


## Kunstmatige Intelligentie (AI)

Hoofdstuk 12 en 13 van Russell/Norvig = [RN]  
Bayesiaanse netwerken

voorjaar 2021  
College 13, 10 mei 2021



[www.liacs.leidenuniv.nl/~kosterswa/AI/bayesnet.pdf](http://www.liacs.leidenuniv.nl/~kosterswa/AI/bayesnet.pdf)

We gaan nu eenvoudige “systemen” bekijken waarin kansen een rol spelen, in het bijzonder **Bayesiaanse netwerken** waarin vele (on)afhankelijkheden gelden.

Basisbouwsteen is de uit de kansrekening bekende **regel van Bayes**.



We gebruiken dus veelvuldig de **regel van Bayes** (te bewijzen via  $P(A, B) = P(A \text{ en } B) = P(A \wedge B) = P(A)P(B|A)$ ):

$$P(B|A) \stackrel{\text{def}}{=} \text{kans op } B \text{ gegeven } A = \frac{P(A|B)P(B)}{P(A)}$$

Een eenvoudige toepassing is als volgt. Stel, met  $S \stackrel{\text{def}}{=}$  stijve nek en  $M \stackrel{\text{def}}{=}$  meningitis:

$$P(S|M) = 0.5 \quad P(M) = 1/50000 \quad P(S) = 1/20$$

(die laatste twee zijn de “prior probability”). Dan:

$$P(M|S) = \frac{P(S|M)P(M)}{P(S)} = \frac{0.5 \times 1/50000}{1/20} = 0.0002 .$$

Diagnostische kennis  $P(M|S)$  gedraagt zich minder stabiel dan causale kennis  $P(S|M)$  (denk maar aan  $M$ -epidemie!).

NB: als  $A$  en  $B$  **onafhankelijk** zijn:  $P(A, B) = P(A)P(B)$ .

Met  $W \stackrel{\text{def}}{=} \text{whiplash}$  kunnen we de relatieve “likelihood” van meningitis en whiplash, gegeven een stijve nek, berekenen:

$$\frac{P(M|S)}{P(W|S)} = \frac{P(S|M)P(M)}{P(S|W)P(W)} = \frac{0.5 \times 1/50000}{0.8 \times 1/1000} = \frac{1}{80},$$

wetende dat  $P(S|W) = 0.8$  en  $P(W) = 1/1000$ .

En soms hoef je niet alles te weten:

$$P(M|S) = \alpha P(S|M)P(M) \quad P(\neg M|S) = \alpha P(S|\neg M)P(\neg M),$$

terwijl  $P(M|S) + P(\neg M|S) = 1$ : **normalisatie**, met uiteraard

$$\alpha = 1/P(S) = 1/\{P(S|M)P(M) + P(S|\neg M)P(\neg M)\}.$$

Bij de tandarts geldt, met  $G \stackrel{\text{def}}{=} \text{gaatje}$ ;  $K \stackrel{\text{def}}{=} \text{kiespijn}$ :

$$P(G|K) = P(G) \frac{P(K|G)}{P(K)} .$$

En met  $H \stackrel{\text{def}}{=} \text{“haakje hangt”}$  erbij:


$$P(G|K \wedge H) = P(G|K) \frac{P(H|K \wedge G)}{P(H|K)} = P(G) \frac{P(K|G)}{P(K)} \frac{P(H|K \wedge G)}{P(H|K)} .$$

Een redelijke *aanname* (**voorwaardelijke onafhankelijkheid**) zoals  $P(H|K \wedge G) = P(H|G)$  (of equivalent:  $P(K|G \wedge H) = P(K|G)$ ) maakt het Bayesiaans updaten wat “eenvoudiger” voor de tandarts:

$$P(G|K \wedge H) = P(G) \frac{P(K|G)}{P(K)} \frac{P(H|G)}{P(H|K)} ,$$

waarbij je de noemers nog kunt “weg-normaliseren” .

Ons standaardvoorbeeld van een **Bayesiaans netwerk** (ofte-  
wel probabilistisch netwerk = belief netwerk = knowledge  
map), afkomstig van Judea Pearl, is:



Inbreker kan Alarm af laten gaan  
Aardbeving kan Alarm af laten gaan  
Alarm kan Mary en/of John  
aanzetten tot bellen

Een Bayesiaans netwerk is een graaf **zonder cykels** met:

1. random variabelen als knopen,
2. pijlen tussen knopen (die directe invloed aangeven),
3. **conditional probability tables (CPT's)** die het gezamenlijk effect van al hun ouders aangeven op de kinderen.

