# “Bayesian Belief Networks” voor redeneren over juridische bewijsvoering

**P.E.M. Huygen**

**16 september 2004**

## 1 Redeneren met waarschijnlijkheid

Er is verschil tussen het redeneren van juristen en het redeneren van bijvoorbeeld natuurwetenschappers. Juridisch redeneren gaat vaak over het verbinden van feiten aan normen of regels. De feiten staan vaak vast, en de redenering gaat over de kwalificatie of interpretatie van deze feiten. Juridisch redeneren beeldt vaak de werkelijkheid af op een virtueel domein van normen en kwalificaties. Een autoriteit kan beslissen of een kwalificatie geldig is voor een bepaald feit. Daarbij komt dat regels doorgaans op een “alles-of-niets” manier moeten worden toegepast [4]. Als vastgesteld is, dat bijvoorbeeld een bepaalde kwalificatie in een bepaald geval geldig is, dan verliezen de argumenten die het toekennen van deze kwalificatie twijfelachtig maken hun waarde, alsof ze er nooit geweest waren. Je zou dus kunnen zeggen dat het domein van het juridisch redeneren een door mensen gemaakt “virtueel” domein is, dat ook volledig door mensen te controleren is.

In het redeneren van natuurwetenschappers en in het juridisch redeneren over bewijzen ligt dat anders. In deze gevallen moeten eigenschappen van de werkelijkheid, die in wezen onbekend zijn, afgeleid worden. Net zo min als een autoriteit definitief kan vaststellen hoe hoog de lichtsnelheid is, kan een autoriteit definitief vaststellen of een bepaalde verdachte schuldig is aan een bepaald misdrijf. In beide gevallen blijft er altijd onzekerheid over. Daarnaast is het niet mogelijk om argumenten te elimineren door op een “alles-of-niets” manier te redeneren. Uiteindelijk moeten alle argumenten in één keer tegen elkaar afgewogen worden.

Bijvoorbeeld, een juridische redenering over contractbreuk kan in twee stappen verlopen. Eerst moet worden vastgesteld of er van een rechtsgeldig contract sprake is. Als er zowel argumenten vóór als tegen rechtsgeldigheid zijn, dan kan de rechter deze argumenten tegen elkaar afwegen en een beslissing nemen. Als de rechter beslist dat er een rechtsgeldig contract sprake is, dan verliezen de argumenten daartegen hun waarde. In een volgende fase kan dan worden beargumenteerd of één van de partijen zich niet aan het contract heeft gehouden. Computerprogramma's die bedoeld zijn om het juridische redeneren te ondersteunen zoals Dialaw [8], proberen een juridische casus daarom in onderdelen uiteen te rafelen waarbij over ieder onderdeel afzonderlijk een beslissing genomen kan worden.

Bij redeneren over bewijsvoering is zoiets niet mogelijk. Stel bijvoorbeeld, dat iemand verdacht wordt van een misdrijf. Er zijn tegenstrijdige getuigenverklaringen over of de verdachte in de buurt van het misdrijf, of juist heel ergens anders is gezien. Bovendien heeft degene die het misdrijf heeft gepleegd een spoor achtergelaten, dat ook door de verdachte achtergelaten zou kunnen zijn. Het is nu niet mogelijk om apart te beslissen of de verdachte in de buurt is geweest of niet en of het spoor door de verdachte was achtergelaten of niet. Voor een juiste besluitvorming over de waarschijnlijkheid dat de verdachte de dader is moeten de twee tegenstrijdige getuigenverklaringen tegelijk met de waarschijnlijkheid van de juistheid van de toerekening van het spoor tegelijk tegen elkaar worden afgewogen.

Omdat rekenen met waarschijnlijkheid erg complex is, is het risico op redeneerfouten groot. Een paar voorbeelden van zulke redeneerfouten ("valkuilen") zijn in hoofdstuk 2.2.1 beschreven.

In dit artikel wordt een methode en een computeralgoritme besproken dat mogelijkheden biedt om het rederen over waarschijnlijkheden te ondersteunen en te visualiseren.

## 2 Waarschijnlijkheid en de Regel van Bayes

Twee bekende redeneerschema's in de logica zijn *deductie* en *abductie*. Deductie is het voorbeeld van een veilige redeneervorm [5]. *Veilig* wil in dit geval zeggen dat, als de premissen juist zijn, de conclusie ook juist is. Een voorbeeld is:

Alle $A$ is $B$
$x$ is $A$
$x$ is dus ook $B$

Voorbeeld:

> Alle honden hebben staarten; dit dier is een hond; het heeft dus een staart.

In veel gebieden van het recht kan deductie toegepast worden. Een juridische autoriteit stelt een feit vast, er is een regel die aan dat feit een conclusie verbindt, en de conclusie kan veilig worden getrokken.

Een niet-veilige redeneervorm, waarbij niet gegarandeerd is dat de conclusie waar is als de premissen waar zijn, is *abductie*. Bij abductie probeer je terug te redeneren:

Alle $A$ is $B$
$x$ is $B$
$x$ is dus ook $A$

Oftewel:

> Alle honden hebben staarten; dit dier heeft een staart; het is dus een hond.

