



CT 720 Tópicos em Aprendizagem de Máquina e
Classificação de Padrões



2-Fundamentos Matemáticos

Conteúdo

1. Introdução
2. Álgebra linear
3. Otimização de Lagrange
4. Teoria de probabilidade
5. Teste de hipóteses
6. Teoria da informação
7. Complexidade computacional

1-Introdução

- Objetivos

- introduzir/comentar notação
- revisar conceitos
- contextualizar o conteúdo ao curso

- Referências

2-Algebra linear

- Notação e preliminares

$$\mathbf{x} \in \mathbf{R}^d$$

$$\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_d \end{pmatrix} \quad \mathbf{x}^t = (x_1 \ x_2 \ \cdots \ x_d)$$

$$\mathbf{M} = [m_{ij}] \ (n \times d), \quad \mathbf{M}: (n \times d)$$


- Produto interno (escalar)

$$\mathbf{x}^t \mathbf{y} = \sum_{i=1}^d x_i y_i = \mathbf{y}^t \mathbf{x}$$

$$\|\mathbf{x}\| = \sqrt{\mathbf{x}^t \mathbf{x}}$$

$$\theta = \frac{\mathbf{x}^t \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|}$$

$$|\mathbf{x}^t \mathbf{y}| \leq \|\mathbf{x}\| \|\mathbf{y}\| \quad (\text{Cauchy - Schwarz})$$



- Independência linear

$\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ LI varre espaço dimensão n

- Produto externo

$$\mathbf{xy}^t = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_d \end{pmatrix} (y_1 \quad y_2 \quad \dots \quad y_n) = \begin{bmatrix} x_1 y_1 & x_1 y_2 & \dots & x_1 y_n \\ x_2 y_1 & x_2 y_2 & \dots & x_2 y_n \\ \vdots & \vdots & \ddots & \vdots \\ x_d y_1 & x_d y_2 & \dots & x_d y_n \end{bmatrix}$$

- Gradiente

$$y = f(\mathbf{x}), \quad f : \mathbf{U}^d \rightarrow \mathbf{V}, \quad \mathbf{x} \in \mathbf{U}^d$$

$$\nabla f(\mathbf{x}) = \text{grad}f(\mathbf{x}) = \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = \begin{pmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_d} \end{pmatrix}$$

■ Jacobiano

$$\mathbf{f} : \mathbf{U}^d \rightarrow \mathbf{V}^n, \mathbf{x} \in \mathbf{U}^d$$

$$\mathbf{J}(\mathbf{x}) = \frac{\partial \mathbf{f}(\mathbf{x})}{\partial \mathbf{x}} = \begin{pmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \dots & \frac{\partial f_1(\mathbf{x})}{\partial x_d} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_n(\mathbf{x})}{\partial x_1} & \dots & \frac{\partial f_n(\mathbf{x})}{\partial x_d} \end{pmatrix}$$

■ $\mathbf{M} = \mathbf{M}(\theta)$

$$\frac{\partial \mathbf{M}}{\partial \theta} = \begin{pmatrix} \frac{m_{11}}{\partial \theta} & \dots & \frac{m_{1d}}{\partial \theta} \\ \vdots & \ddots & \vdots \\ \frac{m_{n1}}{\partial \theta} & \dots & \frac{m_{nd}}{\partial \theta} \end{pmatrix}$$

- Derivadas de matrizes

$$\frac{\partial}{\partial \theta} [\mathbf{M}^{-1}(\theta)] = -\mathbf{M}^{-1} \frac{\partial \mathbf{M}}{\partial \theta} \mathbf{M}^{-1}$$

$$\frac{\partial}{\partial \mathbf{x}} [\mathbf{M}\mathbf{x}] = \mathbf{M}$$

$$\frac{\partial}{\partial \mathbf{x}} [\mathbf{y}^t \mathbf{x}] = \frac{\partial}{\partial \mathbf{x}} [\mathbf{x}^t \mathbf{y}] = \mathbf{y}$$

$$\frac{\partial}{\partial \mathbf{x}} [\mathbf{x}^t \mathbf{M}\mathbf{x}] = [\mathbf{M} + \mathbf{M}^t] \mathbf{x}$$

- Inversão de matrizes e pseudo-inversas

$$\mathbf{M}\mathbf{M}^{-1} = \mathbf{I}$$

$$\mathbf{M}^{-1} = \frac{\text{Adj}[\mathbf{M}]}{|\mathbf{M}|}$$

$$\mathbf{M}^* = [\mathbf{M}^t\mathbf{M}]^{-1}\mathbf{M}^t$$

$$\mathbf{M}^*\mathbf{M} = \mathbf{I}$$

$$[\mathbf{M}\mathbf{N}]^{-1} = \mathbf{N}^{-1}\mathbf{M}^{-1}$$

- Série de Taylor

$$f(\mathbf{x}) = f(\mathbf{x}_0) + \left[\frac{\partial f}{\partial \mathbf{x}} \right]_{\mathbf{x}=\mathbf{x}_0}^t (\mathbf{x} - \mathbf{x}_0) + \frac{1}{2!} (\mathbf{x} - \mathbf{x}_0)^t \left[\frac{\partial^2 f}{\partial \mathbf{x}^2} \right]_{\mathbf{x}=\mathbf{x}_0} (\mathbf{x} - \mathbf{x}_0) + O(\|\mathbf{x} - \mathbf{x}_0\|^3)$$

