

Probabilidad Bayesiana: una lógica para razonar bajo incerteza

Sergio Davis^{1,2} <sergio.davis@cchen.cl>

¹Centro de Investigación en la Intersección de Física de Plasmas, Materia y Complejidad (P²mc),
Comisión Chilena de Energía Nuclear

²Departamento de Física y Astronomía, Facultad de Ciencias Exactas,
Universidad Andrés Bello







En Ciencia, deseamos obtener las mejores conclusiones usando información limitada.

El pensamiento científico:


- ▶ Tiene el rol de una herramienta para **evitar sesgos**
- ▶ Debe aspirar a **ser racional**: creencias que contradicen observaciones del mundo real deben ser abandonadas
- ▶ Necesita poder **cuantificar el grado de incerteza** que tenemos respecto a observaciones o experimentos

Dos modos de "razonamiento científico"

Deducción



Inferencia





En matemáticas:

Axiomas: Premisas que se asumen ciertas sin justificación, como la base de un sistema lógico

Teoremas: Conclusiones que se siguen de un conjunto de axiomas u otros teoremas establecidos previamente

Si las premisas son ciertas y la lógica se aplica correctamente, las conclusiones **deben ser ciertas**.

Inferencia

- ▶ Intenta entregar la mejor respuesta con información incompleta
- ▶ Construye y ajusta modelos en base a observaciones
- ▶ Evita entregar conclusiones fuera de lo justificado por los datos o experiencia



La inferencia **no puede asegurar** que sus respuestas sean correctas, sólo las afirma con un grado de credibilidad.

¿Vida en Marte?



¿Existe vida en Marte en este momento?
¿Cuán fuerte es su creencia respecto a esto?

Dígito 1024 de π : Google AI Overviews



cuál es el dígito 1024 de pi



All Images Videos Short videos Shopping Web News More Tools

AI Overview

El dígito número 1024 de pi es 6.



Las respuestas de la IA pueden contener errores. [Más información](#)



Dígito 1024 de π : Wolfram Alpha

FROM THE MAKERS OF WOLFRAM LANGUAGE AND MATHEMATICA



[//quantity:1024//] digit of Pi



NATURAL LANGUAGE

MATH INPUT

EXTENDED KEYBOARD

EXAMPLES

UPLOAD

RANDOM

Input interpretation

1024th digit

π

Nearby digits

...98938095257201065485863278865936153381827968230301...


Result

8

Download Page

POWERED BY THE WOLFRAM LANGUAGE

Probabilidad Bayesiana: el lenguaje de la inferencia



$P(A|\mathcal{I})$: Probabilidad de A dado \mathcal{I}

Bayesianos versus frecuentistas



Frecuentista: La probabilidad es la frecuencia con que ocurre un evento aleatorio

Bayesiano: La probabilidad es un grado de creencia racional basado en evidencia


Fundadores de la probabilidad Bayesiana



Thomas Bayes (1701 - 1761)



Pierre-Simon Laplace (1749 - 1827)



Harold Jeffreys (1891 - 1989)



Edwin Jaynes (1922 - 1998)

Las reglas de la probabilidad

Regla de la suma

$$P(A|\mathcal{I}) + P(\text{not } A|\mathcal{I}) = 1$$

Regla del producto

$$P(A \text{ and } B|\mathcal{I}) = P(A|B \text{ and } \mathcal{I})P(B|\mathcal{I})$$

Regla extendida de la suma

$$P(A \text{ or } B|\mathcal{I}) = P(A|\mathcal{I}) + P(B|\mathcal{I}) - P(A \text{ and } B|\mathcal{I})$$

¿Cómo actualizamos nuestras creencias?

