

Incertidumbre y conocimiento

- SI sintoma(P,dolor-de-muelas) ENTONCES enfermedad(P,caries)

- ¿Expresa esta regla un conocimiento correcto?

- Quizás sería mejor un conocimiento más exhaustivo:

SI sintoma(P,dolor-de-muelas)

ENTONCES enfermedad(P,caries) 0

enfermedad(P,sinusitis) 0

enfermedad(P,muela-del-juicio) 0

.....

- ¿Por qué a veces el conocimiento categórico no nos sirve?

- Demasiado trabajo ser exhaustivo

- Desconocimiento teórico

- Desconocimiento práctico

Incertidumbre y conocimiento

- Otra forma de expresar el conocimiento: grado de creencia
 - *Creemos*, basándonos en nuestras *percepciones*, que un paciente que tenga dolor de muelas, tiene caries con una probabilidad del 80 %
 - $P(\text{Caries} = \text{true} | \text{Dolor} = \text{true}) = 0,8$
 - La probabilidad expresa el *grado de creencia*, no el *grado de verdad*
 - Por tanto, la probabilidad puede cambiar a medida que se conocen nuevas *evidencias*
- La teoría de la probabilidad servirá como medio de representación de conocimiento incierto

Variables aleatorias

- **Variables aleatorias:** una “parte” del mundo cuyo estado podemos desconocer
 - Ejemplo: la variable aleatoria *Caries* describe el hecho de que un paciente pueda o no tener caries
 - Nuestra descripción del mundo vendrá dada por un conjunto de variables aleatorias
- Una variable aleatoria puede tomar diferentes valores de su dominio
 - Los posibles valores de *Caries* son *true* y *false*
 - Notación: variables aleatorias en mayúsculas y sus valores en minúsculas
- Tipos de variables aleatorias:
 - Booleanas (notación: *caries* y \neg *caries* son equivalentes a $Caries = true$ y $Caries = false$, respectivamente)
 - Discretas (incluyen a las booleanas)
 - Continuas
- En lo que sigue, nos centraremos en las variables discretas

Proposiciones

- Usando las conectivas proposicionales y las variables aleatorias, podemos expresar *proposiciones*
- Ejemplos:
 - $\text{caries} \wedge \neg \text{dolor}$
 - $\text{Caries} = \text{true} \vee \text{Tiempo} = \text{nublado}$
 - $\text{Tirada1} = 5 \wedge (\text{Tirada2} = 4 \vee \text{Tirada2} = 5 \vee \text{Tirada2} = 6)$
- Asignaremos probabilidades a las proposiciones para expresar nuestro grado de creencia en las mismas

Eventos atómicos

- Dado un conjunto de variables aleatorias que describen nuestro “mundo”, un evento atómico es un tipo particular de proposición:
 - Conjunción de proposiciones elementales, que expresan un valor concreto para todas y cada una de las variables
 - Ejemplo: $caries \wedge \neg dolor$, siempre que $Caries$ y $Dolor$ sean todas las variables aleatorias en nuestra descripción del mundo
- Características:
 - Mútuamente excluyentes
 - Todos los eventos atómicos son exhaustivos (alguno debe ocurrir)
 - Un evento atómico implica la verdad o falsedad de toda proposición
 - Toda proposición es equivalente a la disyunción de un conjunto de eventos atómicos: por ejemplo, $caries$ es equivalente a $(caries \wedge dolor) \vee (caries \wedge \neg dolor)$

Probabilidad incondicional

- Probabilidad *incondicional* (o *a priori*) asociada a una proposición a :
 - Grado de creencia sobre a , en ausencia de cualquier otra información o evidencia, notada $P(a)$
 - Ejemplo: $P(\text{caries}) = 0,1$, $P(\text{caries} \wedge \neg\text{dolor}) = 0,05$
 - Notación: $P(\text{caries}, \neg\text{dolor})$ es equivalente a $P(\text{caries} \wedge \neg\text{dolor})$
- *Distribución de probabilidad* de una variable aleatoria
 - Ejemplo: *Tiempo* es una v.a. con valores *lluvia*, *sol*, *nubes* y *nieve*; una distribución de probabilidad viene dada por las probabilidades de que la variable pueda tomar los diferentes valores
 - $P(\text{Tiempo} = \text{sol}) = 0,7$, $P(\text{Tiempo} = \text{lluvia}) = 0,2$, $P(\text{Tiempo} = \text{nubes}) = 0,08$, $P(\text{Tiempo} = \text{nieve}) = 0,02$

