- **Ca. 150 Wahrscheinlichkeiten erhoben**



Vielen Dank für Ihre Aufmerksamkeit ...