

Inferência Bayesiana

Joaquim Neto

joaquim.neto@ufjf.edu.br

www.ufjf.br/joaquim_netto

Departamento de Estatística - ICE
Universidade Federal de Juiz de Fora

Versão 1.0 - 2010

Sumário

1 Informações gerais

- Contato
- Referências Bibliográficas

2 Introdução à probabilidade

- Espaço amostral
- Eventos
- Definições de probabilidade
- Disjuntos 2 a 2 e conjunto das partes
- Evento aleatório
- Axiomas de probabilidade
- Espaço de probabilidade
- Proposições

3 Probabilidade condicional

- Teorema da Multiplicação
- Teorema da Probabilidade Total

4 Revisão: normal multivariada

5 Introdução à inferência bayesiana

- O paradigma bayesiano
- Quem foi Thomas Bayes?
- Teorema de Bayes
- Densidade conjunta, marginal e condicional
- Função de verossimilhança e distribuição a priori
- A distribuição a posteriori e a inferência paramétrica
- Núcleo e constante de proporcionalidade
- Constante de proporcionalidade da posteriori
- Verossimilhança marginal
- Distribuição preditiva

6 Exemplos

- Regressão linear simples
- Regressão não linear
- Ponto de mudança
- Modelo hierárquico
- Modelo linear generalizado
- Análise de sobrevivência

- 7 Conjugação
- 8 Algoritmos de simulação
- 9 Algoritmos de simulação
 - Condicionais completas
 - Amostrador de Gibbs
 - Metropolis-Hastings
- 10 Introdução a teoria da decisão

Informações gerais

E-mail

joaquim.neto@ufjf.edu.br

Site pessoal

http://www.ufjf.br/joaquim_neto

Site do Departamento de Estatística (UFJF)

<http://www.ufjf.br/estatistica>

Referências Bibliográficas



Barry, R. James

(1981)

Probabilidade: um curso em nível intermediário.

Rio de Janeiro: Instituto de Matemática Pura e Aplicada (Projeto Euclides).



Degroot, M. H. & Schervish, M. J.

(2001)

Probability and Statistics, 3rd Edition, 3rd edn.

Addison Wesley.



Gamerman, D. & Lopes, H. F.

(2006)

Markov Chain Monte Carlo - Stochastic Simulation for Bayesian Inference, 2nd edn.

Chapman & Hall.



Pena, Sérgio Danilo

(2006)

Thomas.

Revista Ciência Hoje, 38, no. 228, 22–29.



Turnbull, Bruce W., Bryon Wm. Brown, Jr. & HU, Marie

(1974)

Survivorship analysis of heart transplant data.

Journal of the American Statistical Association, 69, no. 345, 74–80.

Introdução à probabilidade

Espaço amostral

Definição 1: *Suponhamos um experimento realizado sob certas condições fixas. O **espaço amostral** Ω do experimento é um conjunto que contém representações de todos os resultados possíveis, onde por “resultado possível”, entende-se resultado elementar e indivisível do experimento. Ω deve satisfazer as seguintes condições:*

- *A todo resultado possível corresponde um, e somente um, elemento $\omega \in \Omega$.*
- *Resultados distintos correspondem a elementos distintos em Ω , ou seja, $\omega \in \Omega$ não pode representar mais de um resultado.*

Eventos

Quando se realiza um experimento, há certos eventos que ocorrem ou não. Por exemplo, ao jogar um dado e observar o resultado, alguns eventos são:

- observar um número par,
- observar o número 2,
- observar um número maior ou igual a 4,
- etc ...

Todo evento associado a um experimento pode ser identificado a um subconjunto do espaço amostral Ω . Reciprocamente, todo subconjunto A de Ω pode ser associado ao evento “resultado do experimento pertence a A ”. Assim, podemos associar

- o conjunto $\{2, 4, 6\}$ ao evento observar um número par,
- o conjunto $\{2\}$ ao evento observar um número 2
- e o conjunto $\{4, 5, 6\}$ ao evento observar um número maior ou igual a 4.

Definição 2: *Seja Ω o espaço amostral do experimento. Todo subconjunto $A \subset \Omega$ será chamado **evento**. Ω é o evento certo e \emptyset é o evento impossível. Se $\omega \in \Omega$, o evento $\{\omega\}$ é dito **elementar** (ou **simples**).*

Definições de probabilidade

Definição clássica de probabilidade

Se Ω é finito, a definição clássica da probabilidade $P(A)$ de um evento $A \subset \Omega$ é dada por

$$P(A) = \frac{\#A}{\#\Omega} = \frac{\text{número de elementos de } A}{\text{número de elementos de } \Omega}.$$

Esta definição basea-se no conceito de resultados equiprováveis, ou melhor, no princípio da indiferença. Por exemplo, em um experimento que consiste em lançar um dado e observar o resultado, podemos usar $\Omega = \{1, 2, \dots, 6\}$ e, diante da indiferença entre os resultados, temos $P(\{i\}) = \frac{1}{6}$, $\forall i \in \Omega$.

Exemplo 1: *Suponhamos um experimento que consiste em retirar uma carta em um baralho. Usando a definição clássica de probabilidade, qual é a probabilidade de tirar um 7?*

Solução: *Suponhamos que*

$$\Omega = \{A\heartsuit, 2\heartsuit, \dots, J\clubsuit, K\clubsuit\}$$

é o nosso espaço amostral e que

$$A = \{7\clubsuit, 7\diamondsuit, 7\heartsuit, 7\spadesuit\}$$

é o nosso evento de interesse.

Assim,

$$P(A) = \frac{\#A}{\#\Omega} = \frac{4}{52}.$$

Definição frequentista de probabilidade

Outro método de definir a probabilidade $P(A)$ de um evento A é usando o limite da frequência relativa da ocorrência de A em n repetições independentes do experimento, com n tendendo ao infinito, ou seja,

$$P(A) = \lim_{n \rightarrow \infty} \frac{1}{n} \times \left(\begin{array}{c} \text{número de ocorrências de } A \text{ em } n \text{ realizações} \\ \text{independentes do experimento} \end{array} \right)$$

Esta é a **definição frequentista de probabilidade**.

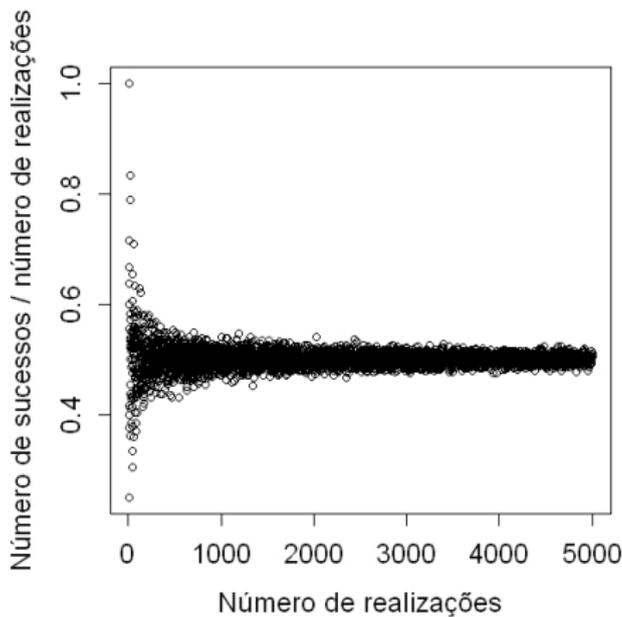


Figura: Número de arremessos de uma moeda honesta versus proporções de coroas obtidas.

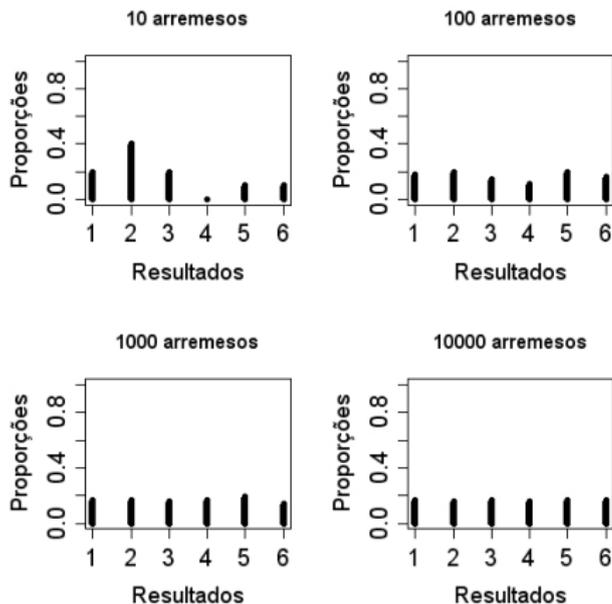


Figura: Proporção de resultados em 10, 100, 1000 e 10000 arremessos de um dado.