Abductie is dus duidelijk een ongeldig redeneerschema. Toch komt redeneren over bewijs vaak neer op een vorm van abductie:

> De dader van het misdrijf heeft een bepaald kenmerk (haarkleur, DNA patroon); de verdachte heeft dat bepaalde kenmerk; hij is dus de dader.

In tegenstelling tot de (binaire) logica kan waarschijnlijkheidsrekening in zo een geval wel iets afleiden. Als de verdachte de enige persoon op de wereld is die het besproken kenmerk heeft, dan mag je de conclusie wel trekken. Als er maar een klein groepje personen bestaat met het besproken kenmerk, dan is de kans dat een bepaalde persoon uit dat groepje de dader is veel groter dan de kans zou zijn zonder kennis over dat kenmerk.

## 2.1 Kansen en voorwaardelijke kansen

Vaak beïnvloedt kennis van omstandigheden de kans die we kunnen toeschrijven aan het optreden van bepaalde gebeurtenissen. Een voorbeeld is de kans dat het morgen zal regenen. Op grond van statistieken van het KNMI kunnen we die kans berekenen aan de hand van het aantal malen dat het in het verleden op dezelfde dag geregend heeft. Als we echter weten dat het vandaag regent, dan moeten de kans dat het morgen regent anders inschatten, omdat de kans dat het regent op de dag na een regenachtige dag groter is dan de kans dat het regent na een zonnige dag. De kans op een gebeurtenis, gegeven het optreden van een andere gebeurtenis, noemen we een *voorwaardelijke kans*.

### 2.1.1 Notatie

Om stellingen over kansen en voorwaardelijke kansen op compacte manier op te schrijven, gebruiken wiskundigen formules en symbolen. In het algemeen symboliseren ze met de letter $P$ (probability) een kans. Beweringen worden ook vaak door hoofdletters gesymboliseerd. We kunnen bijvoorbeeld de bewering "het zal morgen regenen" symboliseren met de letter $H$ (van Hypothese). De bewering "het regent vandaag" symboliseren we met de letter $E$ (van *Evidence*, bewijs). De tegengestelde bewering kunnen we noteren met dezelfde letter, maar met het negatieteken $\neg$ er voor. $\neg E$ betekent dus "het regent vandaag niet".

De kans dat het morgen regent, kunnen we dan noteren als $P(H)$. De voorwaardelijke kans dat het morgen regent, gegeven dat het vandaag regent, noteren we als $P(H \mid E)$. De voorwaardelijke kans dat het morgen regent als het vandaag niet regent noteren we als $P(H \mid \neg E)$.

### 2.2 Omkeren van voorwaardelijke kansen

Een probleem bij het redeneren over bewijsmateriaal is, dat we soms heel precies de kans weten dat het bewijsmateriaal geproduceerd zou worden als de verdachte de dader is, maar dat we eigenlijk geïnteresseerd zijn in het omgekeerde, de voorwaardelijke kans dat de verdachte de dader is, gegeven het gevonden bewijsmateriaal. Stel bijvoorbeeld dat de dader van een misdrijf een haar heeft achtergelaten, en dat het haar van een verdachte dezelfde kleur heeft als de gevonden haar, dan is de voorwaardelijke kans dat de gevonden haar deze kleur zou hebben als de verdachte de dader is precies gelijk aan 1. Het omgekeerde, de voorwaardelijke kans dat de verdachte de dader is, gegeven de kleur van de gevonden haar, weten we niet.

#### 2.2.1 Valkuilen

Stel nu eens, dat het Forensisch Laboratorium heeft uitgezocht dat één op de honderd Nederlanders, net als de verdachte, dezelfde haarkleur heeft als de gevonden haar. Als de verdachte niet schuldig is, dan is iemand anders schuldig. De kans dat deze andere persoon dezelfde haarkleur heeft is één procent, en dit is dus ook de kans dat het haar deze kleur heeft als de verdachte onschuldig is. In formule ($H$ staat voor “verdachte is schuldig” en $E$ staat voor “de gevonden haar heeft deze speciale kleur”):

$$P(E \mid H) = 1 \tag{1}$$
$$P(E \mid \neg H) = 0,01 \tag{2}$$

Deze kansen kunnen leiden tot verkeerde gevolgtrekkingen. Bijvoorbeeld, de officier van justitie kan zeggen “Als de verdachte het niet gedaan heeft, is er een kans van één procent dat deze haar gevonden zou worden Dit is dus voor 99% bewijs dat de verdachte het wel gedaan heeft”. In formulevorm: $P(E \mid \neg H) = 0,01$, dus $P(H) = 0,99$. Deze (verkeerde) gevolgtrekking wordt “prosecutor's fallacy” genoemd. Dat de gevolgtrekking verkeerd is, wordt duidelijk gedemonstreerd door een tegenovergestelde (verkeerde) gevolgtrekking van de advocaat, die zegt “Het bewijsmateriaal toont aan dat één op de honderd Nederlanders de dader kan zijn. Dat zijn ongeveer 160.000 personen. De kans dat mijn cliënt het heeft gedaan is dus verwaarloosbaar.” Deze redeneerfout wordt “defender's fallacy” genoemd. De redenering van de advocaat gaat alleen op als het even waarschijnlijk is dat de verdachte schuldig is als dat iedere andere Nederlander schuldig is. Als er bijvoorbeeld maar tien mogelijke daders zijn, dan is een spoor zoals beschreven behoorlijk belastend. De informatie over de haarkleur moet samengenomen worden met het andere bewijsmateriaal en met het inzicht van de rechter om een zinvolle bijdrage aan de bewijsvoering te geven. In het volgende hoofdstuk (2.3) wordt dit gedaan met behulp van de Regel van Bayes.