Definiciones

H : Una hipótesis que quisiéramos validar o refutar,

E : Una evidencia, posiblemente relevante para la validez de H ,

\mathcal{I} : Un conocimiento base o previo, que no incorpora la evidencia E

Usando la regla del producto podemos escribir

$$P(H \text{ and } E|\mathcal{I}) = P(H|E \text{ and } \mathcal{I})P(E|\mathcal{I})$$

pero también es cierto que

$$P(E \text{ and } H|\mathcal{I}) = P(E|H \text{ and } \mathcal{I})P(H|\mathcal{I}).$$





Como $(H \text{ and } E) = (E \text{ and } H)$, podemos igualar ambos lados derechos,

$$P(H|E \text{ and } \mathcal{I})P(E|\mathcal{I}) = P(E|H \text{ and } \mathcal{I})P(H|\mathcal{I})$$

llegando finalmente a ...

El teorema de Bayes

$$P(H|E \text{ and } \mathcal{I}) = P(H|\mathcal{I}) \times \frac{P(E|H \text{ and } \mathcal{I})}{P(E|\mathcal{I})}$$



Es la regla universal para actualizar creencias **previas** a creencias **posteriores**,

$$P(H|\mathcal{I}) \rightarrow P(H|E \text{ and } \mathcal{I})$$

Dos casos interesantes

Caso 1: La hipótesis H es **falsable**, y de hecho predice que E es imposible.



¿Qué ocurre si E es observada? Se tiene que $P(E|H \text{ and } \mathcal{I}) = 0$
y por lo tanto

$$P(H|E \text{ and } \mathcal{I}) = P(H|\mathcal{I}) \times \frac{P(E|H \text{ and } \mathcal{I})}{P(E|\mathcal{I})} = 0 \implies \boxed{H \text{ es refutada por } E}$$

En este caso el teorema de Bayes se reduce a la aplicación de la lógica:

$(H \Rightarrow \text{not } E)$ es equivalente a $(E \Rightarrow \text{not } H)$

Dos casos interesantes

Caso 2: La hipótesis H predice que E será observada.



Periodic Table of Elements																	
H																	He
Li	Be											B	C	N	O	F	Ne
Na	Mg											Al	Si	P	S	Cl	Ar
K	Ca	Sc	Ti	V	Cr	Mn	Fe	Co	Ni	Cu	Zn	Ga	Ge	As	Se	Br	Kr
Rb	Sr	Y	Zr	Nb	Mo	Tc	Ru	Rh	Pd	Ag	Cd	In	Sn	Sb	Te	I	Xe
Cs	Ba	La	Ce	Pr	Nd	Pm	Sm	Eu	Gd	Tb	Dy	Ho	Er	Tm	Yb	Lu	Rn

¿Qué ocurre cuando E es de hecho observada? En este caso se tiene $P(E|H \text{ and } \mathcal{I}) = 1$ y $P(E|\mathcal{I}) < 1$, luego

$$P(H|E \text{ and } \mathcal{I}) = P(H|\mathcal{I}) \times \frac{P(E|H \text{ and } \mathcal{I})}{P(E|\mathcal{I})} > P(H|\mathcal{I})$$

⇒

H resulta favorecida por E

E no demuestra que H es cierta! Sólo la hace más probable.

Es imposible demostrar H definitivamente acumulando evidencia.

Distribución previa, posterior y verosimilitud

θ : Parámetros de un modelo

D : Datos que el modelo intenta describir

\mathcal{I} : Información previa a ver los datos

Distribución previa

Función verosimilitud

$$P(\boldsymbol{\theta}|D, \mathcal{I}) = \frac{P(\boldsymbol{\theta}|\mathcal{I})P(D|\boldsymbol{\theta}, \mathcal{I})}{P(D|\mathcal{I})}$$

Distribución posterior

Ejemplo 1: Lanzamiento de la moneda



Lanzamiento	Resultado
1	Cara
2	Sello
3	Cara
4	Cara
5	Sello
6	Cara
7	Sello
8	Cara
9	Cara
10	Cara
11	???

En $n = 10$ lanzamientos independientes se obtuvo 7 caras y 3 sellos.