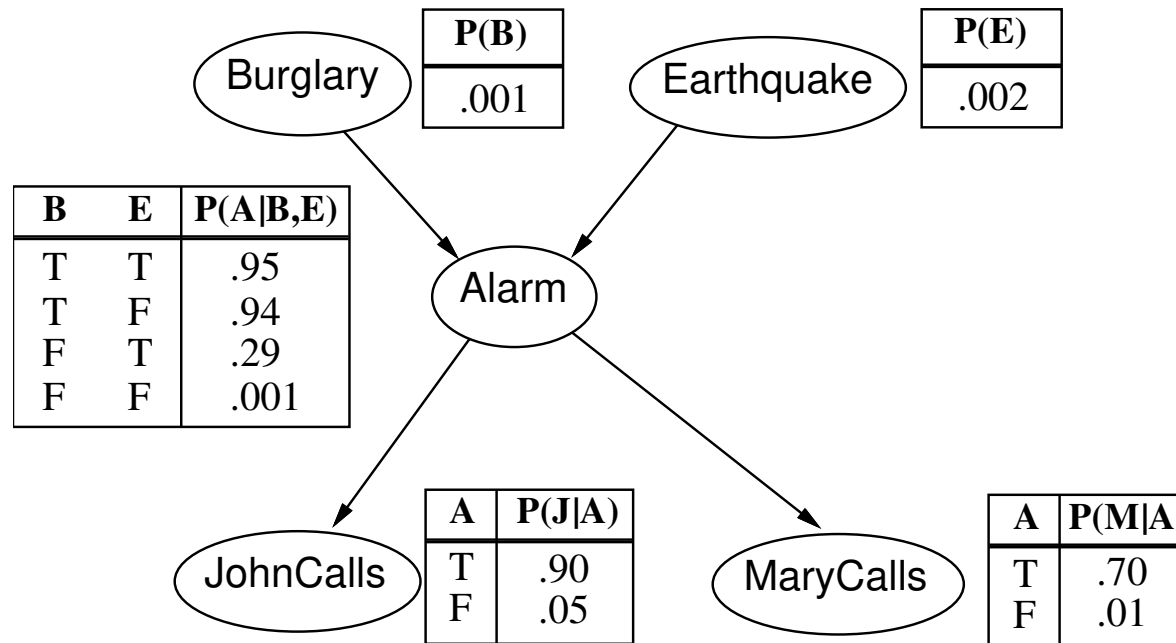
In ons voorbeeld is er *geen directe invloed* van Earthquake op MaryCalls — en dus geen pijl (andersom ook niet).

Die invloed is er op zich wel, maar loopt geheel via Alarm:

$P(M|A, E)(= P(M|A \wedge E)) = P(M|A)$ : MaryCalls is **voorwaardelijk onafhankelijk** van Earthquake, gegeven Alarm.

Als Mary ook rechtstreeks zou reageren op Earthquake, moest er een pijl bij.

Opnieuw ons Bayesiaanse netwerk, nu met CPT's:



Let er op dat de pijlen als het ware van oorzaak naar gevolg lopen. We hebben 10 getallen nodig om dit systeem te beschrijven, in plaats van  $32 - 1 = 31$ .




In een Bayesiaans netwerk moet altijd gelden dat

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{Parents}(X_i)) ,$$

als we definiëren  $P(x_1, \dots, x_n) = P(X_1 = x_1, \dots, X_n = x_n)$   
 en  $\text{Parents}(X_i) =$  de verzameling van knopen die een pijl  
 naar  $X_i$  hebben.

Een voorbeeld (met  $j = (\text{JohnCalls} = \text{true}), \dots$ ):

$$\begin{aligned} P(j \wedge m \wedge a \wedge \neg b \wedge \neg e) &= P(j|a)P(m|a)P(a|\neg b \wedge \neg e)P(\neg b)P(\neg e) \\ &= 0.90 \times 0.70 \times 0.001 \times 0.999 \times 0.998 \\ &= 0.00063 . \end{aligned}$$




Hoe construeer je zo'n Bayesiaans netwerk?

1. Kies relevante variabelen die het domein beschrijven.
2. Orden ze “verstandig”:  $X_1, \dots, X_n$ .
3. Kies zo lang het kan de volgende overgebleven variabele  $X_i$ , maak daarvoor een knoop in het netwerk, en maak  $\text{Parents}(X_i) \subseteq \{X_{i-1}, \dots, X_1\}$  zo klein mogelijk met

$$P(X_i | X_{i-1}, \dots, X_1) = P(X_i | \text{Parents}(X_i)) ,$$

de **voorwaardelijke onafhankelijkheids eigenschap**; definieer tot slot de CPT (conditional probability table) voor  $X_i$ .

De volgorde maakt veel uit voor het uiteindelijke netwerk:




Volgorde van toevoegen links:  $M, J, A, B, E$ , rechts:  $M, J, E, B, A$  (met 31 “parameters”!). Begin dus liever met oorzaken ...