In de zogenaamde "Puttense moordzaak" [2] dreigde het Openbaar ministerie in de "prosecutor's fallacy" te lopen. Er rustte sterke verdenking op de verdachte omdat er een belastende getuigeverklaring was. Er was ook een spoor (textielvezels) dat door één van de verdachten had kunnen worden geproduceerd. Zoals hierboven beschreven is, versterkt zo een spoor een verdenking die al sterk is aanzienlijk. Later bleek de belastende getuigeverklaring onbetrouwbaar te zijn. Doordat de à priori verdenking wegviel, viel ook de bewijskracht van de karpetvezel weg (uiteindelijke vrijspraak: *ljn* AE 1877).

Wagenaar [13] gaf een voorbeeld van een rechter die in een valkuil trapte bij het beoordelen van de verklaring van een getuige-deskundige over de kans dat een vrouw achter het stuur zat, gegeven dat een verbaliserende agent een man achter het stuur dacht waar te nemen en gegeven de kans dat de agent meende een man achter het stuur te zien zitter, terwijl er in werkelijkheid een vrouw achter het stuur zat.

Een andere valkuil is, als ten onrechte aangenomen wordt, dat bepaalde waarnemingen onafhankelijk van elkaar zijn. Een bekende casus waarin deze fout is gemaakt, is "People vs. Collins" (beschreven in [7]), dat in 1968 in Amerika speelde. In deze casus werd eeen vrouw beroofd door een jonge andere vrouw, met blond haar in een paardestaart, die volgens getuigen in een gele auto stapte, die bestuurd werd door een zwarte man met een snor. De politei slaagde er in, een echtpaar te vinden dat aan deze beschrijving voldeed. Een wiskundeleraar, die getuige-deskundige werd gehoord, schatte de kansen van ieder van deze feiten, en vermenigvuldigde ze met elkaar. De getuige-deskundige nam bijvoorbeeld aan dat een op de tien auto's geel was, dat een op de vier zwarte mannen een snor draagt, en dat één op de duizend (echt)paren interraciaal was. Bij elkaar schatte hij de kans dat een stel bij deze beschrijving past als 1 op 12 miljoen. Op grond van de verklaring van deze getuige-deskundige werd de vrouw van het stel in eerste aanleg schuldigbevonden en gestraft (in hoger beroep volgde uiteindelijk toch vrijspraak). De getuige-deskundige verwaarloosde hierbij de mogelijkheid dat bijvoorbeeld zwarte mannen die een snor prefereren, ook een preferentie voor een gele auto zouden kunnen hebben, of dat blanke vrouwen die op zwarte mannen vallen, mannen met een snor prefereren. Extreem gesteld, als alle zwarte mannen met snorren in gele auto's rondrijden, dat levert de waarneming dat de auto geel is geen informatie meer op.

Een recenter geval is Sally Clark in Engeland. Sally Clark is een advocate waarvan twee kinderen (baby's) een jaar na elkaar plotseling stierven. De getuige-deskundige berekende dat de kans dat twee kinderen van dezelfde moeder aan "Sudden Infant Death Syndrome" (SIDS) sterven het kwadraat is van de kans dat één kind hieraan sterft. De kans zou dus onwaarschijnlijk klein zijn (1 op 73 miljoen). De "expert" concludeerde hieruit, dat de babies door mishandeling gestorven moeten zijn. In werkelijkheid is er een grote kans dat er erfelijke factoren in het spel zijn. Als een gezin een baby gehad heeft die aan SIDS stierf, dan is de kans dat een tweede baby ook aan SIDS sterft aanzienlijk verhoogd [11]. In tegenstelling tot de uitspraak van de "expert" is het dus geen extreem zeldzame gebeurtenis als er twee babies in één gezin aan SIDS sterven. Sally Clark is in 1999 tot lange gevangenisstraf veroordeeld. Deze veroordeling is in 2003 ongedaan gemaakt [9].

Tenslotte is er de "base rate fallacy". Het volgende voorbeeld van Tversky en Kahneman [12, 5] illustreert deze valkuil. In een stadje opereren twee concurrerende taxibedrijven: Taxi Groen, dat 85 groene taxi's heeft en Taxi Blauw, met 15 blauwe taxi's. Op een dag veroorzaakt een taxi in de avondschemering een ongeluk, en rijdt daarna weg zonder zich te identificeren. Een getuige verklaart, dat deze taxi blauw is. De politie controleert of de getuige onder de omstandigheden van het ongeluk wel groene van blauwe taxi's kan onderscheiden. Het blijkt, dat de getuige acht van de tien keer de juiste kleur herkent. Het slachtoffer van het ongeluk zou nu verhaal kunnen halen bij Taxi Blauw, omdat de betrouwbaarheid van de getuige 80% is. Echter, als we nauwkeurig analyseren, dan zien we dat de getuige 20% van de 85 groene taxi's, dus 17 groene taxi's als blauw ziet, en maar 12 van de 15 blauwe taxi's als blauw ziet. De kans dat de taxi groen is als de getuige zegt dat hij blauw is, is dus nog steeds groter dan de kans dat de taxi inderdaad blauw is. De fout ontstaat doordat de verhouding van de aantallen blauwe en groene taxi's niet in de redenering zijn betrokken.