Probabilidad incondicional

- **Notación:** usaremos P (en negrita), para expresar de manera compacta una distribución de probabilidad (fijado un orden entre sus valores)
 - **Ejemplo:** $P(\text{Tiempo}) = \langle 0,7, 0,2, 0,08, 0,02 \rangle$
- Distribución de probabilidad *conjunta*: probabilidad de cada combinación de valores de dos o más variables aleatorias
 - Notación $P(X, Y)$: manera compacta de denotar a una tabla con esas probabilidades
 - $P(\text{Tiempo}, \text{Caries})$ denota una tabla con 4×2 entradas
 - Distribución de probabilidad *conjunta y completa* (DCC): probabilidad de cada evento atómico
 - Una DCC es una *especificación completa* de la incertidumbre que se tiene sobre el “mundo” descrito

Probabilidad condicional

- Probabilidad *condicional* (o *a posteriori*) asociada a a dada b (a y b proposiciones):
 - Grado de creencia sobre a , dado que *todo lo que sabemos* es que b ocurre, notada $P(a|b)$
 - Ejemplo: $P(\text{caries}|\text{dolor}) = 0,8$ significa que una vez sabido que un paciente tiene dolor de muelas (y sólo sabemos eso), nuestra creencia es que el paciente tendrá caries con probabilidad 0,8
- Relación entre probabilidad condicional e incondicional:
 - $P(a|b) = \frac{P(a \wedge b)}{P(b)}$, o también
 - $P(a \wedge b) = P(a|b)P(b)$ (regla del producto)
- Notación $P(X|Y)$ para expresar la tabla de probabilidades condicionales
 - Forma compacta de la regla del producto: $P(X, Y) = P(X|Y)P(Y)$

Probabilidad condicional *vs* implicación lógica

- La probabilidad condicional formaliza el hecho de que los grados de creencias se actualizan a medida que se van conociendo nuevas evidencias en el mundo incierto
- La probabilidad condicional *no* es lo mismo que una implicación lógica con incertidumbre
 - $P(a|b) = 0,8$ no es lo mismo que decir que “siempre que b sea verdad, entonces $P(a) = 0,8$ ”
 - Ya que $P(a|b)$ refleja que b es *la única* evidencia conocida

Axiomas de probabilidad y cálculo

- Interpretación de la función P
 - Frecuentista: casos posibles entre casos totales
 - Subjetiva: grado de creencia basado en nuestras percepciones
- Axiomas sobre la función de probabilidad
 - $0 \leq P(a) \leq 1$
 - $P(\text{true}) = 1$ y $P(\text{false}) = 0$ donde *true* y *false* representan a cualquier proposición tautológica o insatisfactible, respectivamente
 - $P(a \vee b) = P(a) + P(b) - P(a \wedge b)$
- El resto del cálculo de probabilidades se construye sobre estos tres axiomas. Por ejemplo:
 - $P(\neg a) = 1 - P(a)$
 - $\sum_{i=1}^n P(D = d_i) = 1$, siendo D una v.a. y $d_i, i = 1, \dots, n$ sus posibles valores
 - $P(a) = \sum_{e_i \in e(a)} P(e_i)$, siendo a una proposición y $e(a)$ el conjunto de eventos atómicos cuya disyunción es equivalente a a

Inferencia probabilística

- Por inferencia probabilística entendemos el cálculo de la probabilidad de una proposición dada condicionada por la observación de determinadas evidencias
 - Es decir, cálculos del tipo $P(a|b)$ donde a es la proposición que se *consulta* y b es la proposición que se ha *observado*
 - El conocimiento base vendrá dado por una DCC (representada de alguna manera *eficiente*, como ya veremos)
- Ejemplo de DCC:

	<i>dolor</i>	<i>dolor</i>	\neg <i>dolor</i>	\neg <i>dolor</i>
	<i>hueco</i>	\neg <i>hueco</i>	<i>hueco</i>	\neg <i>hueco</i>
<i>caries</i>	0.108	0.012	0.072	0.008
\neg <i>caries</i>	0.016	0.064	0.144	0.576