Probabilidade geométrica

Consideremos um experimento que consiste em escolher um ponto ao acaso no círculo unitário. Podemos definir a probabilidade $P(A)$ de um evento A como

$$P(A) = \frac{\text{área de } A}{\text{área de } \Omega} = \frac{\text{área de } A}{\pi}.$$

Acontece, que nem todo subconjunto de Ω tem área bem definida, ou seja, nem todo evento teria uma probabilidade (hipótese do contínuo).

Disjuntos 2 a 2 e conjunto das partes

Definição 3: Os conjuntos A_1, A_2, \dots são **disjuntos 2 a 2**, se $A_i \cap A_j = \emptyset$, $\forall i \neq j$.

Definição 4: O **conjunto das partes** $\mathcal{P}(A)$ de um conjunto A é definido por

$$\mathcal{P}(A) = \{B \mid B \subset A\}$$

Exemplo 2: Se $A = \{3, 5, 7\}$, então

$$\mathcal{P}(A) = \{\{3\}, \{5\}, \{7\}, \{3, 5\}, \{3, 7\}, \{5, 7\}, \{3, 5, 7\}, \emptyset\}$$

Definição 5: *Um evento A ao qual atribuímos probabilidade é chamado de evento aleatório.*

Axiomas de probabilidade

Não vamos nos preocupar, doravante, com o problema de como definir probabilidade para cada experimento. Simplesmente, vamos admitir que as probabilidades estão definidas em um certo conjunto \mathcal{A}^1 de eventos, chamados de eventos aleatórios. Vamos supor que a todo $A \in \mathcal{A}$ seja associado um número real $P(A)$, chamado de probabilidade de A , de modo que os axiomas a seguir sejam satisfeitos.

- **Axioma 1:** $P(A) \geq 0, \forall A \in \mathcal{A}$
- **Axioma 2:** $P(\Omega) = 1$
- **Axioma 3:** Se $A_1, A_2, \dots \in \mathcal{A}$ são disjuntos 2 a 2, então

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n)$$

¹Geralmente usamos $\mathcal{A} = \mathcal{P}(\Omega)$. Para saber mais sobre restrições de \mathcal{A} , consulte Barry (1981).

Espaço de probabilidade

Definição 6: Um **espaço de probabilidade**² é um trio (Ω, \mathcal{A}, P) , onde

- Ω é um conjunto não vazio e
- P é uma probabilidade em \mathcal{A} .

²Para saber mais sobre restrições de \mathcal{A} , consulte Barry (1981).

Proposições

Proposição 1: $P(\emptyset) = 0$.

Prova: *Temos que*

$$P(\Omega) = P(\Omega \cup \emptyset \cup \emptyset \cup \dots) \Rightarrow$$

$$P(\Omega) = P(\Omega) + P(\emptyset) + P(\emptyset) + \dots \Rightarrow$$

$$0 = P(\emptyset) + P(\emptyset) + \dots$$

Proposição 2: Se $A_1, A_2, \dots, A_n \in \mathcal{A}$ são disjuntos 2 a 2 então

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i)$$

Prova:

Outros resultados de probabilidade são:

- $P(A^c) = 1 - P(A)$
- $A_1 \subset A_2 \Rightarrow P(A_1) \leq P(A_2)$
- $0 \leq P(A) \leq 1$
- $P\left(\bigcup_{i=1}^n A_i\right) \leq \sum_{i=1}^n P(A_i)$
- $P\left(\bigcup_{i=1}^{\infty} A_i\right) \leq \sum_{i=1}^{\infty} P(A_i)$
- $P(A_1 \cap A_2^c) = P(A_1) - P(A_1 \cap A_2)$

Probabilidade condicional

Definição 7: *Seja (Ω, \mathcal{A}, P) um espaço de probabilidade. Se $B \in \mathcal{A}$ e $P(B) > 0$, a probabilidade condicional de $A \in \mathcal{A}$ dado B é definida por*

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

OBS:

- Se $P(B) = 0$, $P(A|B)$ pode ser arbitrariamente definida. Mas, por independência, é conveniente fazer $P(A|B) = P(A)$, como veremos adiante.
- Decorre da definição que $P(A \cap B) = P(B)P(A|B)$, e esta igualdade também é válida quando $P(B) = 0$ (verifique!).

Exemplo 3: *Considere um experimento que consiste em retirar 2 cartas do baralho, ao acaso e sem reposição. Usando a definição clássica de probabilidade, qual a probabilidade de tirar um rei na segunda extração dado que foi obtido um rei na primeira extração?*

Passos para a solução:

- *Defina o espaço amostral.*
- *Defina os eventos de interesse.*
- *Use a fórmula de probabilidade condicional.*

Solução:

Teorema da Multiplicação

Teorema 1: *Seja (Ω, \mathcal{A}, P) um espaço de probabilidade com $A_1, A_2, \dots, A_N \in \mathcal{A}$. Então*

$$\begin{aligned} P(A_1 \cap A_2 \cap \dots \cap A_N) &= P(A_N | A_1 \cap \dots \cap A_{N-1}) \\ &\times P(A_{N-1} | A_1 \cap \dots \cap A_{N-2}) \\ &\times \dots \times \\ &\times P(A_2 | A_1) P(A_1) \end{aligned}$$

Em particular, para $N = 2$, temos

$$P(A_1 \cap A_2) = P(A_2 | A_1)P(A_1) = P(A_1 | A_2)P(A_2).$$

Exemplo 4: *Considere um experimento que consiste em retirar 2 cartas do baralho, ao acaso e sem reposição. Usando a definição clássica de probabilidade, qual a probabilidade de tirar dois reis?*

Passos para a solução:

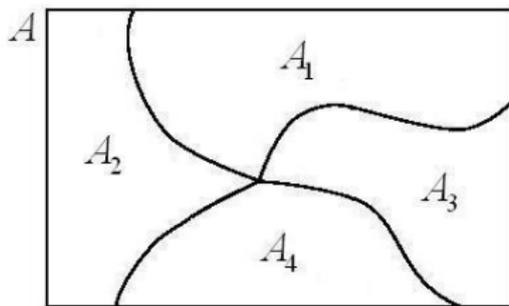
- *Defina o espaço amostral.*
- *Defina os eventos de interesse.*
- *Use o Teorema da Multiplicação.*

Solução:

Partição

Definição 8: Uma sequência A_1, A_2, \dots finita ou enumerável de conjuntos é uma partição de um conjunto A quando

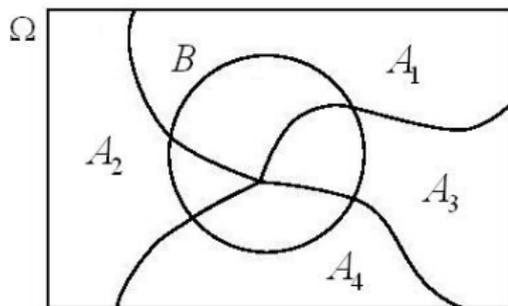
- for uma sequência de conjuntos disjuntos 2 a 2 e
- $\bigcup_i A_i = A$.



Teorema da Probabilidade Total

Teorema 2: Seja (Ω, \mathcal{A}, P) um espaço de probabilidade. Se a sequência (finita ou enumerável) $A_1, A_2, \dots, A_N \in \mathcal{A}$ formar uma partição de Ω , então

$$P(B) = \sum_i P(B|A_i) P(A_i)$$



Exemplo 5: *Considere um experimento que consiste em retirar 2 cartas do baralho, ao acaso e sem reposição. Usando a definição clássica de probabilidade, qual a probabilidade de tirar um rei na segunda extração?*

Passos para a solução:

- *Defina o espaço amostral.*
- *Defina os eventos de interesse.*
- *Use o Teorema da Probabilidade Total.*

Solução:

Revisão: normal multivariada

Façamos uma breve revisão da distribuição normal multivariada.

Definição 9: *Seja Σ uma matriz $p \times p$ positiva definida. Dizemos que um vetor aleatório $Y = (Y_1, \dots, Y_p)$ tem distribuição normal multivariada (de dimensão p) com vetor de médias $\mu = (\mu_1, \dots, \mu_p)^T$ e matriz de covariâncias Σ , se sua densidade for*

$$p(y \mid \mu, \Sigma) = (2\pi)^{-\frac{p}{2}} (\det(\Sigma))^{-\frac{1}{2}} \exp\left(-0.5 (\mathbf{y} - \mu)^T \Sigma^{-1} (\mathbf{y} - \mu)\right),$$

onde $\mathbf{y} = (y_1, \dots, y_p) \in \mathbb{R}^p$ e $\det(\Sigma)$ é o determinante de Σ . Se $p = 1$, dizemos que a distribuição é normal univariada e, se $p = 2$, normal bivariada.

