

Introdução a Inferência Bayesiana

Pedro Luciano de Oliveira Gomes

Centro de Ciências Exatas e da Terra
Universidade Federal do Rio Grande do Norte - UFRN
Departamento de Estatística
Seminário de Tópicos Especias - STE

13 de maio de 2015

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori
- 4 Exemplo
- 5 Resultados
- 6 Conclusão
- 7 Referências Bibliográficas

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori
- 4 Exemplo
- 5 Resultados
- 6 Conclusão
- 7 Referências Bibliográficas

Introdução

A informação que se tem sobre uma quantidade de interesse θ é fundamental na Estatística. O verdadeiro valor de θ é desconhecido e a idéia é tentar reduzir esse desconhecimento. Além disso, a intensidade da incerteza a respeito de θ pode assumir diferentes graus. Do ponto vista Bayesiano, estes diferentes graus de incerteza são representados através de modelos probabilísticos para θ .

Sumário

- 1 Introdução
- 2 Teorema de Bayes**
- 3 Distribuições a priori e a posteriori
- 4 Exemplo
- 5 Resultados
- 6 Conclusão
- 7 Referências Bibliográficas

Teorema de Bayes

Considere uma quantidade de interesse desconhecida θ . A informação de que dispomos sobre θ , resumida probabilisticamente através de $p(\theta)$, pode ser aumentada observando uma quantidade aleatória X relacionada com θ e ,portanto, $p(x|\theta)$ define esta relação.

Teorema de Bayes

O teorema de Bayes é a regra de atualização utilizada para quantificar este aumento na informação,

$$p(\theta|x) = \frac{p(\theta, x)}{p(x)} = \frac{p(x|\theta)p(\theta)}{p(x)} = \frac{p(x|\theta)p(\theta)}{\int p(\theta, x)d\theta}$$

Note que $\frac{1}{p(x)}$ não depende de θ e vai funcionar como uma constante normalizadora de $p(\theta|x)$.

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori**
- 4 Exemplo
- 5 Resultados
- 6 Conclusão
- 7 Referências Bibliográficas

Distribuições a priori e a posteriori

Para um valor fixo de x , a função $Lp(\theta; x) = p(x|\theta)$ fornece a verossimilhança de cada um dos possíveis valores de θ enquanto $p(\theta)$ é chamada de distribuição a *priori* de θ .

Estas duas informações combinadas nos levam à distribuição a posteriori de θ , $p(\theta|x)$.

Distribuições a priori e a posteriori

Feito isso, temos a forma usual do teorema de Bayes:

$$p(\theta|x) \propto L(\theta; x)p(\theta).$$

Distribuição a posteriori \propto verossimilhança \times distribuição a priori.

Distribuições a priori e a posteriori

A constante normalizadora da posteriori pode ser facilmente recuperada pois $p(\theta|x) = kp(x|\theta)p(\theta)$ onde

$$K^{-1} = \int p(x|\theta)p(\theta)d\theta = E_{\theta}[p(X|\theta)] = p(x)$$

é chamada de distribuição preditiva. Esta é a distribuição esperada para a observação x dado θ . Assim,

- Antes de observar X podemos checar a adequação da priori fazendo predições via $p(x)$.
- Se X observado recebia pouca probabilidade preditiva então o modelo deve ser questionado.

Distribuições a priori e a posteriori

Suponha que estamos interessados na previsão de uma quantidade Y , também relacionado com θ , visto que já observamos uma quantidade X . E esta é descrita probabilisticamente por $p(y|\theta)$ então

$$\begin{aligned} p(y|\theta) &= \int p(y, \theta|x) d\theta = \int p(y|\theta, x) p(\theta|x) d\theta \\ &= \int p(y|\theta) p(\theta|x) d\theta \end{aligned}$$

onde a última igualdade se deve a independência entre X e Y condicionado em θ .

Distribuições a priori e a posteriori

Os conceitos de priori e posteriori são relativos àquela observação que está sendo considerada no momento. Assim, $p(\theta|x)$ é a posteriori de θ em relação a X (que já foi observado) mas é a priori de θ em relação a Y (que não foi observado ainda). Após observar $Y = y$ uma nova posteriori (relativa a $X = x$ e $Y = y$) é obtida aplicando-se novamente o teorema de Bayes.

Distribuições a priori e a posteriori

No entanto a posteriori final não depende da ordem em que as observação x e y foram processadas. Prova:

$$p(\theta|x_1) \propto L_1(\theta; x_1)p(\theta)$$

$$p(\theta|x_2, x_1) \propto L_2(\theta; x_2)p(\theta|x_1)$$

.

.

.

$$p(\theta|x_n, x_{n-1}, \dots, x_1) \propto L_n(\theta; x_n)p(\theta|x_{n-1}, \dots, x_1)$$

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori
- 4 Exemplo**
- 5 Resultados
- 6 Conclusão
- 7 Referências Bibliográficas

Exemplo 1.1

(Gamerman e Migon, 1993) Um médico, ao examinar uma pessoa, “desconfia” que ela possa ter uma certa doença. Baseado em sua experiência e nas informações dada pelo paciente ele assume que a probabilidade deste ter a doença é de 0.7. A quantidade de interesse desconhecida é o indicador da doença

$$\theta = \begin{cases} 1, & \text{se o paciente tem a doença,} \\ 0, & \text{se o paciente não tem a doença.} \end{cases}$$

Exemplo 1.1

Para aumentar sua quantidade de informação sobre a doença o médico aplica um teste X relacionado a θ através da distribuição

$$P(X = 1|\theta = 0) = 0.40 \quad \text{e} \quad P(X = 1|\theta = 1) = 0.95$$

O resultado do teste foi positivo ($X = 1$).

