



**CC-226**

# **Introdução à Análise de Padrões**

**Prof. Carlos Henrique Q. Forster**

**Inferência com Bayes**



# Distribuição multivariada- PDF conjunta

Definimos a função de densidade de probabilidade conjunta no caso de mais de uma variável:

$$p(x, y) = P(X = x \wedge Y = y)$$

Caso discreto:

$$P[(X, Y) \in A] = \sum_A p(x, y)$$

Caso contínuo:

$$P[(X, Y) \in A] = \int \int_A p(x, y) dx dy$$

Probabilidade de ocorrer uma instância dentro de um (hiper-)retângulo

$$P(a_1 \leq X_1 \leq b_1, \dots, a_l \leq X_l \leq b_l) = \int_{a_1}^{b_1} \dots \int_{a_l}^{b_l} p(x_1, \dots, x_l) dx_1 \dots dx_l$$



# Probabilidade Marginal

Corresponde à soma de todas probabilidades conjuntas para um dado eixo

$$p_x(x) = \sum_y p(x, y)$$

$$p_y(y) = \sum_x p(x, y)$$

As funções  $p_x$  e  $p_y$  são funções de densidade de probabilidade marginal.



# Covariância

Valor esperado no caso conjunto:

$$E[h(x, y)] = \int \int_{\Omega} h(x, y)p(x, y)dxdy$$

Covariância

$$Cov(x, y) = E[(x - \mu_x) \cdot (y - \mu_y)]$$

$$Cov(x, y) = \int \int_{\Omega} (x - \mu_x)(y - \mu_y)p(x, y)dxdy$$

$$Cov(x, y) = E[x \cdot y] - \mu_x \cdot \mu_y$$



# Correlação

Coefficiente de correlação

$$\text{Corr}(x, y) = \rho_{x,y} = \frac{\text{Cov}(x, y)}{\sigma_x \cdot \sigma_y}$$

Propriedade

$$\text{Corr}(aX + b, cY + d) = \text{Corr}(X, Y)$$



# Independência Estatística

Duas variáveis aleatórias são independentes se e só se

$$p(x, y) = p_x(x) \cdot p_y(y), \forall (x, y)$$

Se  $X$  e  $Y$  são independentes,  $\rho = 0$ .



# Matriz de Covariância

Seja  $\sigma_{xy} = Cov(x, y)$ .

Notar que  $\sigma_{xy} = \sigma_{yx}$  e que  $\sigma_{xx} = Cov(x, x) = E[(x - \mu_x)^2] = \sigma_x^2$

A matriz de covariância  $\Sigma$  é definida como

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1n} & \sigma_{2n} & \dots & \sigma_n^2 \end{pmatrix}$$

Para um vetor coluna de variáveis aleatórias  $\mathbf{x}$  com vetor média  $\mu$

$$\Sigma = E_{\mathbf{x}}[(\mathbf{x} - \mu)(\mathbf{x} - \mu)^T]$$



# Distribuição Normal Multivariada

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{m/2} \|\Sigma\|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)$$

$$\boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_m \end{pmatrix} \quad \Sigma = \begin{pmatrix} \sigma_{11}^2 & \sigma_{12} & \cdots & \sigma_{1m} \\ \sigma_{12} & \sigma_{22}^2 & \cdots & \sigma_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1m} & \sigma_{2m} & \cdots & \sigma_{mm}^2 \end{pmatrix}$$



# Exemplo em 2 dimensões

Write r.v.  $\mathbf{X} = \begin{pmatrix} X \\ Y \end{pmatrix}$  Then define  $X \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  to mean

$$p(\mathbf{x}) = \frac{1}{2\pi \|\boldsymbol{\Sigma}\|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)$$

Where the Gaussian's parameters are...

$$\boldsymbol{\mu} = \begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix} \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{pmatrix}$$

Where we insist that  $\boldsymbol{\Sigma}$  is symmetric non-negative definite


It turns out that  $E[X] = \boldsymbol{\mu}$  and  $\text{Cov}[X] = \boldsymbol{\Sigma}$ . (Note that this is a resulting property of Gaussians, not a definition)