### 2.3 Bayes' regel

In het vorige voorbeeld kenden we de betrouwbaarheid van de getuige, maar konden we daar niet zonder meer de betrouwbaarheid van de getuigenis uit afleiden. Ongeveer 250 jaar geleden heeft de Britse dominee Bayes een regel opgeschreven die we hiervoor kunnen gebruiken [1]. Om te zien hoe deze regel werkt, schrijven we de taxi casus in formulevorm. De hypothese $H$ is "een blauwe taxi veroorzaakte het ongeluk". De waarneming $E$ is "getuige zag een blauwe taxi". Uit het politieonderzoek bleek dat $P(E \mid H) = 0,8$. We willen eigenlijk weten wat $P(H \mid E)$ is, de kans dat een blauwe taxi bij het ongeluk betrokken was, gegeven dat de getuige dat verklaarde.

De regel van Bayes luidt in formulevorm:

$$P(H \mid E) = \frac{P(H)P(E \mid H)}{P(E)} \tag{3}$$

$P(E)$ is de à priori kans op $E$. Deze kans berekenen we uit de kans op $H$ en de voorwaardelijke kans op $E$, afhankelijk van $H$:

$$P(E) = P(H)\,P(E\,|\,H) + P(\neg H)\,P(E\,|\,\neg H) \tag{4}$$

De regel van Bayes is afgeleid in appendix A.

In ons geval is $P(H) = 0,15$ en $P(\neg H) = 0,85$. $P(E\,|\,H)$ is 0,8 en $P(E\,|\,\neg H)$ is gelijk aan 0,2. De kans dat de taxi blauw was als de getuige dat verklaarde:

$$P(H\,|\,E) = \frac{0,150,8}{0,15 \times 0.8 + 0,85 \times 0,2} = 0,41 \tag{5}$$

Ondanks de (betrouwbare) verklaring van de getuige is het dus onwaarschijnlijk dat de taxi blauw was. De gedupeerde zou beter Taxi Groen kunnen aanspreken dan Taxi Blauw.

In het voorbeeld van de gevonden haar met haarkleur van de verdachte in hoofdstuk 2.2.1 kan de rechter de Regel van Bayes gebruiken om de kans te bepalen dat de verdachte de dader is. Als de rechter bijvoorbeeld op grond van een getuigenverklaring inschat dat de kans dat deze verdachte schuldig is op een tiende schat, dan kan hij deze kans herzien op grond van de informatie van het Forensisch Laboratorium. Uit het voorgaande blijkt dat $P(H) = 0,1$; $P(E\,|\,H) = 1$; $P(E\,|\,\neg H) = 0,01$, dus:

$$\begin{aligned} P(E) &= P(H) \times P(E\,|\,H) + P(\neg H) \times P(E\,|\,\neg H) && (6)\\ &= 0,109 && (7) \end{aligned}$$

en

$$P(H\,|\,E) = \frac{0,1}{0,109} \times 1 = 0,92 \tag{8}$$

De haar is dus in dit geval een krachtig bewijsmiddel, dat de schuld van de verdachte uitermate waarschijnlijk maakt. Stel nu, dat even later de getuigenverklaring niets waard blijkt te zijn, zodat de à priori kans dat de verdachte schuldig is, eigenlijk even groot is als die van ongeveer duizend andere mensen die ten tijde van het misdrijf in de buurt waren. De rechter kan opnieuw de berekening doen, maar nu met $P(H) = 0.001$. Hij rekent in dat geval een voorwaardelijke kans op schuld uit van 0,09. Ondanks de passende haar is de kans dat de verdachte schuldig is nog steeds klein.

Grafiek 1 laat voor het voorbeeld van de haar met trefkans van een procent (kans dat een willekeurig lid van de bevolking eenzelfde haarsoort heeft) zien hoe groot de kans is dat een bepaalde persoon schuldig is als er geen speciale verdenking op hem rust (*prior*), en hoe groot de kans is, als de incriminerende haar gevonden is

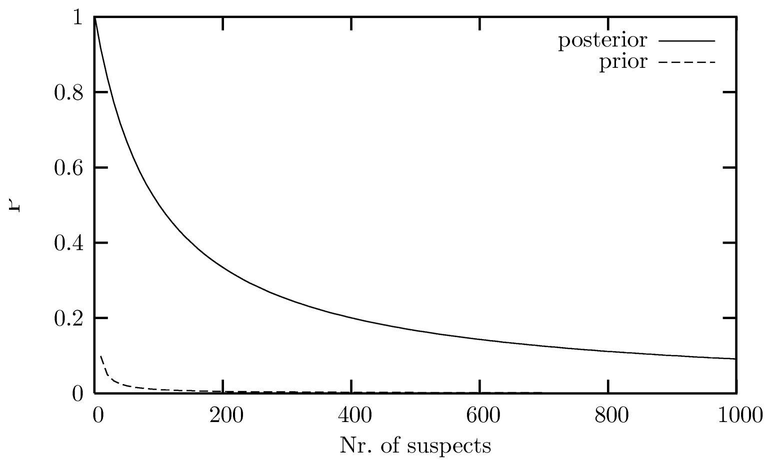


Figuur 1: kans dat een verdachte dader is als een belastend bewijsstuk gevonden is. Zie tekst voor verklaring. *Prior:* kans dat verdachte schuldig is als bewijsstuk er niet is; *Posterior:* Kans dat verdachtem schuldig is als het bewijsstuk gevonden is

