

Mec. Stat - Lista 3 - Gabarito

1) Distribuição bivariada

$$p_{x,y}(x,y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x\sigma_y} + \frac{y^2}{\sigma_y^2} \right] \right\} \quad (1.1)$$

A prob. condicional $p_{x|y}(x|y)$ é definida como

$$p_{x|y}(x|y) = \frac{p_{x,y}(x,y)}{p_y(y)} \quad (1.2)$$

Portanto precisamos primeiro encontrar $p_y(y)$:

$$p_y(y) = \int dx p_{x,y}(x,y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \int_{-\infty}^{\infty} dx \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x\sigma_y} + \frac{y^2}{\sigma_y^2} \right] \right\}$$

$$= \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp \left\{ -\frac{y^2}{2(1-\rho^2)\sigma_y^2} \right\} \int_{-\infty}^{\infty} dx \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x\sigma_y} \right] \right\}$$

Agora completamente quadrada.

$$\frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x\sigma_y} = \left(\frac{x}{\sigma_x} - \frac{\rho y}{\sigma_y} \right)^2 - \left(\frac{\rho y}{\sigma_y} \right)^2$$

Com isso obtemos

$$p_y(y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp \left\{ -\frac{y^2}{2(1-\rho^2)\sigma_y^2} + \frac{1}{2(1-\rho^2)} \frac{\rho^2 y^2}{\sigma_y^2} \right\} \cdot \\ \cdot \int_{-\infty}^{\infty} dx \exp \left\{ -\frac{1}{2(1-\rho^2)} \left(\frac{x}{\sigma_x} - \frac{\rho y}{\sigma_y} \right)^2 \right\}$$

The exponential outside the integral simplifies to

$$-\frac{y^2}{2(1-\rho^2)\sigma_y^2} \left[1 - \rho^2 \right] = -\frac{y^2}{2\sigma_y^2}$$

As for the integral, change variables to

$$z = \frac{x}{\sigma_x} - \frac{\rho y}{\sigma_y}$$

$$dz = \frac{dx}{\sigma_x}$$

then we get

$$p_y(y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} e^{-y^2/2\sigma_y^2} \sigma_x \int_{-\infty}^{\infty} dz \exp \left\{ -\frac{z^2}{2(1-\rho^2)} \right\}$$

$\underbrace{\qquad\qquad\qquad}_{\sqrt{2\pi(1-\rho^2)}}$

thus, we conclude that

$$p_y(y) = \frac{1}{\sqrt{2\pi}\sigma_y} e^{-y^2/2\sigma_y^2} \quad (1.3)$$

we see from this result that $y \sim N(0, \sigma_y^2)$

Substituting (1.3) and (1.1) in (1.2) we get

$$P_{x|y}(x|y) = \frac{1}{\sqrt{2\pi} \sigma_x \sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x \sigma_y} + \frac{y^2}{\sigma_y^2} \right] + \frac{y^2}{2\sigma_y^2} \right\} \quad (1.4)$$

Let us simplify the exponent; it reads

$$\begin{aligned} & -\frac{1}{2(1-\rho^2)} \left\{ \frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x \sigma_y} + \frac{y^2}{\sigma_y^2} - \frac{(1-\rho^2)y^2}{\sigma_y^2} \right\} = \\ &= -\frac{1}{2(1-\rho^2)} \left\{ \frac{x^2}{\sigma_x^2} - \frac{2\rho xy}{\sigma_x \sigma_y} + \frac{\rho^2 y^2}{\sigma_y^2} \right\} \\ &= -\frac{1}{2(1-\rho^2)} \left\{ \left(\frac{x}{\sigma_x} - \frac{\rho y}{\sigma_y} \right)^2 \right\} \\ &= -\frac{1}{2(1-\rho^2)} \frac{1}{\sigma_x^2} \left(x - \frac{\rho \sigma_x y}{\sigma_y} \right)^2 \end{aligned}$$

Now let

$$\mu_x = \rho \frac{\sigma_x y}{\sigma_y} \quad (1.5)$$

$$\tilde{\sigma}_x = \sigma_x \sqrt{1-\rho^2}$$

Eq (1.5) then becomes

$$P_{x|y}(x|y) = \frac{1}{\sqrt{2\pi} \tilde{\sigma}_x} \exp \left\{ -\frac{(x-\mu_x)^2}{2\tilde{\sigma}_x^2} \right\} \quad (1.6)$$

thus we conclude that

$$x|y=y \sim N\left(\frac{\rho \sigma_x y}{\sigma_y}, \sigma_x^2(1-\rho^2)\right) \quad (1.7)$$

We see that the correlation ρ reduces the variance of x . When $\rho = \pm 1$, the variance tends to zero (in this case, if $y=y$ is known, then you completely know what x will be).

When $\rho=0$ the mean of $X|Y=y$ is zero. But if $\rho>0$ the mean will have the same sign as y and if $\rho<0$ the sign will be opposite. This agrees with our idea of correlation: when x, y are positively correlated, $y>0$ makes it more likely to have $x>0$ and when they are negatively correlated, $y>0$ makes it more negative to have $x<0$.

Regra das 5 segundas

(a) Causa $N_t \sim \text{Pois}(\lambda) \Rightarrow \langle N_t \rangle = \lambda t$

$$\Rightarrow \lambda t_c = N_c$$

$$t_c = \frac{N_c}{\lambda}$$

(b) $X_t = \frac{N_t}{N_c}$

Sabemos que quando t é grande $\text{Pois}(\lambda t)$ tende a uma normal, portanto

$$X_t \sim N(\mu, \sigma^2)$$

Temos: $\mu = \langle X_t \rangle = \frac{\langle N_t \rangle}{N_c} = \frac{\lambda t}{N_c}$

Mas $N_c = \lambda t_c \Rightarrow \mu = t/t_c$.