- ▶ ¿Cuál es la probabilidad de obtener cara en el siguiente lanzamiento?
- ▶ ¿Cómo cambia la respuesta para 70 caras y 30 sellos? ($n = 100$)

Lanzamiento de la moneda: solución frecuentista


Se obtendrá cara con probabilidad p **en cada lanzamiento, independiente de los resultados previos**, y sello con probabilidad $1 - p$.

Si la moneda no está cargada, se tiene que $p = 0.5$.

La probabilidad de n_c caras en n intentos es binomial:

$$P(n_c | n, p) = \binom{n}{n_c} p^{n_c} (1 - p)^{n - n_c}$$

y se cumple que $n_c \approx np$ para $n \gg 1$.



Lanzamiento de la moneda: solución Bayesiana

Existe una probabilidad p desconocida de obtener cara, a la cual asignamos una **creencia inicial** \emptyset **plana**,

$$P(p|\emptyset) = \begin{cases} 1 & \text{si } 0 \leq p \leq 1, \\ 0 & \text{en caso contrario.} \end{cases}$$

Esta creencia cambiará al incluir los lanzamientos observados por medio del teorema de Bayes,

$$P(p|n_c, n) = P(p|\emptyset) \times \frac{P(n_c|n, p)}{P(n_c|n, \emptyset)}$$


Usamos la probabilidad binomial de n_c caras en n intentos,

$$P(n_c|n, p) = \binom{n}{n_c} p^{n_c} (1-p)^{n-n_c}.$$

Lanzamiento de la moneda: distribución posterior

La distribución posterior de p es entonces

$$P(p|n_c, n) = \frac{p^{n_c} (1-p)^{n-n_c}}{B(n_c+1, n-n_c+1)}$$




Valor más probable de p :

$$p^* = f := \frac{n_c}{n}$$

Lanzamiento de la moneda: probabilidad y frecuencia

$$\langle p \rangle_{n_c, n} \approx f \quad \frac{\langle (\delta p)^2 \rangle_{n_c, n}}{\langle p \rangle_{n_c, n}^2} \approx \left(\frac{1-f}{f} \right) \frac{1}{n} \rightarrow 0$$




$$\lim_{n \rightarrow \infty} P(p|n_c, n) = \delta(p - f)$$


¿Está cargada la moneda?

Si decimos que la moneda está cargada si $p < 0.4$ o si $p > 0.6$...

$$P(0.4 \leq p \leq 0.6 | n, f) = \int_{0.4}^{0.6} dp \frac{p^{nf} (1-p)^{n(1-f)}}{B(nf+1, (1-f)n+1)}$$



Ejemplo 2: Apagones



$$P(n|\lambda) = \frac{\exp(-\lambda)\lambda^n}{n!}$$

- ▶ En una cuadra ocurrieron $n = 5$ apagones durante el mes de febrero.
- ▶ Suponga que cada mes el número de apagones sigue la misma distribución de Poisson.

¿Cuál es la probabilidad de tener uno o más apagones durante marzo?

Apagones


La probabilidad de n apagones para una distribución Poisson es

$$P(n|\lambda) = \frac{\exp(-\lambda)\lambda^n}{n!}$$

donde λ es el parámetro que controla el valor medio de n .

Usamos el teorema de Bayes para obtener la **distribución posterior** de λ


$$\begin{aligned} P(\lambda|n) &= P(\lambda|\emptyset) \times \frac{P(n|\lambda)}{P(n|\emptyset)} \\ &= \frac{\exp(-\lambda)\lambda^{n-1}}{(n-1)!} \end{aligned}$$



Apagones

Finalmente, la **distribución predictiva** de m apagones en marzo dado n en febrero considera todos los valores de λ posibles,

$$P(m|n) = \int_0^\infty d\lambda P(m|\lambda)P(\lambda|n) = \int_0^\infty d\lambda \frac{\exp(-2\lambda)\lambda^{m+n-1}}{(m!)(n-1)!}$$



Distribución binomial negativa


$$P(m|n) = \frac{(m+n-1)!}{2^{m+n}(m!)(n-1)!}$$

$$\langle m \rangle_n = n$$

$$P(m=0|n) = \frac{1}{2^n} \implies P(m \geq 1|n) = 1 - \frac{1}{2^n} \quad (96.875\%)$$

Ejemplo 3: Cuenta de la luz

Costo total = (Costo por kWh) \times Consumo + (Costo base) + Variaciones



$$Y = \underbrace{AX + B}_{\text{dependencia lineal}} + \underbrace{\varepsilon}_{\text{incerteza}}$$

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

¿Cuál es la mejor recta que representa a los datos?