Inferencia probabilística a partir de una DCC

- Cálculo de probabilidades incondicionales basado en la ecuación $P(a) = \sum_{e_i \in \mathbf{e}(a)} P(e_i)$
 - $P(\text{caries} \vee \text{dolor}) = 0,108 + 0,012 + 0,072 + 0,008 + 0,016 + 0,064 = 0,28$
 - $P(\text{caries}) = 0,108 + 0,012 + 0,072 + 0,008 = 0,2$
- En general:
 - $P(Y) = \sum_z P(Y, z)$ (regla de marginalización)
- Notación:
 - Y es un vector de variables aleatorias, simbolizando cualquier combinación de valores de esas variables
 - z representa una combinación de valores concretos para un conjunto Z de variables aleatorias (las restantes)
- Variante: $P(Y) = \sum_z P(Y|z) \cdot P(z)$ (regla de condicionantes)

Inferencia probabilística a partir de una DCC

- Cálculo de probabilidades condicionales usando la DCC (un ejemplo)

- Probabilidad de tener caries, observado que hay dolor:

$$P(\text{caries}|\text{dolor}) = \frac{P(\text{caries} \wedge \text{dolor})}{P(\text{dolor})} = \frac{0,108 + 0,012}{0,108 + 0,012 + 0,016 + 0,064} = 0,6$$

- Como comprobación podemos calcular el opuesto:

$$P(\neg\text{caries}|\text{dolor}) = \frac{P(\neg\text{caries} \wedge \text{dolor})}{P(\text{dolor})} = \frac{0,016 + 0,064}{0,108 + 0,012 + 0,016 + 0,064} = 0,4$$

- $P(\text{dolor})$ puede verse como una constante que *normaliza* la distribución $P(\text{Caries}|\text{dolor})$ haciendo que sume 1:

$$\begin{aligned} P(\text{Caries}|\text{dolor}) &= \alpha P(\text{Caries}, \text{dolor}) = \\ &= \alpha [P(\text{Caries}, \text{dolor}, \text{hueco}) + P(\text{Caries}, \text{dolor}, \neg\text{hueco})] = \\ &= \alpha [\langle 0,108, 0,016 \rangle + \langle 0,012, 0,064 \rangle] = \alpha \langle 0,12, 0,08 \rangle = \langle 0,6, 0,4 \rangle \end{aligned}$$

Inferencia probabilística a partir de una DCC

- En general, dada una variable aleatoria X , un conjunto de variables observadas E (con valor concreto e), se tiene:

$$P(X|e) = \alpha P(X, e) = \alpha \sum_{\mathbf{y}} P(X, e, \mathbf{y})$$

- un sumando para cada combinación \mathbf{y} de valores de las variables restantes Y no observadas
- α es una constante de normalización, que hace que la distribución de probabilidades sume 1
- Dada una DCC, la fórmula anterior nos da un método para realizar inferencia probabilística
- Problema en la práctica: exponencialidad
 - Con n variables, procesar la DCC necesita un tiempo $O(2^n)$
 - En un problema real, podría haber cientos o miles de variables

Independencia probabilística

- En muchos casos prácticos, muchas de las variables de un problema son *independientes* entre sí
 - Ejemplo: $P(\text{Tiempo} = \text{nublado} | \text{dolor}, \text{caries}, \text{hueco}) = P(\text{Tiempo} = \text{nublado})$
 - Si la variable *Tiempo* (con 4 posibles valores) formara parte de una descripción en la que están *Caries*, *Hueco* y *Dolor*, no necesitaríamos una tabla con 32 entradas para describir la DCC, sino dos tablas independientes (8+4 entradas)
- Dos variables aleatorias X e Y son independientes si $P(X|Y) = P(X)$ (equivalentemente, $P(Y|X) = P(Y)$ ó $P(X, Y) = P(X) \cdot P(Y)$)
 - En general, dos proposiciones a y b son independientes si $P(a|b) = P(a)$
- Asumir independencia entre ciertas variables ayuda a que la representación del mundo sea más manejable
 - Reduce la exponencialidad (*factorización* del problema)
 - El asumir que dos variables son independientes está basado normalmente el en conocimiento previo del dominio que se modela