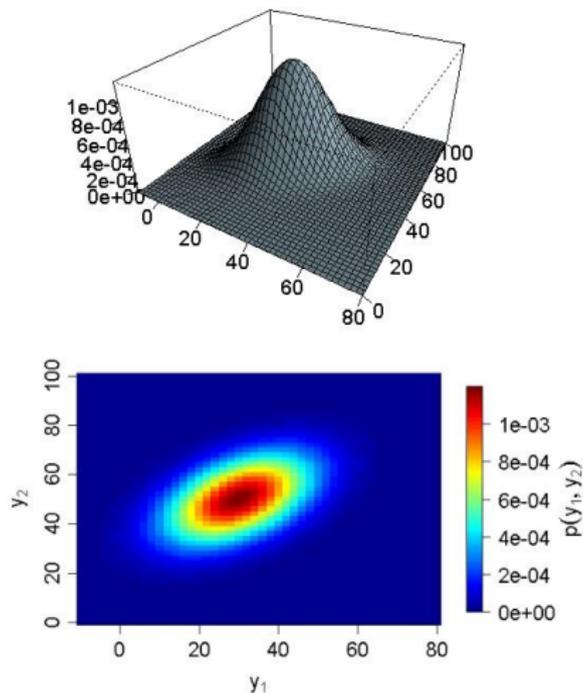


Figura: Densidade da normal bivariada com vetor de médias $\mu = [30, 50]^T$ e matriz de covariâncias $\Sigma = \begin{bmatrix} 150 & 70 \\ 70 & 150 \end{bmatrix}$

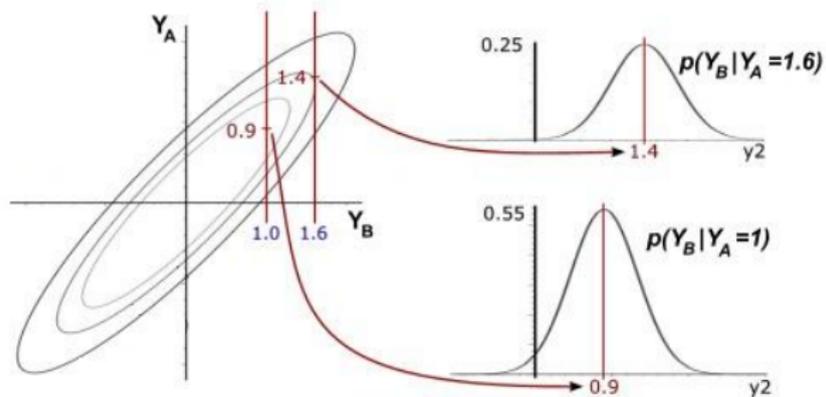


Figura: Distribuição condicional.

Suponhamos as partições

$$Y = \begin{bmatrix} Y_A \\ Y_B \end{bmatrix}, \quad \mu = \begin{bmatrix} \mu_A \\ \mu_B \end{bmatrix} \quad \text{e} \quad \Sigma = \begin{bmatrix} \Sigma_{A,A} & \Sigma_{A,B} \\ \Sigma_{B,A} & \Sigma_{B,B} \end{bmatrix}.$$

A distribuição condicional de Y_B dado Y_A é normal multivariada com vetor de médias

$$\mu_{B|A} = \mu_B + \Sigma_{B,A} \Sigma_{A,A}^{-1} (Y_A - \mu_A)$$

e matriz de covariâncias

$$\Sigma_{B|A} = \Sigma_{B,B} - \Sigma_{B,A} \Sigma_{A,A}^{-1} \Sigma_{A,B}.$$

Exercício 1: Use o software *R* para plotar a densidade de uma distribuição normal bivariada qualquer.

Introdução à inferência bayesiana

O paradigma bayesiano

O pároco de um vilarejo da Inglaterra do século 18, até certo ponto obscuro em seu tempo, é hoje festejado e considerado avançado nos meios científicos atuais, tudo por ter escrito um pequeno ensaio sobre probabilidade. O processo de raciocínio idealizado por Thomas Bayes neste texto, que ele mesmo sequer levou a público, é tido hoje como uma novo paradigma na estatística e como a base de uma verdadeira revolução em diferentes campos do conhecimento, da genética à teologia. Mas o que é o raciocínio bayesiano e por que vem ganhando tanto prestígio?

Ao visitar o campus de uma universidade norte-americana, é provável que encontre estudantes usando camisetas com a inscrição Bayes rules! A tradução para o português seria algo como “Bayes é o ‘cara’!” (em inglês, a frase contém um trocadilho). Curioso, você decide checar quem é esse Bayes e o melhor lugar para isso é certamente a internet. Ao digitar o nome “Bayes” em uma página de busca, descobre-se que o nome completo dele é Thomas Bayes, que há um teorema de Bayes e que esse nome é citado (em junho de 2006) em nada menos que 9.3 milhões de páginas de internet! Se usarmos a palavra inglesa bayesian (bayesiano), o total de páginas sobe para 23.2 milhões.

Quem foi Thomas Bayes?

Considerando sua imensa importância na estatística, sabemos pouco sobre Thomas Bayes.

- Ele foi um reverendo presbiteriano que viveu no início do século 18 na Inglaterra.
- Estudou teologia na Universidade de Edimburgo (Escócia), de onde saiu em 1722.
- Em 1731 assumiu a paróquia de Tunbridge Wells, no condado de Kent, a 58 km de Londres. Neste mesmo ano, apareceu na Inglaterra um livro anônimo, hoje creditado a Bayes, chamado Benevolência divina.
- Cinco anos depois, publicou seu primeiro e único livro de matemática, chamado “*The doctrine of fluxions*” (A doutrina dos fluxions³).
- Com base nesse livro e em outras possíveis contribuições sobre as quais não temos dados precisos, Bayes foi eleito em 1752 para a Real Sociedade, entidade científica britânica criada em 1645.
- Dois anos após sua morte, um amigo, o filósofo Richard Price (1723-1791), apresentou à Real Sociedade um artigo que aparentemente encontrou entre os papéis do reverendo, com o nome “*An essay towards solving a problem in the doctrine of chances*” (Ensaio buscando resolver um problema na doutrina das probabilidades). Neste artigo estava a demonstração do famoso teorema de Bayes. Após sua publicação, o trabalho caiu no esquecimento, do qual só foi resgatado pelo matemático francês Pierre-Simon de Laplace (1749-1827), que o revelou ao mundo.

³O nome *fluxion* foi dado pelo matemático e físico Isaac Newton (1642-1727) para a derivativa de uma função contínua (que Newton chamava de *fluent*).



Figura: O reverendo Thomas Bayes na única representação que existe dele.

Teorema de Bayes

Teorema 3: *Seja (Ω, \mathcal{A}, P) um espaço de probabilidade. Se a sequência (finita ou enumerável) $A_1, A_2, \dots, A_N \in \mathcal{A}$ formar uma partição de Ω , então*

$$P(A_i|B) = \frac{P(B|A_i) P(A_i)}{\sum_j P(B|A_j) P(A_j)}$$

Exemplo 6 (probabilidade subjetiva): *Uma pessoa vai ao médico reclamando de dores. Após uma detalhada conversa e um cuidadoso exame físico, o médico acredita que o paciente pode ter uma determinada doença.*

Seja θ uma quantidade desconhecida que indica se o paciente tem a doença ou não. Se ele possui a doença então $\theta = 1$, caso contrário $\theta = 0$. Subjetivamente, o médico assume que $P(\theta = 1|H) = 0.6$, onde H representa toda a informação disponível até a consulta. Para simplificar, iremos omitir H fazendo $P(\theta = 1|H) = P(\theta = 1) = 0.6$.

Um pouco antes do fim da consulta, o médico prescreve um exame laboratorial. Seja X uma variável associada ao resultado deste exame, de modo que $X = 1$ se o exame acusa a doença e $X = 0$ caso contrário. O exame fornece um resultado incerto com as seguintes probabilidades

$$P(X = 1 | \theta = 0) = 0.10 \quad \text{e} \quad P(X = 1 | \theta = 1) = 0.95$$

Suponhamos que o resultado do exame tenha acusado a doença, $X = 1$. Assim, para o médico, a probabilidade do paciente ter a doença passa a ser

$$\begin{aligned} P(\theta = 1 | X = 1) &= \frac{P(X = 1 | \theta = 1)P(\theta = 1)}{P(X = 1 | \theta = 1)P(\theta = 1) + P(X = 1 | \theta = 0)P(\theta = 0)} \\ &= \frac{0.95 \times 0.6}{0.95 \times 0.6 + 0.1 \times 0.4} = 0.9344262. \end{aligned}$$

Exemplo 7: *Recomenda-se que, a partir dos 40 anos, as mulheres façam mamografias anuais. Nesta idade, 1% das mulheres são portadoras de um tumor assintomático de mama.*

Seja θ uma quantidade desconhecida que indica se uma paciente (desta faixa etária) tem a doença ou não. Se ela possui a doença, então $\theta = 1$, caso contrário, $\theta = 0$. Assim, podemos assumir que

$$P(\theta = 1) = 0.01 \quad \text{e} \quad P(\theta = 0) = 0.99.$$

Sabe-se que a mamografia indica a doença em 80% das mulheres com câncer de mama, mas esse mesmo resultado ocorre também com 9.6% das mulheres sem o câncer. Assim, seja X uma variável aleatória associada ao resultado da mamografia, de modo que se $X = 1$ o exame acusou a doença e $X = 0$ caso contrário. Temos então que

$$P(X = 1 \mid \theta = 0) = 0.096$$

$$P(X = 1 \mid \theta = 1) = 0.80$$

Imagine agora que você encontra uma amiga de 40 e poucos anos aos prantos, desesperada, porque fez uma mamografia de rotina e o exame acusou a doença. Qual a probabilidade de ela ter um câncer de mama?