Exemplo 1.1

Dado este resultado, usaremos o teorema de Bayes para quantificar esse aumento.

$$P(\theta = 1|X = 1) \propto L(\theta = 1; X = 1)p(\theta = 1) = (0.95)(0.7) = 0.665$$

$$P(\theta = 0|X = 1) \propto L(\theta = 0; X = 1)p(\theta = 0) = (0.40)(0.3) = 0.120.$$

Exemplo 1.1

A constante normalizadora é tal que

$$P(\theta = 1|X = 1) + P(\theta = 0|X = 1) = 1$$

Logo,

$$k(0.665) + k(0.120) = 1$$

e $k = \frac{1}{0.785}$. Portanto, a distribuição a posteriori de θ é

$$P(\theta = 1|X = 1) = \frac{0.665}{0.785} = 0.847$$

$$P(\theta = 0|X = 1) = \frac{0.120}{0.785} = 0.153$$

Exemplo 1.1

Agora o médico aplica outro teste Y cujo resultado está relacionado a θ através da seguinte distribuição

$$P(Y = 1|\theta = 0) = 0.04 \quad \text{e} \quad P(Y = 1|\theta = 1) = 0.99$$

Exemplo 1.1

Antes de observar o resultado do teste é interessante obter sua distribuição preditiva. Como θ é uma quantidade discreta segue que

$$p(y|x) = \sum_{\theta} p(y|\theta)p(\theta|x)$$

note que $p(\theta|x)$ é a priori em relação a Y . Assim,

$$\begin{aligned} P(Y = 1|X = 1) &= P(Y = 1|\theta = 0)P(\theta = 0|X = 1) \\ &+ P(Y = 1|\theta = 1)P(\theta = 1|X = 1) \\ &= (0.90)(0.153) + (0.99)(0.847) = 0.845 \end{aligned}$$

$$P(Y = 0|X = 1) = 1 - P(Y = 1|X = 1) = 0.155$$

Exemplo 1.1

Sabendo que o resultado do teste Y foi negativo, quantificaremos essa informação usando o teorema de Bayes,

$$\begin{aligned}P(\theta = 1|X = 1, Y = 0) &\propto L(\theta = 1; Y = 0)P(\theta = 1|X = 1) \\ &\propto (0.01)(0.847) = 0.0085\end{aligned}$$

$$\begin{aligned}P(\theta = 0|X = 1, Y = 0) &\propto L(\theta = 0; Y = 0)P(\theta = 0|X = 1) \\ &\propto (0.96)(0.153) = 0.1469.\end{aligned}$$

Exemplo 1.1

A constante normalizadora é

$$k = \frac{1}{(0.0085 + 0.1469)} = \frac{1}{0.1554}$$

e assim a distribuição a posteriori de θ é

$$P(\theta = 1 | X = 1, Y = 0) = \frac{0.0085}{0.1554} = 0.055$$

$$P(\theta = 0 | X = 1, Y = 0) = \frac{0.1469}{0.1554} = 0.945.$$

Exemplo 1.1

Vejamos como a probabilidade da doença se alterou ao longo dos exames

$$P(\theta = 1) = \begin{cases} 0.7, & \text{antes dos testes,} \\ 0.847, & \text{após o teste X,} \\ 0.055, & \text{após X e Y.} \end{cases}$$

Exemplo 1.1

Notemos que o valor observado de Y recebia pouca probabilidade preditiva. Isto pode levar o médico a repensar o modelo,

(i) Será que $P(\theta = 1) = 0.7$ é uma priori adequada?

(ii) Será que as distribuições amostrais de X e Y estão corretas? O teste X é tão inexpressivo e Y é realmente tão poderoso?

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori
- 4 Exemplo
- 5 Resultados**
- 6 Conclusão
- 7 Referências Bibliográficas

Resultados

Tabela: Tabela de prioris

Posteriori	Priori		
	0.3	0.5	0.7
$P(\theta = 1 X = 1)$	0.504	0.703	0.847
$P(\theta = 0 X = 1)$	0.495	0.296	0.153
$P(\theta = 1 X = 1, Y = 0)$	0.010	0.0241	0.055
$P(\theta = 0 X = 1, Y = 0)$	0.989	0.9756	0.945

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori
- 4 Exemplo
- 5 Resultados
- 6 Conclusão**
- 7 Referências Bibliográficas

Conclusão

Vejamos que é possível inferir sobre um parâmetro mesmo sem ter observado uma amostra, o contrário do que acontece em inferência clássica.

Sumário

- 1 Introdução
- 2 Teorema de Bayes
- 3 Distribuições a priori e a posteriori
- 4 Exemplo
- 5 Resultados
- 6 Conclusão
- 7 Referências Bibliográficas**

Referências



EHLERS, Ricardo S.. **Introdução a Inferência Bayesiana**,
Paraná, v. 1, p.2-8, jun. 2003.