Da mesma forma, sabemos da Poisson que
 $\text{Var}(N_t) = \lambda t$. Portanto

$$\sigma^2 = \text{Var}(X_t) = \frac{1}{N_c^2} \text{Var}(N_t) = \frac{\lambda t}{N_c^2} = \frac{t/t_c}{N_c}$$

Assim:

$$X_t \sim N\left(t/t_c, \frac{t}{t_c N_c}\right)$$

(c) Violar a regra das 5 segundas significa demorar mais que 5 segundas para que os microbios devorem sua comida. Ou seja

$$P(N_{tc} < N_c)$$

Para $N_t \sim Pois(\lambda t)$, temos

$$P(N_{tc} < N_c) = e^{-\lambda t_c} \sum_{m=0}^{N_c} \frac{(\lambda t_c)^m}{m!}$$

Para X_t temos

$$P(X_{tc} < t) = \int_{-\infty}^t dx \frac{1}{\sqrt{2\pi\sigma_c^2}} \exp\left\{-\frac{1}{2} \frac{(x - \mu)^2}{\sigma_c^2}\right\}$$

$$\text{onde } \sigma_c = 1/N_c$$

Quando $N_c \rightarrow \infty$ a dist. tende para um f. de Dirac e, consequentemente, a probabilidade de obter uma reacção vai a zero.

2) Cadeia de Markov

(a)

$$Q = \begin{bmatrix} 0.5 & 0.25 & 0 & 0 \\ 0.5 & 0.75 & 0 & 0 \\ 0 & 0 & 0.25 & 0.75 \\ 0 & 0 & 0.75 & 0.25 \end{bmatrix} \quad (2.1)$$

Esse cadeia não é irredutível pois começando em (1,2), nunca podemos alcançar (3,4) e vice versa.

(b) A distribuição estacionária \vec{P} :

$$Q\vec{P}^* = \vec{P}^* \quad (2.2)$$

Como a cadeia se fatora em duas cadeias independentes, teremos duas dist. estacionárias independentes, que não comunicam as duas partes. Ou seja, elas sejam do tipo

$$\vec{P}_1^* = \begin{bmatrix} a \\ b \\ 0 \\ 0 \end{bmatrix} \quad \vec{P}_2^* = \begin{bmatrix} 0 \\ 0 \\ c \\ d \end{bmatrix} \quad (2.3)$$

Aplicando a Eq (2.2) para \vec{P}_1^* obtemos

$$Q\vec{P}_1^* = \begin{bmatrix} \frac{a}{2} + \frac{b}{4} \\ \frac{a}{2} + \frac{3b}{4} \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} a \\ b \\ 0 \\ 0 \end{bmatrix} = \vec{P}_1^*$$

Portanto

$$\frac{a}{2} + \frac{b}{4} = a \Rightarrow b = 2a$$

Assim \vec{p}_1 será

$$\vec{p}_1^* = a \begin{bmatrix} 1 \\ 2 \\ 0 \\ 0 \end{bmatrix}$$

A constante a é determinada da normalização

$$a + 2a = 1 \Rightarrow a = 1/3$$

Portanto, a 1ª distribuição estacionária será

$$\boxed{\vec{p}_1^* = \begin{bmatrix} 1/3 \\ 2/3 \\ 0 \\ 0 \end{bmatrix}}$$

(2.4)

A outra distribuição é obtida de maneira semelhante:

$$Q \vec{p}_2^* = \begin{bmatrix} 0 \\ 0 \\ \frac{c}{4} + \frac{3d}{4} \\ \frac{3c}{4} + \frac{d}{4} \end{bmatrix} - \begin{bmatrix} 0 \\ 0 \\ c \\ d \end{bmatrix} = \vec{p}_2^*$$

Portanto

$$\frac{c}{4} + \frac{3d}{4} = c \Rightarrow c = d$$

Assim

$$\boxed{\vec{p}_2^* = \begin{bmatrix} 0 \\ 0 \\ 1/2 \\ 1/2 \end{bmatrix}}$$

(2.5)

(c) Se o sistema começa em $\vec{P}(0) = (\frac{1}{2}, 0, \frac{1}{2}, 0)$, então ele tem 50% de chance de começar em (1, 2) e 50% de chance de ele começar em (3, 4). Se ele começa em 1 ou 2, ele sempre tenderá para \vec{P}_1 e se ele começar em 3 ou 4, sempre tenderá para \vec{P}_2 . Portanto, para essa condição inicial o sistema tenderá para

$$\vec{P}(t \rightarrow \infty) = \frac{1}{2} \vec{P}_1 + \frac{1}{2} \vec{P}_2 = \begin{bmatrix} 1/6 \\ 2/6 \\ 4/4 \\ 1/4 \end{bmatrix} \quad (2.6)$$

3) Um rei se movendo em um tabuleiro de xadrez

Este problema se enquadra no problema do passeio aleatório em um grafo não direcionado. Para este problema sabemos que a distribuição estacionária será

$$p_m^* = \frac{d_m}{\sum_m d_m}$$

Onde d_m é a conectividade de cada sitio.

Temos 3 categorias de sitio no total

Quina: 4 sitios, $d = 3$

Lados: $4 \times 6 = 24$ sitios, $d = 5$

Meio: $64 - 28 = 36$ sitios, $d = 8$

Portanto

$$\sum_m d_m = 36 \times 8 + 24 \times 5 + 4 \times 3 = 384$$

e

$$p^*(\text{quina}) = \frac{3}{384}$$

$$p^*(\text{lado}) = \frac{5}{384}$$

$$p^*(\text{meio}) = \frac{8}{384}$$