Solução: Temos que

$$\begin{aligned}P(\theta = 1 | X = 1) &= \frac{P(X = 1 | \theta = 1)P(\theta = 1)}{P(X = 1 | \theta = 1)P(\theta = 1) + P(X = 1 | \theta = 0)P(\theta = 0)} \\ &= \frac{0.80 \times 0.01}{0.80 \times 0.01 + 0.096 \times 0.99} = 0.07763975\end{aligned}$$

Logo, a probabilidade dela ter a doença é de aproximadamente 7.8%.

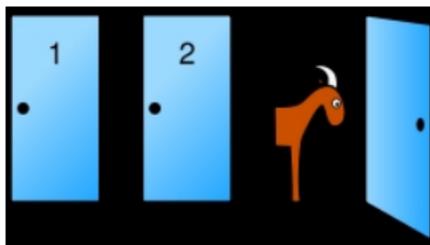
Ao apresentar este problema a várias pessoas, inclusive estudantes de medicina, observa-se uma tendência a superestimar a probabilidade a posteriori da doença. Isso revela que o raciocínio bayesiano não é intuitivo. Parece haver uma tendência geral a ignorar o fato de que a probabilidade a priori de doença é pequena, fenômeno denominado “falácia da probabilidade de base” pelo psicólogo norte-americano (de origem israelense) Daniel Kahneman, premiado com o Nobel de Economia em 2002 por estudos sobre o comportamento de investidores. Num sentido específico: “as pessoas não são racionais”.

Exemplo 8: O problema de Monty Hall é um problema matemático que surgiu a partir de um concurso televisivo dos Estados Unidos da América chamado *Let's Make a Deal*, exibido na década de 1970.

O jogo consiste no seguinte: Monty Hall (o apresentador) apresentava 3 portas aos concorrentes, sabendo que atrás de uma delas está um carro (prêmio bom) e que as outras têm prêmios de pouco valor.

- 1 Na 1ª etapa o concorrente escolhe uma porta (que ainda não é aberta).
- 2 Em seguida, Monty abre uma das outras duas portas que o concorrente não escolheu, sabendo que o carro não se encontra nela.
- 3 Agora, com duas portas apenas para escolher e sabendo que o carro está atrás de uma delas, o concorrente tem que se decidir se permanece com a porta que escolheu no início do jogo e abre-a ou se muda para a outra porta que ainda está fechada para então a abrir.

Neste caso, existe uma estratégia mais lógica? Ficar com a porta escolhida inicialmente ou mudar de porta? Será que com alguma das portas ainda fechadas o concorrente tem mais probabilidades de ganhar? Por que?



O problema de Monty Hall demonstra muito bem como nossa intuição é falha em certos problemas que envolvem chances. Felizmente, pode-se resolver o problema de Monty Hall de forma simples e sem erro usando o teorema de Bayes.

Justificativa pelo Teorema de Bayes: Consideremos os eventos

- A_1 = “Carro está na primeira porta”,
- A_2 = “Carro está na segunda porta”,
- A_3 = “Carro está na terceira porta” e
- C = “O apresentador abre a terceira porta”.

Naturalmente, iremos assumir $P(C | A_1) = 0.5$, $P(C | A_2) = 1$ e $P(C | A_3) = 0$. Assim, pelo teorema da probabilidade total, temos

$$\begin{aligned} P(C) &= P(C|A_1)P(A_1) + P(C|A_2)P(A_2) + P(C|A_3)P(A_3) = \\ &= \frac{1}{2} \cdot \frac{1}{3} + 1 \cdot \frac{1}{3} + 0 \cdot \frac{1}{3} = \frac{1}{2} = 0.5 \end{aligned}$$

Agora, usando o teorema de Bayes, temos

$$\begin{aligned} P(A_1 | C) &= \frac{P(C | A_1)P(A_1)}{P(C)} = \frac{\frac{1}{2} \times \frac{1}{3}}{\frac{1}{2}} = \frac{1}{3}, \\ P(A_2 | C) &= \frac{P(C | A_2)P(A_2)}{P(C)} = \frac{1 \times \frac{1}{3}}{\frac{1}{2}} = \frac{2}{3} \quad \text{e} \\ P(A_3 | C) &= \frac{P(C | A_3)P(A_3)}{P(C)} = \frac{0 \times \frac{1}{3}}{\frac{1}{2}} = 0. \end{aligned}$$

Portanto, escolhendo trocar de porta a chance de ganhar o carro é maior.

Densidade conjunta, marginal e condicional

Sejam \mathbf{X} e \mathbf{Y} vetores aleatórios com densidades $p(x)$ e $p(y)$, respectivamente. Suponhamos ainda que $p(\mathbf{x}, \mathbf{y})$ é a densidade conjunta do vetor (\mathbf{X}, \mathbf{Y}) e $p(\mathbf{x} | \mathbf{y})$ é a densidade da distribuição de \mathbf{Y} dado \mathbf{X} . Uma importante equação relaciona estas densidades:

$$p(\mathbf{x} | \mathbf{y}) = \frac{p(\mathbf{x}, \mathbf{y})}{p(\mathbf{y})} \quad (\text{probabilidade condicional}).$$

Já a densidade da distribuição marginal de \mathbf{X} pode ser obtida com

$$p(\mathbf{x}) = \int p(\mathbf{x}, \mathbf{y}) d\mathbf{y} = \int p(\mathbf{x} | \mathbf{y}) p(\mathbf{y}) d\mathbf{y} \quad (\text{teorema da probabilidade total}).$$

Temos ainda a seguinte relação

$$p(\mathbf{y} | \mathbf{x}) = \frac{p(\mathbf{x} | \mathbf{y}) p(\mathbf{y})}{\int p(\mathbf{x} | \mathbf{y}) p(\mathbf{y}) d\mathbf{y}} \quad (\text{teorema de Bayes}).$$

OBS: Para distribuições discretas, as integrais acima assumem a forma de somatórios.

Função de verossimilhança e distribuição a priori

Suponhamos agora que um modelo probabilístico é utilizado para representar matematicamente a aleatoriedade inerente às observações y_1, \dots, y_n . Suponhamos ainda que este modelo depende de um vetor paramétrico θ . Em outras palavras, consideremos um problema típico de inferência paramétrica.

Seguindo o paradigma bayesiano, informações prévias sobre θ são representadas matematicamente usando uma distribuição de probabilidade, chamada de **distribuição a priori** (ou simplesmente **priori**), que estabelece (pondera) quais valores de θ são mais prováveis, segundo informações disponíveis antes de conhecer as observações. Uma distribuição a priori deve então representar a informação do pesquisador sobre θ antes de conhecer as observações.

OBS: A priori não é uma distribuição para θ , uma vez que este é fixo, mas sim uma distribuição que representa a incerteza do pesquisador diante do valor desconhecido θ . No entanto, num abuso de linguagem e notação, é comum dizermos “priori para θ ” e usarmos $p(\theta)$ para a densidade de θ , por exemplo.

A distribuição a posteriori e a inferência paramétrica

A distribuição condicional de θ dado um conjunto de observações y_1, \dots, y_n é chamada de **distribuição a posteriori** (ou simplesmente **posteriori**) de θ . A densidade ou função de probabilidade da posteriori será denotada por $p(\theta | y_1, \dots, y_n)$.

Pelo teorema de Bayes, temos que a posteriori pode ser obtida com

$$\begin{aligned} p(\theta | y_1, \dots, y_n) &= \frac{p(y_1, \dots, y_n | \theta) p(\theta)}{p(y_1, \dots, y_n)} \\ &= \frac{p(y_1, \dots, y_n | \theta) p(\theta)}{\int p(y_1, \dots, y_n | \theta) p(\theta) d\theta} \end{aligned}$$

OBS: Naturalmente, no caso discreto a integral acima assume a forma de um somatório.

Núcleo e constante de proporcionalidade

Definição 10: Se uma densidade (ou função de probabilidade) $p(\mathbf{x} | \theta)$ for escrita como $p(\mathbf{x} | \theta) = f(\theta)g(\mathbf{x}, \theta)$, onde f é uma função de θ (apenas) e g é uma função de (\mathbf{x}, θ) , diremos que $g(\mathbf{x}, \theta)$ e $f(\theta)$ são, respectivamente, um **núcleo** e uma **constante de proporcionalidade** de $p(\mathbf{x} | \theta)$.