■ Autovalores e autovetores

$$\mathbf{M}\mathbf{x} = \lambda\mathbf{x} \quad \mathbf{M}(d \times d), \mathbf{x} \in \mathbf{R}^d$$

$$(\mathbf{M} - \lambda\mathbf{I})\mathbf{x} = \mathbf{0}$$

$\mathbf{x} = \mathbf{e}_j$ autovetor correspondente a λ_j

$$|\mathbf{M} - \lambda\mathbf{I}| = \lambda^d + a_1\lambda^{d-1} + \dots + a_{d-1}\lambda + a_d$$

$$\text{tr}[\mathbf{M}] = \sum_{i=1}^d \lambda_i$$

$$|\mathbf{M}| = \prod_{i=1}^d \lambda_i$$

3-Otimização de Lagrange

$$\begin{aligned} &\min(\max) f(\mathbf{x}) \\ &\text{s.a} \quad g(\mathbf{x}) = \mathbf{0} \end{aligned}$$

$$L(\mathbf{x}, \lambda) = f(\mathbf{x}) + \lambda g(\mathbf{x})$$

$$\frac{\partial L(\mathbf{x}, \lambda)}{\partial \mathbf{x}} = \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} + \lambda \frac{\partial g(\mathbf{x})}{\partial \mathbf{x}} = 0$$

4-Teoria de probabilidade

- Variável aleatória
 - variável cujo valor depende de uma probabilidade
 - processo de atribuir um número real $x(\zeta)$ a cada $\zeta \in \chi$

- Variável aleatória discreta

$$\chi = \{v_1, v_2, \dots, v_m\}$$

$$p_i = \Pr\{x = v_i\}, i = 1, \dots, m$$

$$p_i \geq 0$$

$$\sum_i p_i = 1$$

■ Valores esperados

$$E[x] = \mu = \sum_{x \in \mathcal{X}} xP(x) = \sum_{i=1}^m v_i p_i$$

$$E[f(x)] = \sum_{x \in \mathcal{X}} f(x)P(x)$$

$$E[\alpha_1 f_1(x) + \alpha_2 f_2(x)] = \alpha_1 E[f_1(x)] + \alpha_2 E[f_2(x)] \quad \text{Operador linear}$$

$$E[x^2] = \sum_{x \in \mathcal{X}} x^2 P(x) \quad \text{segundo momento}$$

$$\text{Var}[x] = \sigma^2 = E[(x - \mu)^2] = \sum_{x \in \mathcal{X}} (x - \mu)^2 P(x)$$

$$\text{Var}[x] = E[x^2] - (E[x])^2$$

$$\text{Se } v_1 = 0, v_2 = 1 \text{ e } p = \Pr[x = 1] \text{ então } \mu = p \text{ e } \sigma = \sqrt{p(1-p)}$$


■ Desigualdade de Chebyshev

$$\Pr[|x - \mu| > n\sigma] \leq \frac{1}{n^2}, \quad n > 1$$

$$\Pr[|x - \mu| \leq \sigma] \approx 0.68$$

$$\Pr[|x - \mu| \leq 2\sigma] \approx 0.95$$

$$\Pr[|x - \mu| \leq 3\sigma] \approx 0.997$$



Distribuição Normal

- Pares de variáveis aleatórias discretas

$$X = \{v_1, v_2, \dots, v_m\} \quad Y = \{w_1, w_2, \dots, w_n\}$$

(x, y) : vetor (ponto) espaço $X \times Y$

$$p_{ij} = \Pr[x = v_i, y = w_j]$$

$P(x, y)$ = função distribuição conjunta de probabilidade
(*joint probability mass function*)

$$P(x, y) \geq 0 \quad \sum_{x \in X} \sum_{y \in Y} P(x, y) = 1$$

$$\left. \begin{aligned} P_x(x) &= \sum_{y \in Y} P(x, y) \\ P_y(y) &= \sum_{x \in X} P(x, y) \end{aligned} \right\} \text{Distribuições marginais}$$

- Independência estatística

$$P(x, y) = P(x)P(y)$$

$$p_i = \Pr[x = v_i]$$

$$q_j = \Pr[x = w_j]$$

$$p_i q_j = P(v_i)P(w_j)$$

- Valores esperados: funções de duas variáveis

$$E[f(x, y)] = \sum_{x \in X} \sum_{y \in Y} f(x, y)P(x, y)$$

$$E[\alpha_1 f_1(x, y) + \alpha_2 f_2(x, y)] = \alpha_1 E[f_1(x, y)] + \alpha_2 E[f_2(x, y)]$$