La regla de Bayes

- De $P(a \wedge b) = P(a|b)P(b) = P(b|a)P(a)$ podemos deducir la siguiente fórmula, conocida como *regla de Bayes*:

$$P(b|a) = \frac{P(a|b)P(b)}{P(a)}$$

- Regla de Bayes para variables aleatorias:

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

- recuérdese que esta notación representa un conjunto de ecuaciones, una para cada valor específico de las variables
- Generalización, en presencia de un conjunto e de observaciones:

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

Uso de la regla de Bayes

- La regla de Bayes nos permite *diagnosticar* en función de nuestro conocimiento de relaciones *causales*
- Ejemplo
 - Sabemos que la probabilidad de que un paciente de meningitis tenga el cuello hinchado es 0.5 (relación causal)
 - También sabemos la probabilidad (incondicional) de tener meningitis ($\frac{1}{50000}$) y de tener el cuello hinchado (0.05)
 - Estas probabilidades provienen del conocimiento y la experiencia
 - La regla de Bayes nos permite diagnosticar la probabilidad de tener meningitis una vez que se ha observado que el paciente tiene el cuello hinchado:

$$P(m|h) = \frac{P(h|m)P(m)}{P(h)} = \frac{0,5 \times \frac{1}{50000}}{0,05} = 0,0002$$

Uso de la regla de Bayes

- Una variante del ejemplo anterior:

- Si M es una variable aleatoria booleana, podríamos calcular con la siguiente fórmula, donde α es el factor de normalización:

$$P(M|h) = \alpha \langle P(h|m)P(m), P(h|\neg m)P(\neg m) \rangle$$

- Versión para variables aleatorias: $P(Y|X) = \alpha P(X|Y)P(Y)$

- ¿Por qué calcular el diagnóstico en función del conocimiento causal y no al revés?

- Porque es más fácil y robusto disponer de probabilidades causales que de probabilidades de diagnóstico
- La información probabilística está generalmente disponible en la forma $P(\text{efecto}|\text{causa})$
- Y usamos la regla de Bayes para calcular $P(\text{causa}|\text{efecto})$

La regla de Bayes: combinando evidencias

- Evidencias múltiples y exponencialidad
 - Cuando manejamos varias variables para representar distintas evidencias (y es lo habitual), el uso de la regla de Bayes puede necesitar una cantidad exponencial de probabilidades de tipo $P(\text{efecto}|\text{causa})$
 - Supongamos, por ejemplo, que tenemos evidencias sobre oquedades en los dientes (*Hueco*) y sobre dolor en el paciente (*Dolor*), y queremos diagnosticar si tiene caries (*Caries*)
 - Por la regla de Bayes: $P(\text{Caries}|\text{Dolor}, \text{Hueco}) = \alpha P(\text{Dolor}, \text{Hueco}|\text{Caries})P(\text{Caries})$
 - En general, si se tienen n variables booleanas de evidencia, deberíamos tener 2^n probabilidades condicionales (por cada valor de una variable de diagnóstico) en nuestra base de conocimiento
 - Esta exponencialidad no se maneja bien desde el punto de vista práctico
- Nuevamente, asumir cierta noción de *independencia* entre variables simplificará la cuestión

Independencia condicional

- Sin embargo, en nuestro ejemplo *Dolor* y *Hueco* no son independientes
 - Ambas dependen de *Caries*
- Pero son independientes *una vez conocido el valor de Caries*
 - Es decir: $P(\text{Dolor}|\text{Hueco}, \text{Caries}) = P(\text{Dolor}|\text{Caries})$ o equivalentemente $P(\text{Hueco}|\text{Dolor}, \text{Caries}) = P(\text{Hueco}|\text{Caries})$
 - También equivalente: $P(\text{Hueco}, \text{Dolor}|\text{Caries}) = P(\text{Hueco}|\text{Caries})P(\text{Dolor}|\text{Caries})$
- En general, dos v.a. X e Y son independientes dada una v.a. Z si $P(X, Y|Z) = P(X|Z)P(Y|Z)$
 - O equivalentemente $P(X|Y, Z) = P(X|Z)$ ó $P(Y|X, Z) = P(Y|Z)$
- Esto simplifica la inferencia probabilística:
 - $$\underline{P(\text{Caries}|\text{Dolor}, \text{Hueco}) = \alpha P(\text{Dolor}|\text{Caries})P(\text{Hueco}|\text{Caries})P(\text{Caries})}$$
 - Sólo es necesario saber las probabilidades causales de cada variable *por separado*
 - “Reduciendo” la exponencialidad