A partir do núcleo de uma densidade (ou f.p.) $p(\mathbf{x} | \theta)$, podemos obter a constante de proporcionalidade via integração. Para isto, basta lembrar que toda densidade (ou f.p.) deve integrar 1, ou seja, basta fazer

$$\int p(\mathbf{x} | \theta) d\mathbf{x} = 1 \Rightarrow \int f(\theta) g(\mathbf{x}, \theta) d\mathbf{x} = 1 \Rightarrow f(\theta) = \frac{1}{\int g(\mathbf{x}, \theta) d\mathbf{x}}$$

Assim, podemos dizer que “o núcleo contém toda a informação de uma distribuição”. A identificação de núcleos será útil mais adiante para reconhecer prioris conjugadas.

Constante de proporcionalidade da posteriori

Por $1/p(y_1, \dots, y_n)$ não depender de θ , dizemos que esta quantidade é uma **constante de proporcionalidade da posteriori** (que denotaremos por k). Assim, observe que a posteriori é proporcional ao produto da verossimilhança pela priori:

$$p(\theta | y_1, \dots, y_n) = k p(y_1, \dots, y_n | \theta) p(\theta) \propto \underbrace{p(y_1, \dots, y_n | \theta)}_{\text{verossimilhança}} \underbrace{p(\theta)}_{\text{priori}}$$

A constante de proporcionalidade pode ser recuperada com

$$k = \left(\int p(y_1, \dots, y_n | \theta) p(\theta) d\theta \right)^{-1}.$$

Verossimilhança marginal

Definição 11: A densidade (ou função de probabilidade) $p(y_1, \dots, y_n)$ é chamada de **verossimilhança marginal** e pode ser obtida com

$$p(y_1, \dots, y_n) = \int p(y_1, \dots, y_n | \theta) p(\theta).$$

Distribuição preditiva

Em muitas aplicações como, por exemplo, em séries temporais e geoestatística, o maior interesse é prever um processo em pontos não observados do tempo ou espaço. Suponha então que, após observar y_1, \dots, y_n , estamos interessados na previsão de quantidades Y_1^*, \dots, Y_p^* , também relacionadas à θ e descritas probabilisticamente por uma distribuição $(Y_1^*, \dots, Y_p^* | y_1, \dots, y_n, \theta)$.

Definição 12: A distribuição de $(Y_1^*, \dots, Y_p^* | y_1, \dots, y_n)$ é chamada de **distribuição preditiva** e sua densidade (ou f.p.) pode ser obtida por integração com

$$\begin{aligned} p(y_1^*, \dots, y_p^* | y_1, \dots, y_n) &= \int p(y_1^*, \dots, y_p^*, \theta | y_1, \dots, y_n) d\theta \\ &= \int p(y_1^*, \dots, y_p^* | \theta, y_1, \dots, y_n) p(\theta | y_1, \dots, y_n) d\theta. \end{aligned} \quad (1)$$

Em muitos problemas estatísticos a hipótese de independência condicional⁴ entre (Y_1, \dots, Y_n) e (Y_1^*, \dots, Y_p^*) dado θ está presente e a distribuição preditiva pode ser representada por

$$p(y_1^*, \dots, y_p^* | y_1, \dots, y_n) = \int p(y_1^*, \dots, y_p^* | \theta) p(\theta | y_1, \dots, y_n) d\theta. \quad (2)$$

OBS: Em muitas aplicações práticas, a integral em (1) (ou (2)) não tem solução analítica e precisa ser obtida por algum método de aproximação.

⁴Esta hipótese de independência condicional não é uma hipótese razoável para dados espacialmente distribuídos, onde admite-se que exista alguma estrutura de correlação no espaço.

Exemplos

Exemplo 9 (regressão linear simples): Um biólogo investiga o efeito de diferentes quantidades de fertilizante na produção de grama em solo calcário. Dez áreas de 1 m^2 foram escolhidas ao acaso e diferentes quantidades do fertilizante foram aplicadas a cada área. Dois meses depois, as produções de grama foram anotadas. Os dados desta investigação são apresentados na tabela abaixo.

Massa de fertilizante (g/m^2)	Produção de grama (g/m^2)
25	84
50	80
75	90
100	154
125	148
150	169
175	206
200	244
225	212
250	248

Considere o modelo de regressão linear descrito por

$$Y_i \sim N(\mu_i, \sigma^2) \text{ e}$$
$$\mu_i = \alpha X_i + \beta.$$

Assuma a priori que

$$\alpha \sim N(0, 10^6),$$

$$\beta \sim N(0, 10^6) \text{ e}$$

$$\phi = \frac{1}{\sigma^2} \sim Ga(0.1, 0.1).$$

- Construa o gráfico de dispersão com as massas de fertilizante no eixo das abscissas e as produções de grama no eixo das ordenadas.
- Construa uma tabela com as médias a posteriori e intervalos de 95% de credibilidade a posteriori para os parâmetros α , β e σ^2 .
- Acrescente ao gráfico de dispersão obtido no item (a) a função $f(x) = \hat{\alpha}x + \hat{\beta}$, onde $\hat{\alpha}$ e $\hat{\beta}$ são, respectivamente, a média a posteriori de α e β .
- Compare as médias a posteriori com as estimativas de máxima verossimilhança dos parâmetros α , β e σ^2 .
- Usando 15 g/m² de fertilizante, qual é o intervalo de 95% de credibilidade para a produção de grama em 1 m².
- Suponha que a grama foi plantada em 50 m² usando 15 g/m² de fertilizante. Qual é o intervalo de 95% de credibilidade para a produção de grama em toda a área plantada.

Exemplo 10 (regressão não linear): *Dugongues são animais da mesma ordem dos peixes-bois (ordem Sirenia). Dentre suas principais características, temos: narinas no topo da cabeça, lábio superior voltado para baixo e nadadeira dividida em duas partes (como a das baleias e golfinhos). Os Dugongues são encontrados na costa leste da África, Índia, Indonésia, Malásia e Austrália.*



Figura: Foto de um dugongue

A tabela abaixo exhibe tamanhos e idades de 27 Dugongues.

Idades	Tamanhos	Idades	Tamanhos
x_i	y_i	x_i	y_i
1	1.80	10	2.50
1.5	1.85	12	2.32
1.5	1.87	12	2.32
1.5	1.77	13	2.43
2.5	2.02	13	2.47
4	2.27	14.5	2.56
5	2.15	15.5	2.65
5	2.26	15.5	2.47
7	2.47	16.5	2.64
8	2.19	17	2.56
8.5	2.26	22.5	2.70
9	2.40	29	2.72
9.5	2.39	31.5	2.57
9.5	2.41		

Carlin & Gelfand (1991) propõem o seguinte modelo para os dados da tabela:

$$Y_i \sim N(\mu_i, \sigma^2)$$
$$\mu_i = \alpha - \beta\gamma^{x_i}$$

- Construa um gráfico de dispersão com as idades no eixo das abscissas e os tamanhos no eixo das ordenadas.
- Construa uma tabela as médias a posteriori e intervalos de 95% de credibilidade a posteriori para os parâmetros α , β , γ e σ^2 .
- Construa um gráfico com as idades no eixo das abscissas e médias a posteriori dos parâmetros μ_1, \dots, μ_{27} no eixo das ordenadas. Neste mesmo gráfico, exiba os intervalos de credibilidade destes parâmetros.

Exemplo 11 (ponto de mudança): *Sejam Y_1, Y_2, \dots, Y_n uma sequência de variáveis aleatórias com distribuição de Poisson e y_i uma observação de $Y_i, \forall i \in \{1, \dots, n\}$. Suponhamos ainda que existe uma suspeita de “mudança de ponto”, ou seja, suspeita-se que, para algum $m \in \{1, \dots, m\}$, a sequência Y_1, \dots, Y_m têm média λ_1 e a sequência Y_{m+1}, \dots, Y_n têm média λ_2 . Com as $n = 112$ observações y_1, \dots, y_{112} apresentadas na tabela abaixo, estime os parâmetros λ_1, λ_2 e m assumindo as distribuições a priori independentes: $\lambda \sim \text{Ga}(0.1, 0.1)$, $\phi \sim \text{Ga}(0.1, 0.1)$ e m uniformemente distribuído em $\{1, \dots, n\}$.*

4	5	4	1	0	4	3	4	0	6	3	3	4	0
2	6	3	3	5	4	5	3	1	4	4	1	5	5
3	4	2	5	2	2	3	4	2	1	3	2	2	1
1	1	1	3	0	0	1	0	1	1	0	0	3	1
0	3	2	2	0	1	1	1	0	1	0	1	0	0
0	2	1	0	0	0	1	1	0	2	3	3	1	1
2	1	1	1	1	2	4	2	0	0	0	1	4	0
0	0	1	0	0	0	0	0	1	0	0	1	0	1

Tabela: Observações y_1, \dots, y_{112}

Exemplo 12: (modelo hierárquico) Souza (1999) considera modelos hierárquicos para descrever o ganho de peso de 68 mulheres grávidas que visitaram, de 5 à 7 vezes, o Instituto de Puericultura e Pediatria Martagão Gesteira da Universidade Federal do Rio de Janeiro. Os dados deste exemplo podem ser obtidos na página

http://www.ufjf.br/joaquim_netto.