(*posterior*). Beide kansen zijn afhankelijk van het aantal mogelijke verdachten. Als er veel mogelijke verdachten zijn, bijvoorbeeld omdat iedereen in de stad het net zo goed gedaan kan hebben als genoemde persoon, dan wordt de kans op schuld ongeveer honderd maal zo groot door het vinden van de haar. Omdat de à priori kans echter heel klein is, is de uiteindelijke kans echter ook klein. Pas als het aantal mogelijke verdachten ongeveer even groot is als de inverse van de trefkans van het spoor (in dit geval honderd verdachten) wordt de à posterie kans groter dan 50%, terwijl de à priori kans nog steeds heel klein is.

De regel van Bayes kan worden herschreven op een manier die hem praktischer bruikbaar maakt. Hierbij berekenen we de verhouding tussen de kans dat de hypothese juist is ($P(H)$) en de kans $P(\neg H)$ dat hij onjuist is. Deze verhouding, in het Engels de "odds" genoemd, wordt vaak in weddenschappen gebruikt ("tien tegen één dat het morgen mooi weer is"). De *prior odds* is dan de verhouding van de kansen dat $H$ juist dan wel niet juist is als we nog geen kennis van het bewijsmateriaal hebben, en de *posterior odds* is dezelfde verhouding als we wel weet van het bewijsmateriaal hebben.

De formule van Bayes kan in termen van *odds* herschreven worden:

$$\frac{P(H\,|\,E)}{P(\neg H\,|\,E)} = \frac{P(H)}{P(\neg H)} \times \frac{P(E\,|\,H)}{P(E\,|\,\neg H)} \tag{9}$$

In woorden: "De *posterior odds* dat de hypothese juist is, gegeven het bewijsmateriaal is gelijk aan de *prior odds* dat de hypothese juist is maal de verhouding van de kansen dat we het bewijsmateriaal zouden vinden als de hypothese juist is of als hij niet juist is".

Vergelijking 9 levert een werkverdeling op tussen de rechter en de getuige-deskundige [10]. Het is de taak van de rechter om een opinie te vormen over de casus [13]. Hij moet voor zichzelf een indruk krijgen van de mate waarin vaststaat dat een verdachte schuldig is. Deze infdruk legt hij vast in de *prior odds*. De getuige-deskundige moet daarbuiten blijven. Het enige dat hij kan doen is, om de verhouding $P(E \mid H)/P(E \mid \neg H)$ zo goed mogelijk te schatten op grond van zijn onderzoek. De rechter moet deze informatie gebruiken om zijn opinie aan te passen en tot *posterior odds* te komen.

### 2.4 Bayesiaanse netwerken

In sommige gevallen hangen gebeurtenissen op een ingewikkelde manier met elkaar samen. Het is dan moeilijk om de uiteindelijke kans te bepalen dat gebeurtenissen gegaan zijn zoals door partijen in een juridisch proces voorspiegelen [6]. De Regel van Bayes maakt het mogelijk om ook deze complexe situaties door te rekenen. Er bestaan computerprogramma's, "Bayesian Belief Networks" (BBN's) die dat doen. Een voorbeeld van zo een programma is Hugin (`www.hugin.com`). Een "light" versie van dit programma, met beperkte mogelijkheden kan vrij gedownload en gebruikt worden. In dit voorbeeld zal ik deze "light" versie gebruiken.

### 2.5 Voorbeeld van een Bayesian Belief Netwerk

Het volgende, fictieve, voorbeeld is een illustratie over hoe een BBN gebruikt zou kunnen worden.

Er is een moord gepleegd en de politie heeft een verdachte gearresteerd. Een getuige verklaart, dat hij de verdachte in de buurt van de plaats van het misdrijf heeft gezien rond het tijdstip dat de moord moet zijn gepleegd. Een vriend van de verdachte verklaart echter dat verdachte bij hem thuis is geweest, te ver weg om de moord te hebben kunnen plegen. De technische recherche vond een spoor dat geproduceerd moet zijn door de dader. Één op de honderd Nederlanders zou dit spoor kunnen produceren. De verdachte blijkt het spoor ook te kunnen produceren.