Algemeen: neem aan dat elke Booleaanse variabele rechtstreeks wordt beïnvloed door maximaal  $k$  andere, dan heb je — als er  $n$  knopen zijn — aan  $n \cdot 2^k$  getallen voldoende voor de CPT's.

De volledige “joint” gebruikt er  $2^n - 1$  (−1 omdat de getallen tot 1 sommeren).

Met  $n = 20$  en  $k = 5$  is dat 640 respectievelijk 1 miljoen.

Als je *meer* weet kun je ze soms efficiënter opslaan, zeker in het geval van deterministische knopen.



In “gewone” logica geldt:

$$\text{Koorts} \Leftrightarrow \text{Verkouden} \vee \text{Griep} \vee \text{Malaria}$$

Neem nu aan dat:

- (1) elke oorzaak heeft een onafhankelijke kans het effect Koorts te veroorzaken;
- (2) alle oorzaken zijn gegeven (voeg eventueel een “leak node” toe);
- (3) dat wat (bijvoorbeeld) Verkouden ervan weerhoudt Koorts te veroorzaken is onafhankelijk van dat wat Griep verbiedt Koorts te veroorzaken.

Samen heet dit wel een **Noisy-OR** relatie.

We krijgen dan een volgende tabel:

| Verkouden | Griep | Malaria | P(Koorts) | P( $\neg$ Koorts)                     |
|-----------|-------|---------|-----------|---------------------------------------|
| F         | F     | F       | 0.0 (2)   | 1.0                                   |
| F         | F     | T       | 0.9 (1)   | 0.1                                   |
| F         | T     | F       | 0.8 (1)   | 0.2                                   |
| F         | T     | T       | 0.98      | $0.02 = 0.2 \cdot 0.1$ (3)            |
| T         | F     | F       | 0.4 (1)   | 0.6                                   |
| T         | F     | T       | 0.94      | $0.06 = 0.6 \cdot 0.1$ (3)            |
| T         | T     | F       | 0.88      | $0.12 = 0.6 \cdot 0.2$ (3)            |
| T         | T     | T       | 0.988     | $0.012 = 0.6 \cdot 0.2 \cdot 0.1$ (3) |

Alleen de drie **rode** getallen hoef je te onthouden, de rest volgt hier uit.

Bij de **Naive Bayes classifier** (liever: **model**; zie Data mining) neem je iets soortgelijks aan.


In ons Tennis-voorbeeld zou je kunnen veronderstellen:

$$\begin{aligned} P(\text{Weer} = \text{zonnig} \wedge \text{Temp} = \text{koud} \mid \text{Tennis} = \text{Ja}) &= \\ &P(\text{Weer} = \text{zonnig} \mid \text{Tennis} = \text{Ja}) \\ &\times P(\text{Temp} = \text{koud} \mid \text{Tennis} = \text{Ja}) \end{aligned}$$

Hiermee kun je “eenvoudig” classificeren. Als namelijk het weer zonnig, temperatuur koud, vochtigheid hoog en wind sterk is, kun je een hogere kans voor het effect Tennis = Nee (benaderend) uitrekenen dan voor Tennis = Ja.

Het berekenen van voorwaardelijke kansen in een Bayesiaans netwerk (inferentie) is in het algemeen niet eenvoudig. We willen “ $P(\text{Query} \mid \text{Evidence})$ ” weten: we hebben informatie over zekere “Evidence” variabelen, en zijn geïnteresseerd in zekere “Query” variabelen.

In het algemeen heb je te maken met de zogeheten **Markov blanket**: ouders, kinderen en co-ouders van kinderen.





Er worden vier soorten inferentie onderscheiden:

**diagnostisch** van effect naar oorzaak:  $P(b|j) = 0.016$

**causaal** van oorzaak naar effect (met de pijlen mee):

$$P(j|b) = 0.86$$


(via  $P(j|b) = P(j|a)P(a|b) + P(j|\neg a)P(\neg a|b)$  en

$$P(a|b) = P(a|b, e)P(e) + P(a|b, \neg e)P(\neg e))$$

**intercausaal** (“explaining away”) tussen oorzaken van gemeenschappelijk effect:  $P(b|a \wedge e) = 0.003$

**mixed** overig:  $P(a|j \wedge \neg e) = 0.03$

Waarbij weer  $j = (\text{JohnCalls} = \text{true}), \dots$



We zullen als voorbeeld van een diagnostische afleiding  $P(b|j)$  berekenen:

Stap 1:  $P(b|j) = P(b|a)P(a|j) + P(b|\neg a)P(\neg a|j)$

Stap 2:  $P(b|a) = P(a|b)P(b)/P(a)$  (Bayes)