Um dos modelos propostos por Souza (1999) é descrito por

$$\begin{aligned} Y_{i,j} \mid \alpha_i, \beta_i, \sigma^2 &\sim N(\alpha_i + \beta_i X_{i,j}, \sigma^2), \\ \alpha_i &\sim N(\mu_\alpha, \sigma_\alpha^2), \quad \beta_i \sim N(\mu_\beta, \sigma_\beta^2), \\ \mu_\alpha &\sim N(0, 1000), \quad \mu_\beta \sim N(0, 1000), \\ \sigma^{-2} &\sim \text{Ga}(0.1, 0.1), \quad \sigma_\alpha^{-2} \sim \text{Ga}(0.1, 0.1) \quad \text{e} \quad \sigma_\beta^{-2} \sim \text{Ga}(0.1, 0.1). \end{aligned}$$

Aqui, $Y_{i,j}$ está associada à j -ésima medida de peso da i -ésima mulher e $x_{i,j}$ é o tempo (em semanas após o início do estudo) em que ocorre esta medida.

- a) Usando os diferentes valores de i e j para os quais existe uma observação $y_{i,j}$, faça um gráfico cartesiano com segmentos de reta conectando os pontos $(x_{i,j}, y_{i,j})$ e $(x_{i,j+1}, y_{i,j+1})$.
- b) Construa uma tabela com médias a posteriori e limites dos intervalos de 95% de credibilidade a posteriori para os parâmetros $\alpha, \beta, \sigma^2, \sigma_\alpha^2, \sigma_\beta^2$.
- c) Construa uma tabela com médias a posteriori e limites dos intervalos de 95% de credibilidade a posteriori para os parâmetros $\alpha_1, \dots, \alpha_{68}, \beta_1, \dots, \beta_{68}$.
- d) Para cada observação $x_{i,j}$ sem observação de ganho de peso, encontre as médias a posteriori e os intervalos de 95% de credibilidade a posteriori para estes ganhos. Exiba estas informações em uma tabela.

Exemplo 13 (modelo linear generalizado): *Suponha que 8 grupos de besouros são expostos à diferentes níveis de concentração de disulfato de carbono gasoso. A tabela abaixo exhibe o número de besouros em cada grupo e o número de besouros mortos após 5 horas de exposição.*

Numeração dos Grupos (i)	Dose (x_i)	Número de besouros (m_i)	Número de mortos (y_i)
1	1.6907	59	6
2	1.7242	60	13
3	1.7552	62	18
4	1.7842	56	28
5	1.8113	63	52
6	1.8369	59	53
7	1.8610	62	61
8	1.8839	60	60

a) Construa um gráfico de dispersão com as doses (x_i) no eixo das abscissas e as proporções de mortos (y_i/m_i) no eixo das ordenadas.

b) Assuma que y_i é uma amostra aleatória da v.a. Y_i , de modo que $Y_i \sim \text{Bin}(\pi_i, m_i)$, $\forall i \in \{1, \dots, 8\}$ (modelo binomial). Supondo uma função de ligação logito, caracterizada pelas equações equivalentes

$$\begin{aligned} \text{logito}(\pi_i) &= \log\left(\frac{\pi_i}{1-\pi_i}\right) = \beta_1 + \beta_2 x_i \\ \text{e} \\ \pi_i &= \frac{\exp(\beta_1 + \beta_2 x_i)}{1 + \exp(\beta_1 + \beta_2 x_i)}, \end{aligned}$$

encontre a média a posteriori e o intervalo de 95% de credibilidade a posteriori para os parâmetros β_1 e β_2 .

Exemplo 14 (análise de sobrevivência): *Turnbull et al. (1974) descrevem algumas abordagens para analisar dados do programa de transplante de coração de Stanford. Um dos objetivos é decidir se transplantes de coração estendem o tempo de vida do paciente.*

Para cada paciente $i \in \{1, \dots, 82\}$ no programa, seja $T_{1,i}$ sua data de entrada no programa e $T_{i,2}$ a “última informação” que se tem do paciente, que pode ser: a data de sua morte ou a data de fechamento do estudo para análise dos dados (1 de março de 1973). Se o paciente realizou um transplante, seja $T_{i,3}$ a data da operação. Assim, para um paciente transplantado, temos $T_{i,1} \leq T_{i,3} \leq T_{i,2}$. Para os pacientes que não realizaram transplante, seja $X_i = T_{i,2} - T_{i,1}$ seu tempo de sobrevivência. Já para os pacientes que receberam o transplante, seja $Y_i = T_{i,3} - T_{i,1}$ seu tempo de espera até realizar o transplante e $Z_i = T_{i,2} - T_{i,3}$ seu tempo de sobrevivência após o transplante.

Suponhamos ainda que $X_1, \dots, X_n, Y_1, \dots, Y_m, Z_1, \dots, Z_m$ são variáveis associadas a pacientes que faleceram e que $X_{n+1}, \dots, X_N, Y_{m+1}, \dots, Y_M, Z_{m+1}, \dots, Z_M$ estão associadas a pacientes ainda vivos na data de fechamento do estudo.

Em um dos modelos, Turnbull *et al.* (1974) assumem que os tempos de vida dos pacientes no grupo de não transplantados seguem uma distribuição exponencial⁵ com média $1/\theta$. Por outro lado, para os pacientes transplantados, o tempo de sobrevivência⁶ segue uma distribuição exponencial com média $1/(\theta\tau)$. Assim, para um paciente transplantado, o modelo assume que o risco do paciente muda de acordo com um fator τ . Especificamente, se $\tau = 1$, não há mudança no risco devido à realização do transplante.

O banco de dados deste exemplo e o artigo Turnbull *et al.* (1974) podem ser obtidos na página

http://www.ufjf.br/joaquim_netto

contém 4 variáveis: “transplant”, que assume o valor 1 para transplantados e 0 caso contrário, “state”, que assume o valor 1 para paciente vivo e zero caso contrário, “timetotransplant”, que contém os dias de espera até o transplante e, finalmente, “survtime”, que contém os dias de sobrevivência do paciente desde sua entrada no estudo.

⁵A distribuição exponencial é muito usada em análise de sobrevivência para modelar o tempo até a primeira ocorrência de um evento. Vale lembrar ainda que ao assumir um processo Poisson, o tempo até a primeira ocorrência segue distribuição exponencial.

⁶tempo de vida após transplante

- a) Proponha uma distribuição a priori para o vetor de parâmetros desconhecidos.
- b) Escreva a função de verossimilhanças.
- c) Estime as médias a posteriori e os intervalos de 95% de credibilidade para os parâmetros do modelo.
- d) Você diria que o transplante aumenta, diminui ou não afeta o risco do paciente? Por que?

Conjugação

Para os modelos estatísticos mais populares, existem famílias de distribuições com uma característica muito especial.

Definição 13: *Suponhamos que uma distribuição a priori pertence à uma determinada família de distribuições. Se, para um determinado modelo e parâmetro, a posteriori pertencer a mesma família, dizemos que esta é uma **família conjugada** de distribuições a priori para o parâmetro.*

Resultado 1 (normal - normal): Seja Y_1, \dots, Y_n uma amostra aleatória da $N(\mu, \sigma^2)$, com σ^2 conhecido. Supondo que $\mu \sim N(m, v^2)$ então $\mu \mid Y_1, \dots, Y_n$ tem distribuição normal com

$$E(\mu \mid Y_1, \dots, Y_n) = \frac{\sigma^2 m + nv^2 \bar{Y}}{\sigma^2 + nv^2}$$

$$\text{Var}(\mu \mid Y_1, \dots, Y_n) = \frac{\sigma^2 v^2}{\sigma^2 + nv^2}, \text{ onde } \bar{Y} = \frac{\sum_{i=1}^n Y_i}{n}.$$

Prova:

Exercício 2: Seja Y_1, \dots, Y_n uma amostra aleatória da $N(\mu, \sigma^2)$, com σ^2 conhecido. Supondo uma priori $\mu \sim N(m, v^2)$:

- verifique o limite de $E(\mu \mid y_1, \dots, y_n)$ quando v^2 tende à ∞ ,
- encontre o EMV para esta amostra aleatória e
- compare os resultados dos itens (a) e (b).

Resultado 2 (binomial - beta): Seja Y_1, \dots, Y_n uma amostra aleatória da $\text{Bin}(m, \theta)$, com m conhecido. Supondo uma priori $\theta \sim \text{Be}(a, b)$ temos que

$$(\theta \mid Y_1, \dots, Y_n) \sim \text{Be} \left(a + \sum_{i=1}^n Y_i, nm + b - \sum_{i=1}^n Y_i \right).$$

Prova:

OBS: Lembre-se que a distribuição uniforme é um caso particular da beta (basta fazer $a = 1$ e $b = 1$). Assim, pelo resultado acima, um modelo binomial combinado com uma priori uniforme produz uma posteriori beta.