Het bovenstaande voorbeeld kan in een model gegoten worden, waarna met de formule van Bayes de waarschijnlijkheid berekend kan worden dat de verdachte de dader is, gebruik makend van 1) de waarschijnlijkheid dat de getuigen liegen of zich vergissen; 2) de waarschijnlijkheid dat de belastende getuige de verdachte juist geïdentificeerd heeft, 3) de waarschijnlijkheid dat de verdachte het gevonden spoor heeft geproduceerd en 4) de à priori waarschijnlijkheid dat de verdachte de dader is. Een model van het voorbeeld staat in figuur 2. Het model is een zogenaamde *graaf*, een netwerk van *knopen* die door pijlen met elkaar verbonden zijn. De knopen representeren gebeurtenissen, waarnemingen

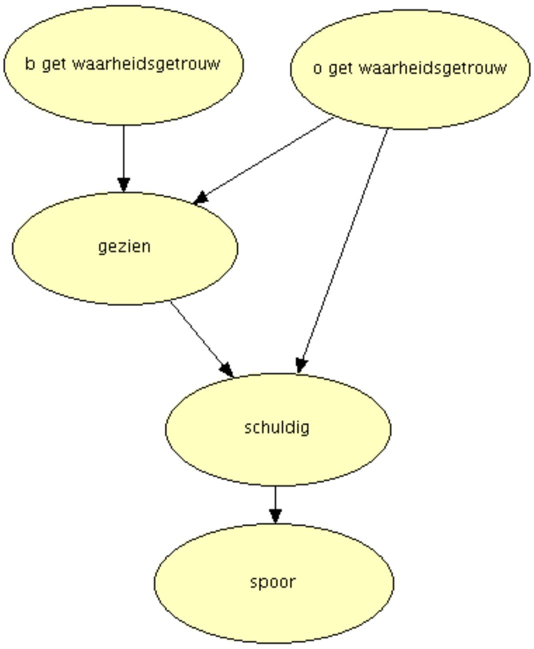


Figuur 2: Model van een fictieve moordcasus (zie tekst).

of hypothesen, die waar of onwaar kunnen zijn, en een pijl tussen twee knopen geeft aan, dat het al of niet waar zijn van wat de ene knoop representeert invloed heeft op de waarschijnlijkheid dat wat de andere knoop representeert waar is.

De bovenste twee knopen `b get waarheidsgetrouw` en `o get waarheidsgetrouw` representeren de kansen dat de belastende getuige (die verklaarde de verdachte in de buurt van de plaats van de misdaad gezien te hebben) resp. de ontlastende getuige (die verklaarde dat de verdachte heel ergens anders was) liegt. De knoop `gezien` representeert de kans dat de belastende getuige de verdachte inderdaad gezien heeft (hij zou zich ook hebben kunnen vergissen). In dit voorbeeld gaan we er van uit dat de ontlastende getuige, een bekende van de verdachte, zich niet kan vergissen. Als deze de waarheid spreekt, dan kan de verdachte niet op de plaats van het misdrijf gezien zijn, en dan kan de verdachte ook niet schuldig zijn. De knoop `schuldig` representeert de kans dat de verdachte de dader is, en knoop `spoor` representeert de kans dat het gevonden spoor juist dit kenmerk heeft dat bij de verdachte past.

De bovenste knopen, waar geen pijlen op uitkomen, bevatten ieder een tabel van á priori waarschijnlijkheden, en de andere knopen bevatten tabellen van voorwaardelijke waarschijnlijkheden (bijvoorbeeld de kans dat de verdachte schuldig is, gegeven dat de belastende getuige hem in de buurt van het misdrijf heeft gezien). Tabel 1 geeft een voorbeeld.

| **hypothese** | **bel. getuige** | **ontl. getuige** | **gezien** | **schuldig** | **kans** |
|---|---|---|---|---|---|
| Bel. getuige | | | | | 0,8 |
| Ontl. getuige | | | | | 0,8 |
| Gezien | $j$ | $j$ | | | 0,0 |
| | $j$ | $n$ | | | 0,8 |
| | $n$ | $j$ | | | 0,0 |
| | $n$ | $n$ | | | 0,0 |
| Schuldig | | $j$ | $j$ | | 0,0 |
| | | $j$ | $n$ | | 0,0 |
| | | $n$ | $j$ | | 0,5 |
| | | $n$ | $n$ | | 0,1 |
| Spoor | | | | $j$ | 1,0 |
| | | | | $n$ | 0,01 |

Tabel 1: Voorbeeld voor instellingen van het voorbeeld BBN van figuur 2. De laatste kolom (*kans*) is de waarschijnlijkheid dat een hypothese waar is. Voor sommige hypothesen hangt deze waarschijnlijkheid af van het waar of niet waar van andere hypothesen. Zo wordt bijvoorbeeld in de eerste rij van de tabel de kans dat de belastende getuige waarheidsgetrouw is geschat op 0,8, en in de tiende rij de kans dat de verdachte schuldig is, als er geen waarheidsgetrouwe verklaringen zijn van mensen die de verdachte in de buurt hebben gezien, op 0,1 geschat.

Als deze waarden ingevuld worden, dan kan de computer de waarschijnlijkheden doorrekenen (figuur 3).

Vervolgens kunnen we het spoor als bewijs invoegen (figuur 4). De kans dat de verdachte schuldig is, neemt nu toe van 7% naar 88%. Als naderhand blijkt dat de belastende getuige erg onbetrouwbaar was, dan kan de waarschijnlijkheid dat de belastende getuige waarheidsgetrouw was op 0% gesteld worden. De waarschijnlijkheid dat de verdachte schuldig is, zakt daardoor naar 67%.