Regresión lineal Bayesiana

Suponiendo que la incerteza \mathcal{E} sobre Y sigue una distribución normal,

$$P(\mathcal{E}|\sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{\mathcal{E}^2}{2\sigma^2}\right)$$

luego las cantidades desconocidas son A , B y σ , y el teorema de Bayes dice

$$P(A, B, \sigma|D) = P(A, B, \sigma|\emptyset) \times \frac{P(D|A, B, \sigma)}{P(D|\emptyset)}$$

Como las observaciones son independientes, la función verosimilitud es

$$P(D|A, B, \sigma) = \prod_{i=1}^n P(y_i|x_i, A, B, \sigma) \times P(x_i|\emptyset).$$

Regresión lineal Bayesiana

$$P(D|A, B, \sigma) = \prod_{i=1}^n P(y_i|x_i, A, B, \sigma) \times P(x_i|\emptyset).$$

La probabilidad de y_i dado x_i es la probabilidad de observar una desviación

$$\mathcal{E}_i = y_i - (Ax_i + B),$$

que es normal, luego se tiene


$$P(y_i|x_i, A, B, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(y_i - Ax_i - B)^2\right).$$

y la función verosimilitud es

$$P(D|A, B, \sigma) = \frac{1}{(\sqrt{2\pi})^n \sigma^n} \left[\prod_{i=1}^n P(x_i|\emptyset) \right] \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - Ax_i - B)^2\right).$$

Regresión lineal Bayesiana

$$P(A, B, \sigma | D) \propto \frac{1}{\sigma^{n+1}} \exp \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n \left(y_i - [Ax_i + B] \right)^2 \right)$$



$$\mathbb{E}^2(A, B) := \sum_{i=1}^n \left(\underbrace{y_i}_{\text{dato}} - \underbrace{[Ax_i + B]}_{\text{predicción}} \right)^2$$

¡La recta más probable es la que minimiza el error cuadrático!

Regresión lineal

Definiendo $s_x := \sqrt{x^2 - (\bar{x})^2}$, la distribución de A y B dado σ es normal,

$$P(A|\sigma, D) = \frac{1}{\sqrt{2\pi}\sigma_A} \exp\left(-\frac{1}{2\sigma_A^2}(A - A^*)^2\right)$$

$$P(B|\sigma, D) = \frac{1}{\sqrt{2\pi}\sigma_B} \exp\left(-\frac{1}{2\sigma_B^2}(B - B^*)^2\right)$$

donde los valores más probables de A y B corresponden a la solución tradicional de mínimos cuadrados,

$$A^* = \frac{\overline{xy} - \bar{x}\bar{y}}{x^2 - \bar{x}^2}$$

$$B^* = \bar{y} - A^*\bar{x}$$

La incerteza sobre A y B decrece como $1/\sqrt{n}$ al aumentar el número de puntos,

$$\sigma_A := \frac{\sigma}{\sqrt{ns_x}}, \quad \sigma_B := \frac{\sigma}{\sqrt{ns_x}} \times \sqrt{x^2}.$$

Conclusiones

- ▶ La probabilidad Bayesiana es una extensión de la lógica tradicional que permite incorporar incerteza
- ▶ Es posible construir y analizar modelos usando inferencia Bayesiana en todas las áreas de la Ciencia
- ▶ Este enfoque es particularmente útil cuando se trata con un número pequeño de observaciones, o con eventos que no se repiten



Agradecimientos al proyecto
ANID FONDECYT 1220651 (Chile)