Resultado 3 (Poisson - gamma): Seja Y_1, \dots, Y_n uma amostra aleatória da $\text{Poi}(\theta)$. Supondo uma priori $\theta \sim \text{Ga}(a, b)$ temos que

$$(\theta \mid Y_1, \dots, Y_n) \sim \text{Ga} \left(a + \sum_{i=1}^n Y_i, b + n \right).$$

Prova:

Resultado 4 (normal - gamma): Seja Y_1, \dots, Y_n uma amostra aleatória da $N(\mu, \phi^{-1})$, com μ conhecido. Supondo uma priori $\phi \sim Ga(a, b)$ então

$$(\phi \mid Y_1, \dots, Y_n) \sim Ga \left(\frac{n}{2} + a, b + \frac{\sum_{i=1}^n (y_i - \mu)^2}{2} \right).$$

Algoritmos de simulação

Aqui, veremos apenas dois algoritmos para simular amostras de uma distribuição de probabilidade: o amostrador de Gibbs e o Metropolis-Hastings. Para uma revisão mais detalhada destes algoritmos e para conhecer outros, veja Gamerman and Lopes (2006).

Condicionais completas

Definição 14: *As distribuições de*

$$\begin{aligned} & (Y_1 | Y_2, Y_3, \dots, Y_n), \\ & (Y_2 | Y_1, Y_3, Y_4, \dots, Y_n), \\ & (Y_3 | Y_1, Y_2, Y_4, Y_5, \dots, Y_n), \\ & \vdots \\ & (Y_n | Y_1, Y_2, \dots, Y_{n-1}) \end{aligned}$$

são chamadas de **condicionais completas da distribuição conjunta** de (Y_1, \dots, Y_n) .

Pela teoria de probabilidades, a densidade (ou f.p.) condicional $p(y_i | y_1, \dots, y_{i-1}, y_{i+1}, \dots, y_n)$ pode ser obtida com

$$p(y_i | y_1, \dots, y_{i-1}, y_{i+1}, \dots, y_n) = \frac{p(y_1, \dots, y_n)}{\int p(y_1, \dots, y_n) dy_i}.$$

Amostrador de Gibbs

O **amostrador de Gibbs** (AG) é um método MCMC que têm núcleo de transição formado pelas distribuições condicionais completas.

O amostrador de Gibbs é um dos algoritmos de simulação mais utilizados na inferência bayesiana. Seu objetivo é simular de uma distribuição conjunta (que no contexto bayesiano é a posteriori) e, para isto, valores são simulados sucessivamente das distribuições condicionais completas.

O problema a ser resolvido então envolve a simulação de uma distribuição conjunta quando a simulação das condicionais completas é acessível (ou trivial) e esquemas para simular diretamente da conjunta ⁷ são muito complicados ou simplesmente não disponíveis.

⁷Ver Gamerman and Lopes (2006)

O amostrador de Gibbs é descrito pelos seguintes passos:

- 1) Inicialize um contador de iterações $j = 1$ e defina (“chute”) um vetor de valores iniciais $\mathbf{y}^{(0)} = (y_1^{(0)}, y_2^{(0)}, \dots, y_n^{(0)})$.
- 2) Obtenha um novo vetor $\mathbf{y}^{(1)} = (y_1^{(1)}, y_2^{(1)}, \dots, y_n^{(1)})$ simulando

$$\begin{aligned}
 & y_1^{(j)} \text{ de } p\left(y_1 | y_2^{(j-1)}, y_3^{(j-1)}, \dots, y_n^{(j-1)}\right) \\
 & y_2^{(j)} \text{ de } p\left(y_2 | y_1^{(j)}, y_3^{(j-1)}, y_4^{(j-1)}, \dots, y_n^{(j-1)}\right) \\
 & y_3^{(j)} \text{ de } p\left(y_3 | y_1^{(j)}, y_2^{(j)}, y_4^{(j-1)}, y_5^{(j-1)}, \dots, y_n^{(j-1)}\right) \\
 & \quad \vdots \\
 & y_n^{(j)} \text{ de } p\left(y_n | y_1^{(j)}, y_2^{(j)}, \dots, y_{n-1}^{(j)}\right).
 \end{aligned}$$

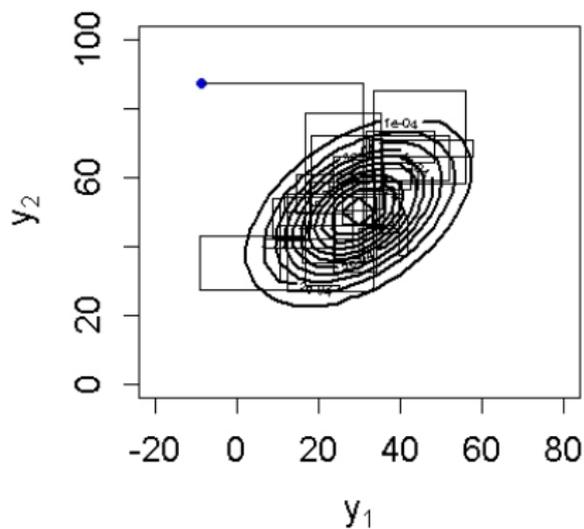
- 3) Se o contador for menor que k , mude o contador de j para $j + 1$ e retorne ao passo 2.

O algoritmo produz seqüências $y_i^{(1)}, y_i^{(2)}, \dots, y_i^{(k)}$, para $i \in \{1, \dots, n\}$. Na prática⁸, o procedimento utilizado para obter amostras da distribuição conjunta a partir destas seqüências consiste em descartar um número b de valores iniciais e, em seguida, escolher valores com um espaçamento igual a t . As quantidades b e t são chamadas de aquecimento (*burnin*) e espaçamento (*thinning*), respectivamente.

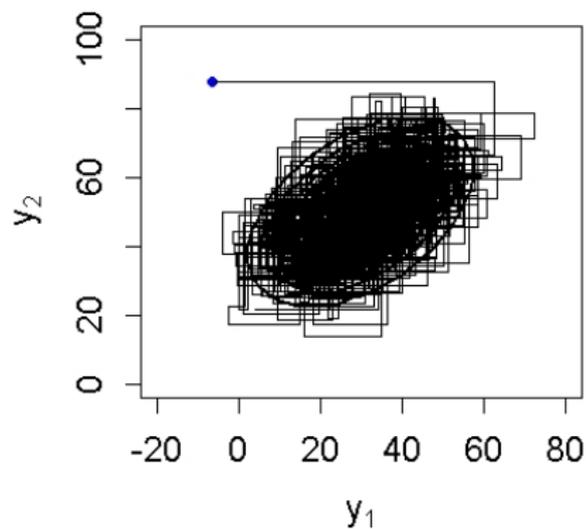
⁸Para mais informações, consulte Gamerman and Lopes (2006).

Exemplo 15 (Didático): Use o amostrador de Gibbs para simular amostras de uma distribuição normal bivariada⁹ com vetor de médias $\mu = (30, 50)^T$ e matriz de covariâncias $\Sigma = \begin{bmatrix} 150 & 70 \\ 70 & 150 \end{bmatrix}$.

⁹Neste exemplo, a escolha da normal foi didática, uma vez que a maioria dos softwares estatísticos possuem comandos para simular desta distribuição.



50 iterações.



1000 iterações.

Figura: Cadeias obtidas com o amostrador de Gibbs para o exemplo 15. O ponto azul marca o valor inicial da cadeia.

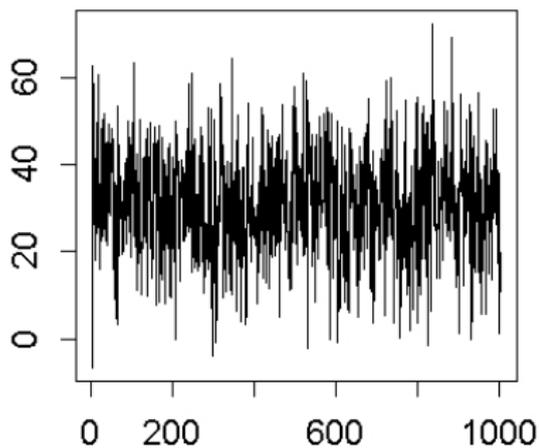
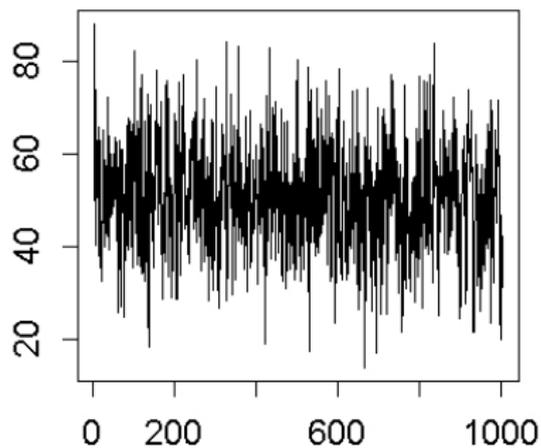
 y_1 . y_2 .

Figura: Cadeias obtidas com o amostrador de Gibbs para o exemplo 15.

