


Kunstmatige Intelligentie (AI)

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

voorjaar 2023
College 13, 8 mei 2024



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: $P(A, B) = P(A)P(B)$.

lekke band = true
 \Downarrow

Stel dat vandaag geldt $P(\text{lek}) = 0.1$
 (en dus $P(\neg\text{lek}) = 0.9$), $P(\text{tuin}) = 0.4$,
 $P(\text{vies} \mid \text{lek}, \text{tuin}) = 0.8$, $P(\text{vies} \mid \neg\text{lek}, \text{tuin}) = 0.7$,
 $P(\text{vies} \mid \text{lek}, \neg\text{tuin}) = 0.4$ en $P(\text{vies} \mid \neg\text{lek}, \neg\text{tuin}) = 0.0$.

Bereken $P(\text{vies} \mid \text{tuin}) = P(\text{vies} \mid \text{tuin}, \text{lek})P(\text{lek}) + P(\text{vies} \mid \text{tuin}, \neg\text{lek})P(\neg\text{lek}) =$
 $= 0.8 \cdot 0.1 + 0.7 \cdot 0.9 = 0.71$, en dan met Bayes:

$$P(\text{tuin} \mid \text{vies}) = P(\text{vies} \mid \text{tuin})P(\text{tuin}) / P(\text{vies}) \approx 0.71 \cdot 0.4 / 0.3 \approx 0.9.$$

Gebruik: $P(\text{vies}) = P(\text{vies} \mid \text{lek}, \text{tuin})P(\text{lek})P(\text{tuin}) + P(\text{vies} \mid \neg\text{lek}, \text{tuin})P(\neg\text{lek})P(\text{tuin})$
 $+ P(\text{vies} \mid \text{lek}, \neg\text{tuin})P(\text{lek})P(\neg\text{tuin}) + P(\text{vies} \mid \neg\text{lek}, \neg\text{tuin})P(\neg\text{lek})P(\neg\text{tuin}) \approx 0.3$.

Ook interessant: $P(\text{lek} \mid \text{vies}, \text{tuin})$. En een pijl van “lekke band” naar “in tuin werken”? En is het een “Noisy-OR”?

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 $H \stackrel{\text{def}}{=} \text{“haakje blijft hangen”}$ 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

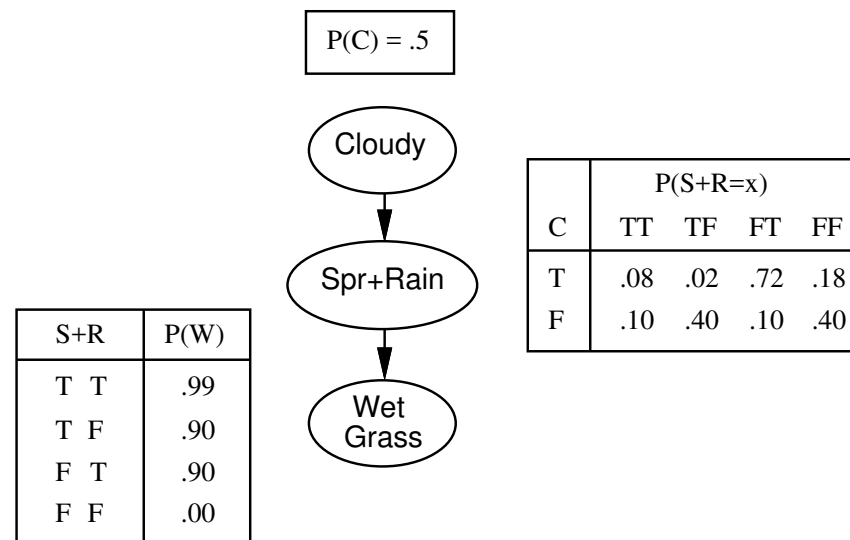
sampling methoden: doe simulaties om een benaderend antwoord te krijgen — veel statistiek dus

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 woensdag 15 mei 2024, kijken we naar het geheel en naar een oud tentamen: [7 juni 2023](#). Zie ook het [oude tentamen van 2 juni 2014](#), met (video's van) uitwerkingen. Er is dus geen college meer op 22 mei, en geen werkcollege op 23 mei.

Denk aan de opgaven:

www.liacs.leidenuniv.nl/~kosterswa/AI/opgaven2.pdf

Maak in het bijzonder 30, 31, 33, 13 en 14, tijdens het werkcollege van 16 mei 2024.

Zie verder

www.liacs.leidenuniv.nl/~kosterswa/AI/