# 3 Discussie

## 3.1 Het invoeren van de waarschijnlijkheden

Voor juridische casus lijkt het op het eerste gezicht moeilijk om de waarschijnlijkheden en voorwaardelijke waarschijnlijkheden in te vullen. Ogenschijnlijk is dit veel eenvoudiger voor natuurwetenschappelijke of biomedische problemen,

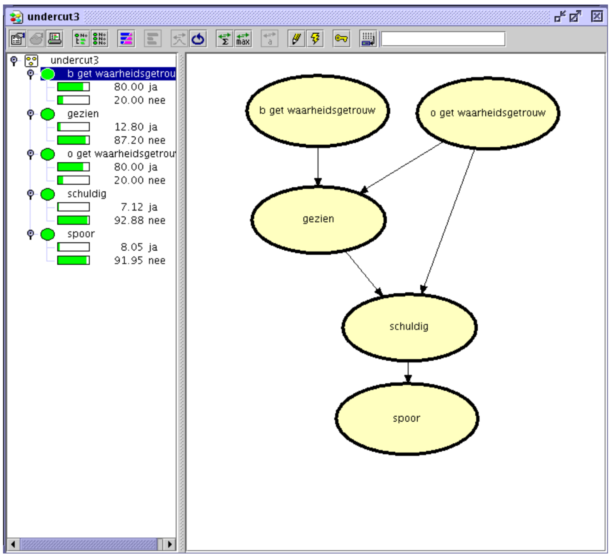


Figuur 3: Waarschijnlijkheden na het invullen van de à priori kansen, voordat het spoor is geïdentificeerd.

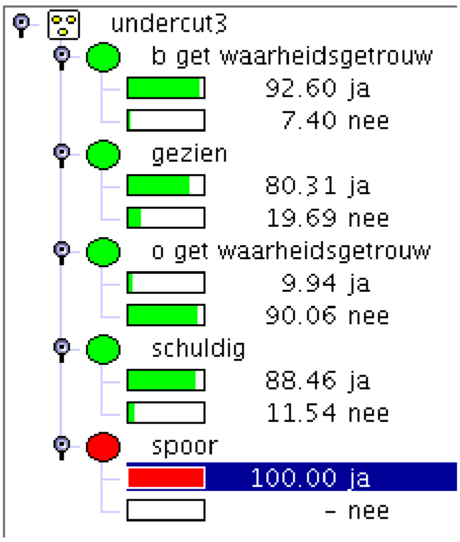


Figuur 4: Berekende waarschijnlijkheden als vast staat dat de verdachte het spoor had kunnen produceren

waarbij de waarschijnlijkheden met experimenteel onderzoek bepaald kunnen worden. Uit de experimenten volgen dan waarschijnlijkheidswaarden. In juridische casus kunnen zulke experimenten natuurlijk niet gedaan worden. Van de andere kant moet een rechter toch enig idee hebben van de waarschijnlijkheid. Hoe zou hij anders kunnen bepalen of iets overtuigend bewezen is? Feitelijk is een vaag, intuïtief idee over de waarschijnlijkheden in de onderliggende casus het enig beschikbare middel waarop een rechter kan besluiten of iets overtuigend bewezen is. Een rechter moet dus minstens in staat worden geacht om ondergrenzen en bovengrenzen van kansen aan te geven dat bepaalde veronderstellingen juist zijn. Als de rechter het bijvoorbeeld niet onmogelijk acht dat de belastende getuige liegt, dan zal de kans dat dat zo is toch ergens boven de 10% liggen. En misschien vindt hij de kans dat de ontlastende getuige liegt wel wat groter, omdat deze een goede kennis van de verdachte is, of omdat deze getuige een slechte indruk maakte tijdens de zitting. Een BBN kan de rechter helpen om zijn inzicht in deze waarschijnlijkheden zo goed mogelijk te gebruiken. De rechter zou bijvoorbeeld ook redelijke onder- en bovengrenzen kunnen invoeren, beurtelings in het voordeel van de ene of de andere partij [6]. Op grond daarvan zou hij kunnen concluderen dat het eigenlijk wel zeker is dat de verdachte schuldig is, of dat er toch reden is voor twijfel.

In de vorm waarin het in dit artikel gepresenteerd is, is het BBN niet goed bruikbaar voor de juridsche praktijk. Om echt bruikbaar te zijn zou een aangepast BBN moeten worden ontwikkeld, waar de kansen op flexibele manier ingevoerd kunnen worden.

Het modelleren van juridische redenering kan het inzicht in een casus verdiepen, en kan laten zien of er hiaten in de benodigde informatie zijn. Het geeft een zo precies mogelijk inzicht in hoe de waarschijnlijkheden liggen. Alle onzekerheden worden in één keer tegen elkaar afgewogen. Daardoor krijgt bijvoorbeeld een rechter goed inzicht in de waarschijnlijkheden. Als een rechter zo een model probeert te maken, dan kan het gebeuren dat hij merkt, dat hij onvoldoende informatie heeft om de waarschijnlijkheid te bepalen. Een fictief voorbeeld is het volgende: Op het been van een vermoorde vrouw is een druppel sperma gevonden. De politie vindt een verdachte, maar het sperma blijkt niet van deze verdachte afkomstig te zijn. Het Openbaar Ministerie oppert dan de mogelijkheid dat deze druppel afkomstig is van sexueel contact van de vrouw met een andere man voordat de moord plaatsvond. Door de verkrachting is de spermadruppel vanuit de vagina naar het been verplaatst. Een getuige-deskundige verklaart dat dit scenario "niet onmogelijk" is. De rechter probeert van deze casus een Bayesiaans model te maken en moet dan een kans invullen dat een druppel sperma vanuit de vagina op het been terechtkomt. Hij vraagt de getuige-deskundige om een zo precies mogelijke waarschijnlijkheid. De getuige-deskundige is daardoor gedwongen om nader onderzoek te doen, en moet vervolgens concluderen dat deze kans eigenlijk onrealistisch klein is. Als gevolg daarvan moet er ernstig aan getwijfeld worden of de verdachte de verkrachting en moord wel gepleegd heeft, en volgt vrijspraak.