Independencia condicional

- La independencia condicional entre algunas variables es esencial para un almacenamiento eficiente de las DCCs. Por ejemplo:

$$\begin{aligned} P(\text{Dolor}, \text{Hueco}, \text{Caries}) &= P(\text{Dolor}, \text{Hueco} | \text{Caries}) P(\text{Caries}) = \\ &= P(\text{Dolor} | \text{Caries}) P(\text{Hueco} | \text{Caries}) P(\text{Caries}) \end{aligned}$$

- En lugar de tener una tabla con 7 números independientes sólo necesitamos 5 números independientes (en tres tablas)
- Si *Caries* tuviera n síntomas independientes entre sí (dado *Caries*), el tamaño de la representación de la DCC crece $O(n)$ en lugar de $O(2^n)$
- Con una *Causa* con n efectos E_i independientes entre sí dado *Causa*, se tiene $P(\text{Causa}, E_1, \dots, E_n) = P(\text{Causa}) \prod_i P(E_i | \text{Causa})$
 - No siempre se dan estas condiciones de independencia tan fuertes, aunque a veces compensa asumirlas

Ejemplo

- Problema

- Un 1 % de las mujeres de más de 40 años que se hacen un chequeo tienen cáncer de mama. Un 80 % de las que tienen cáncer de mama se detectan con una mamografía y el 9.6 % de las que no tienen cáncer de mama, al realizarse una mamografía se le diagnostica cáncer erróneamente

- Variables aleatorias: C (tener cáncer de mama) y M (mamografía positiva)

- Pregunta 1: ¿cuál es la probabilidad de tener cáncer si la mamografía así lo diagnostica?

- $P(C|m) = \alpha P(C, m) = \alpha P(m|C)P(C) = \alpha \langle P(m|c)P(c), P(m|\neg c)P(\neg c) \rangle = \alpha \langle 0,8 \cdot 0,01, 0,096 \cdot 0,99 \rangle = \alpha \langle 0,008, 0,09504 \rangle = \langle 0,0776, 0,9223 \rangle$

- Luego el 7.8 % de las mujeres diagnosticadas positivamente con mamografía tendrán realmente cáncer de mama

Ejemplo

- **Pregunta 2:** ¿cuál es la probabilidad de tener cáncer si tras dos mamografías consecutivas en ambas se diagnostica cáncer?
 - Variables aleatorias: M_1 (primera mamografía positiva) y M_2 (segunda mamografía positiva)
 - Obviamente, no podemos asumir independencia incondicional entre M_1 y M_2
 - Pero es plausible asumir independencia condicional de M_1 y M_2 *dada* C
 - Por tanto, $P(C|m_1, m_2) = \alpha P(C, m_1, m_2) = \alpha P(m_1, m_2|C)P(C) = \alpha P(m_1|C)P(m_2|C)P(C) = \alpha \langle P(m_1|c)P(m_2|c)P(c), P(m_2|\neg c)P(m_2|\neg c)P(\neg c) \rangle = \alpha \langle 0,8 \cdot 0,8 \cdot 0,01, 0,096 \cdot 0,096 \cdot 0,99 \rangle = \langle 0,412, 0,588 \rangle$
 - Luego aproximadamente el 41 % de las mujeres doblemente diagnosticadas positivamente con mamografía tendrán realmente cáncer de mama

Redes Bayesianas

- En general, las relaciones de independencia condicional permiten simplificar drásticamente las DCCs, haciendo que se puedan usar en la práctica
- Las Redes Bayesianas constituyen un método de representación de DCCs que explota las relaciones de independencia condicional
 - Permitiendo un tratamiento manejable de la inferencia probabilística
 - Es lo que veremos en el próximo tema

Bibliografía

- Russell, S. y Norvig, P. *Inteligencia artificial (Un enfoque moderno)* (Prentice–Hall Hispanoamericana, 1996)
 - Cap. 13: “Incertidumbre”