Metropolis-Hastings

O algoritmo Metropolis-Hastings é descrito pelos seguintes passos:

- 1) Inicialize um contador de iterações $j = 1$ e defina (“chute”) um vetor de valores iniciais $\mathbf{y}^{(0)} = (y_1^{(0)}, y_2^{(0)}, \dots, y_n^{(0)})$.
- 2) Obtenha um novo vetor $\mathbf{y}^* = (y_1^*, y_2^*, \dots, y_n^*)$ simulando de uma densidade (ou f.p.) proposta $q(\mathbf{y}^* | \mathbf{y}^{(j-1)})$, que pode ou não depender de $\mathbf{y}^{(j-1)}$.
- 2) Simule uma amostra u da distribuição $U[0, 1]$.
- 3) Calcule a razão

$$r(\mathbf{y}^{(j-1)}, \mathbf{y}^*) = \frac{p(\mathbf{y}^* | \mathbf{y}^{(j-1)})}{p(\mathbf{y}^{(j-1)} | \mathbf{y}^*)} \frac{q(\mathbf{y}^{(j-1)} | \mathbf{y}^*)}{q(\mathbf{y}^* | \mathbf{y}^{(j-1)})}$$

- 4) Se $u < r(\mathbf{y}^{(j-1)}, \mathbf{y}^*)$ o valor proposto é aceito fazendo $\mathbf{y}^{(j)} = \mathbf{y}^*$, caso contrário, o valor proposto é rejeitado fazendo $\mathbf{y}^{(j)} = \mathbf{y}^{(j-1)}$.
- 5) Se o contador for menor que k , mude o contador de j para $j + 1$ e retorne ao passo 2.

Assim como o amostrador de Gibbs, o algoritmo produz seqüências $\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(k)}$ e para obter amostras da distribuição basta retirar observações iniciais (*burnin*) e usar um espaçamento (*thinning*).

Um algoritmo de Metropolis muito utilizado é baseado em um passeio aleatório. Neste caso, se usarmos uma distribuição proposta com variância σ^2 , duas situações extremas podem ocorrer:

- se σ^2 for muito pequena os valores gerados estarão próximos do valor atual e serão aceitos com frequência. Neste caso, serão necessárias muitas iterações para percorrer o espaço paramétrico.
- valores grandes de σ^2 levam a uma taxa de rejeição excessivamente alta e a cadeia se movimentará lentamente.

Exemplo 16 (Didático): Use o algoritmo Metropolis-Hastings para simular valores da distribuição $N(5, 25)$. Use como proposta um passeio aleatório normal com variância τ^2 . Compare as taxas de aceitação obtidas com diferentes valores de τ^2 .

Exercício 3: Considere a densidade

$$p(y_1, y_2 | \mu_1, \mu_2, \Sigma_1, \Sigma_2) = 0.7p(y_1, y_2 | \mu_1, \Sigma_1) + 0.3p(y_1, y_2 | \mu_2, \Sigma_2)$$

de uma mistura de normais, onde $p(y_1, y_2 | \mu_i, \Sigma_i)$ é a densidade de uma normal bivariada com vetor de médias μ_i e matriz de covariâncias Σ_i , para $i = 1, 2$. Especificamente, fixe

$$\mu_1 = (4, 5)^T, \mu_2 = (0.7, 3.5)^T, \Sigma_1 = \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix} \quad \text{e} \quad \Sigma_2 = \begin{bmatrix} 1 & -0.7 \\ -0.7 & 1 \end{bmatrix}.$$

- Plote a densidade $p(y_1, y_2 | \mu_1, \mu_2, \Sigma_1, \Sigma_2)$ (superfície tridimensional).
- Use o algoritmo Metropolis-Hastings para simular amostras de $p(y_1, y_2 | \mu_1, \mu_2, \Sigma_1, \Sigma_2)$.

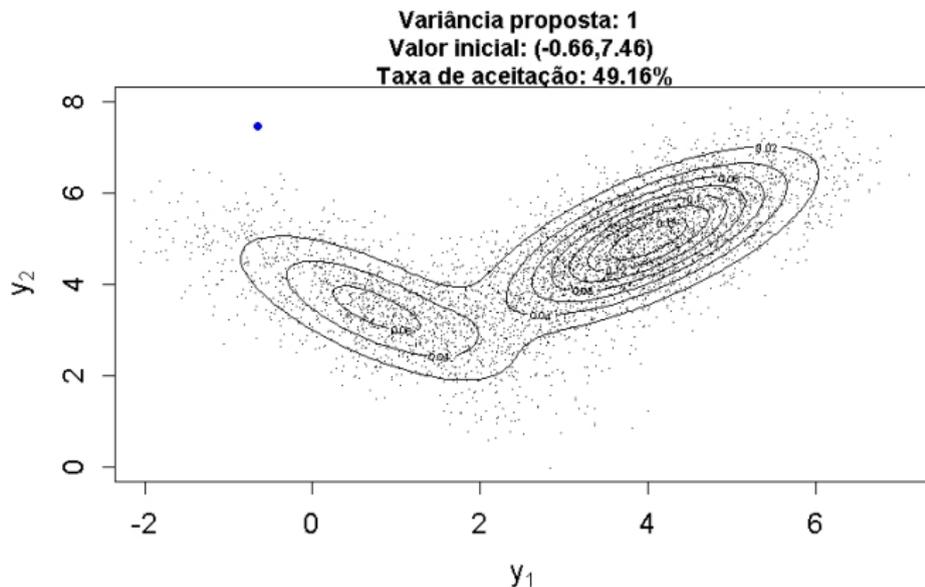


Figura: Cadeia obtida com o algoritmo Metropolis-Hastings. O ponto azul marca o valor inicial da cadeia.

Introdução a teoria da decisão

Relembremos um típico problema de inferência paramétrica, no qual uma variável aleatória \mathbf{X} (possivelmente multidimensional) é usada para representar matematicamente a incerteza de observações amostrais. Suponhamos um vetor θ , chamado de **vetor paramétrico**, com componentes desconhecidas. Suponhamos ainda que θ pertence a um conjunto Θ de valores possíveis, chamado **espaço paramétrico**.

Um problema de decisão pode ser completamente especificado usando 3 conjuntos:

- o espaço paramétrico Θ ,
- o conjunto de possíveis resultados do experimento Ω e
- um conjunto de possíveis ações \mathcal{A} .

Uma **regra de decisão** (ou simplesmente **decisão**) δ é uma função definida em Ω e que assume valores em \mathcal{A} , ou seja $\delta : \Omega \rightarrow \mathcal{A}$. Uma **função perda** $L(\delta, \theta)$ associa a cada decisão δ e valor possível $\theta \in \Theta$ um número real positivo. Este número pode ser interpretado como uma punição¹⁰ por tomar a decisão δ sendo que o valor do parâmetro é θ .

¹⁰Esta punição é denominada também pelos termos: custo, perda e prejuízo.

Definição 15: O **risco** de uma regra de decisão δ , denotado por $R(\delta)$, é definido como o valor esperado da função perda, ou seja,

$$R(\delta) = E(L(\delta, \theta)).$$

Se nenhuma amostra de X foi observada, o valor esperado da equação acima é baseado na priori, ou seja,

$$R(\delta) = E(L(\delta, \theta)) = \int L(\delta, \theta) p(\theta) d\theta.$$

Por outro lado, se uma amostra \mathbf{x} de \mathbf{X} já tiver sido observada, o valor esperado é com relação a distribuição a posteriori e

$$R(\delta) = E(L(\delta, \theta)) = \int L(\delta, \theta) p(\theta | \mathbf{x}) d\theta.$$

Uma regra de decisão δ^* é dita **ótima** se tem risco mínimo, ou seja, se para qualquer outra regra de decisão δ e observação \mathbf{x} , $R(\delta^*) < R(\delta)$. O risco é uma medida que permite comparar diferentes regras de decisão e, naturalmente, a regra de decisão com o menor risco tem menor perda esperada.

Exemplo 17: Consideremos novamente a situação exposta no exemplo 6. Porém, agora o médico precisa escolher entre duas decisões: submeter o paciente a uma determinada cirurgia, denotada por d_1 , ou não, denotada por d_2 . A tabela abaixo apresenta uma possível atribuição de perdas para cada decisão e estado do paciente. Qual é a regra de decisão ótima?

		Decisão	
		Não faz a cirurgia (d_2)	Faz a cirurgia (d_1)
Estado θ	Sem a doença (0)	0	500
	Com a doença (1)	1000	100

Solução:

Definição 16: *Um estimador é uma regra de decisão ótima com respeito a uma determinada função perda. Seu valor observado é chamado de estimativa.*

Proposição 3: *Seja $L(\delta, \theta) = L(\delta(\omega), \theta)$ a função perda associada a estimação de um parâmetro θ . Esta função é geralmente chamada de perda quadrática. O estimador de θ é $E(\theta | \mathbf{x})$, se uma amostra x foi observada, e $E(\theta)$, caso contrário.*

FIM!