# Distância de Mahalanobis

1. Begin with vector  $\mathbf{x}$
2. Define  $\delta = \mathbf{x} - \mu$
3. Count the number of contours crossed of the ellipsoids formed  $\Sigma^{-1}$

$D = \text{this count} = \text{sqrt}(\delta^T \Sigma^{-1} \delta)$   
= Mahalanobis Distance  
between  $\mathbf{x}$  and  $\mu$



$$p(\mathbf{x}) = \frac{1}{2\pi \|\Sigma\|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu)\right)$$








# Gaussiana com eixos alinhados

$$\boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_m \end{pmatrix} \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma^2_1 & 0 & 0 & \dots & 0 & 0 \\ 0 & \sigma^2_2 & 0 & \dots & 0 & 0 \\ 0 & 0 & \sigma^2_3 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & \sigma^2_{m-1} & 0 \\ 0 & 0 & 0 & \dots & 0 & \sigma^2_m \end{pmatrix}$$

# Gaussiana esférica

$$\boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_m \end{pmatrix} \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma^2 & 0 & 0 & \dots & 0 & 0 \\ 0 & \sigma^2 & 0 & \dots & 0 & 0 \\ 0 & 0 & \sigma^2 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & \sigma^2 & 0 \\ 0 & 0 & 0 & \dots & 0 & \sigma^2 \end{pmatrix}$$

# Propriedades das Gaussianas (A. Moore)





# Noção da dimensionalidade

- Considere uma variável  $X$  e cada componente  $x_i$  independente

Considere uma amostra de tamanho 10000 e fazemos a poda de 5% dos valores extremos para cada variável.

Quanto sobra da amostra para diferentes dimensões (no. de atributos) dos dados?



# Solução

- Para uma variável, multiplica por 95%:
  - $10000 * 0.95 = 9500$
- Para duas dimensões, multiplica novamente por 95%:
  - 9025
- Para 10 dimensões, multiplica por  $(0.95)^{10}$ :
  - 5987 (quase metade dos dados foram podados)
- Para 50 dimensões:
  - 769
- Para 100 dimensões:
  - 59 (a grande maioria está nos 5% outliers de alguma variável)



# Probabilidade Condicional

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



# Exercício

- Num programa de TV você deve escolher uma dentre três portas das quais uma delas tem um prêmio. O apresentador escolhe uma das portas que você não escolheu e abre para mostrar que o prêmio não está lá. Você é dado a oportunidade de trocar a porta que escolheu pela outra que ainda não está aberta. Qual é a melhor opção?



# Exercício

<http://www.regentsprep.org/regents/math/algebra/APR3/PracCond.htm>

A survey of middle school students asked: What is your favorite winter sport? The results are summarized below:



**Favorite Winter Sport**

Grade	Snowboarding	Skiing	Ice Skating	TOTAL
6th	68	41	46	155
7th	84	56	70	210
8th	59	74	47	180
<b>TOTAL</b>	211	171	163	545

Using these 545 students as the sample space, a student from this study is randomly selected.



## Exercício (cont)

- a.) What is the probability of selecting a student whose favorite sport is skiing?
- b.) What is the probability of selecting a 6th grade student?
- c.) If the student selected is a 7th grade student, what is the probability that the student prefers ice-skating?
- d.) If the student selected prefers snowboarding, what is the probability that the student is a 6th grade student?
- e.) If the student selected is an 8th grade student, what is the probability that the student prefers skiing or ice-skating?

Part a:  $171/545$

Part b:  $155/545 = 31/109$

Part c:  $70/210 = 1/3$

Part d:  $68/211$

Part e:  $(74 + 47)/180 = 121/180$



# Exercício

- Na tabela dada, identificar ou calcular:
  - Distribuição de probabilidade conjunta  $P(A,B)$
  - Probabilidades marginais de cada variável  $P(A)$  e  $P(B)$
  - Probabilidades condicionais  $P(A|B)$  e  $P(B|A)$
- Qual a relação entre  $P(A|B)$  e  $P(B|A)$ ?  
(que tal montar uma tabela dividindo uma pela outra?)