Naast hulpmiddel bij de bepaling of het bewezen is dat een bepaalde verdachte schuldig is aan een bepaald misdrijf, kan een BBN ook helpen om bijvoorbeeld bij verkeersongelukken alternatieve verklaringen van partijen met elkaar te vergelijken [6, 3].

Tenslotte zouden BBN's een goed hulpmiddel kunnen zijn in het onderwijs aan (aanstaande) juristen, om hen een gevoel te geven over de werking van waarschijnlijkeid en kansen, en hen te laten zien wat voor valkuilen er zijn.

## 4 Conclusie

Het redeneren over juridisch bewijs verschilt van het meeste juridische redeneren, omdat onzekerheid er een grote rol in speelt. Het redeneren met onzekerheid kan soms gecompliceerd zijn, zeker als er met meerdere onzekerheden tegelijkertijd rekening gehouden moet worden. Bovendien is het eenvoudig om daarbij bepaalde redeneerfouten te maken. Bayesiaanse Belief Networks zouden een gereedschap kunnen zijn om deze zekerheden inzichtelijk te maken. Toepassingsmogelijkheden zouden in de eerste plaats in het onderwijs aan juristen kunnen liggen, en eventueel ook in de rechtszaal. Een probleem is nog de moeilijkheid om alle waarschijnlijkheden en voorwaardelijke waarschijnlijkheden in te voeren.

## A Afleiding van de regel van Bayes

De regel van Bayes kan afgeleid worden uit de kans dat $H$ en $E$ tegelijk waar zijn. Deze kans is gelijk aan het product van de kans dat $H$ waar is en de kans dat $E$ waar is, gegeven dat $H$ waar is:

$$P(H\&E) = P(H) \times P(E\,|\,H) \tag{10}$$

In formule 10 kunnen we $E$ en $H$ met elkaar verwisselen:

$$P(H\&E) = P(E) \times P(H\,|\,E) \tag{11}$$

De rechterleden van beide vergelijkingen aan elkaar gelijkstellen:

$$P(E) \times P(H\,|\,E) = P(H) \times P(E\,|\,H) \tag{12}$$

Beide leden door $P(E)$ delen levert de Regel van Bayes op:

$$P(H \mid E) = \frac{P(H)}{P(E)} P(E \mid H) \tag{13}$$

## Referenties


[1] Th. Bayes. An essay toward solving a problem in the doctrine of chance. *Philosophical Transactions of the Royal Society*, 1763.

[2] J.A. Blaauw. *De Puttense moordzaak: Reconstructie van een dubieus moordonderzoek*. Fontein., Baarn, 3e aangevulde ed. edition, 2002.

[3] G.A. Davis. Bayesian reconstruction of traffic accindents. *Law, Probability and Risk*, 2:69–89, 2003.

[4] R. Dworkin. Taking rights seriously. In Frederick Schauer and Walter Sinnott-Armstrong, editors, *The Philosophy of Law: Classic and Contemporary Readings with Commentary*, pages 74–89. Harcourt Brace and Company, 1996.

[5] I. Hacking. *An Introduction to Probability and Inductive Logic*. Cambridge University Press, 2001.

[6] P.E.M. Huygen. Use of bayesian belief networks in legal reasoning. In *17-th Bileta Conference, Amsterdam*, page `http://www.bileta.ac.uk/02papers/huygen.html`, 2002.

[7] H.O. Kerkmeester and R.V. de Mulder. Statistiek en bewijsrecht. *Nederlands Juristenblad*, 62(3):73–81, 1987.

[8] AR Lodder. *On Legal Justification and Dialogical Models of Argumentation*, volume 42 of *Law and Philosophy Library*. Springer, 1999.

[9] Court of Appeal. Judgment. `http://www.sallyclark.org.uk/Judgment03.html`, 4 2003. Herziening uitspraak Sally Clark.

[10] M. Sjerps. Onderzoek forensische statistiek. *NAW*, 2004.

[11] Royal Statistical Society. Royal statistical society concerned by issues raised in sally clark case. `http://www.rss.org.uk/archive/evidence/sclark.html`, october 2001.

[12] A. Tversky and D. Kahneman. Evidential impact of base rate. In D. Kahneman, P. Slovic, and A. Tversky, editors, *Judgment under Uncertainty: Heuristics and Biases*, chapter 10. Cambridge University Press, 1982.

[13] W.A. Wagenaar. The proper seat: A Bayesian discussion of the position of expert witnesses. *Law and Human Behavior*, 12(4):499–510, 1988.