Stap 3:  $P(a) = P(a|b, e)P(b)P(e) + P(a|\neg b, e)P(\neg b)P(e) + P(a|b, \neg e)P(b)P(\neg e) + P(a|\neg b, \neg e)P(\neg b)P(\neg e) = 0.0025$

Stap 4:  $P(a|b) = P(a|b, e)P(e) + P(a|b, \neg e)P(\neg e) = 0.94$


Stap 5:  $P(b|a) = 0.376$  en  $P(b|\neg a) = 0.00006$

Stap 6:  $P(j) = P(j|a)P(a) + P(j|\neg a)P(\neg a) = 0.052$

Stap 7:  $P(a|j) = P(j|a)P(a)/P(j) = 0.043$  en

$$P(\neg a|j) = 0.957$$

Stap 8:  $P(b|j) = 0.016$



We kunnen  $P(b|j)$  ook op een andere manier berekenen.

Omdat  $P(b|j) = P(b, j)/P(j)$  en  $P(\neg b|j) = P(\neg b, j)/P(j)$  is het voldoende  $P(b, j)$  en  $P(\neg b, j)$  te bepalen, en daarna te “normaliseren” — of  $P(j)$  te gebruiken.


$$P(b, j) = P(b) \left\{ P(e) \{ P(a|b, e)P(j|a) + P(\neg a|b, e)P(j|\neg a) \} \right. \\ \left. + P(\neg e) \{ P(a|b, \neg e)P(j|a) + P(\neg a|b, \neg e)P(j|\neg a) \} \right\} ,$$

wat na invullen gelijk blijkt aan 0.00085.

Analoog:  $P(\neg b, j) = \dots = 0.05129$ .

En dus  $P(j) = P(b, j) + P(\neg b, j) = 0.05214$ .

Tot slot:  $P(b|j) = 0.00085/0.05214 = 0.016$ .



Het is blijkbaar lastig! Enkele vuistregels:

- werk toe naar “causaal”
- gebruik de uitgebreide regel van Bayes, met overal  $|C$ :


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

Voorbeeld:

$$P(\text{lek} | \text{vies}, \text{tuin}) = \frac{P(\text{vies} | \text{lek}, \text{tuin})P(\text{lek} | \text{tuin})}{P(\text{vies} | \text{tuin})}$$

waarbij  $P(\text{lek} | \text{tuin}) = P(\text{lek})$  en

$$P(\text{vies} | \text{tuin}) = P(\text{vies} | \text{tuin}, \text{lek})P(\text{lek}) + P(\text{vies} | \text{tuin}, \neg\text{lek})P(\neg\text{lek})$$



In netwerken waarbij knopen met meerdere paden verbonden zijn, is exacte inferentie nog moeilijker. In het algemeen is inferentie in een Bayesiaans netwerk zelfs NP-volledig!


Je kunt verschillende methoden gebruiken:

**clustering = join tree** methoden: bouw het netwerk om naar één zonder verschillende paden: een “polytree”

**conditioning** methoden: maak kopieën van het netwerk door vaste waardes te kiezen voor lastige variabelen


**sampling** methoden: doe simulaties om een benaderend antwoord te krijgen — veel statistiek dus

We bekijken het volgende “multiply connected” netwerk:



Hier zijn 9 getallen nodig. De onderste knoop voldoet overigens aan de “Noisy-OR” relatie.

Bij de **join tree** methode voegen we nu de knopen Sprinkler en Rain samen tot één mega-knoop met een grote CPT, en krijgen dan een “polytree” :




Hier zijn **11** getallen nodig (de 12e en 13e volgen hieruit). In het algemeen explodeert dit aantal.

# AI—Bayesiaanse netwerken **Conditioning en sampling**

Je kunt ook (**conditioning**) twee netwerken maken, één voor Cloudy = true en één voor Cloudy = false: “polytrees” gelabeld met kans 0.5. Cloudy vormt de “cutset”.

Of gaan “**samplen**”:





In de laatste week, op maandag 17 mei 2021, kijken we naar het geheel en het [oude tentamen van 2 juni 2014](#).

Denk aan de opgaven:

[www.liacs.leidenuniv.nl/~kosterswa/AI/opgaven2.pdf](http://www.liacs.leidenuniv.nl/~kosterswa/AI/opgaven2.pdf)

Doe in het bijzonder: 30, 31, 33, 13 en 14. Zie ook de video's met uitwerkingen op

[www.liacs.leidenuniv.nl/~kosterswa/AI/](http://www.liacs.leidenuniv.nl/~kosterswa/AI/)

Werk aan de vierde opgave: [Neurale netwerken](#); deadline: **dinsdag 18 mei 2021**.