■ Primeiros momentos

$$\mu_x = E[x] = \sum_{x \in X} \sum_{y \in Y} x P(x, y)$$

$$\mu_y = E[y] = \sum_{x \in X} \sum_{y \in Y} y P(x, y)$$

■ Variâncias

$$\sigma_x^2 = \text{Var}[x] = E[(x - \mu_x)^2] = \sum_{x \in X} \sum_{y \in Y} (x - \mu_x)^2 P(x, y)$$

$$\sigma_y^2 = \text{Var}[y] = E[(y - \mu_y)^2] = \sum_{x \in X} \sum_{y \in Y} (y - \mu_y)^2 P(x, y)$$

- Covariância

$$\sigma_{xy} = E[(x - \mu_x)(y - \mu_y)] = \sum_{x \in X} \sum_{y \in Y} (x - \mu_x)(y - \mu_y)P(x, y)$$

- Generalização

$$\boldsymbol{\mu} = E[\mathbf{z}] = \sum_{\mathbf{z} \in \mathbf{Z}} \mathbf{z}P(\mathbf{z}) \quad \mathbf{z} = (x, y) \in \mathbf{Z} = X \times Y$$

$$\boldsymbol{\Sigma} = E[(\mathbf{z} - \boldsymbol{\mu})(\mathbf{z} - \boldsymbol{\mu})^t]$$

- Coeficiente de correlação

$$\rho = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad -1 \leq \rho \leq 1$$

■ Observações

x e y estatisticamente independentes $\Rightarrow \sigma_{xy} = 0$

$\sigma_{xy} = 0 \Rightarrow x$ e y não correlatas

x e y não correlatas $\not\Rightarrow x$ e y são independentes

x e y não correlatas $\Rightarrow x$ e y são independentes se distribuição for normal

x e y estatisticamente independentes $\Rightarrow E[f(x)g(y)] = E[f(x)]E\{g(y)\}$

■ Cauchy Schwarz

$$\sigma_{xy} \leq \sigma_x^2 \sigma_y^2$$

- Probabilidade condicional

$$\Pr[x = v_i | y = w_j] = \frac{\Pr[x = v_i, y = w_j]}{\Pr[y = w_j]}$$

$$P(x | y) = \frac{P(x, y)}{P(y)}$$

- Probabilidade total

evento A ocorre em m diferentes maneiras A_1, A_2, \dots, A_m
sub-eventos A_1, A_2, \dots, A_m mutuamente exclusivos

$$P(y) = \sum_{x \in X} P(x, y)$$

- Teorema de Bayes

$$P(x, y) = P(y | x)P(x)$$

$$P(x | y) = \frac{P(x, y)}{P(y)} = \frac{P(y | x)P(x)}{\sum_{x \in X} P(y | x)P(x)}$$

$$P(x | y) = \frac{P(y | x)P(x)}{\sum_{x \in X} P(y | x)P(x)}$$

Regra de Bayes

posteriori = (likelihood × priori) / evidência

probabilidade a posteriori de uma causa, uma vez observado o efeito

- Vetor de variáveis aleatórias

$$\mathbf{x} = (x_1 x_2 \cdots x_d)^t$$

$$P(\mathbf{x}) \geq 0 \quad \sum P(\mathbf{x}) = 1$$

$$P(\mathbf{x}) = P_{x_1}(x_1)P_{x_2}(x_2)\cdots P_{x_d}(x_d) = \prod_{i=1}^d P_{x_i}(x_i)$$

Variáveis independentes

$$P_{x_i}(x_i) = \sum_{j \neq i}^d P(x_1, x_2, \cdots, x_d)$$

Distribuição marginal

$$P(x_1, x_4) = \sum_{x_2} \sum_{x_3} \sum_{x_5} P(x_1, x_2, x_3, x_4, x_5)$$

- Vetor de variáveis aleatórias (cont.)

$$\mathbf{x} = (x_1 x_2 \cdots x_d)$$

$$P(x_1, x_2 | x_3) = \frac{P(x_1, x_2, x_3)}{P(x_3)}, \quad P(x_1, x_2, x_3) = \sum_{x_4} \sum_{x_5} P(x_1, x_2, x_3, x_4, x_5)$$

$$P(\mathbf{x}_1, \mathbf{x}_2) = \frac{P(\mathbf{x}_2 | \mathbf{x}_1)}{\sum_{\mathbf{x}_1} P(\mathbf{x}_2 | \mathbf{x}_1) P(\mathbf{x}_1)}$$

$\mathbf{x}_1, \mathbf{x}_2$ vetores

- Esperanças e vetores médios

$$\mathbf{f}(\mathbf{x}) = \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ \vdots \\ f_n(\mathbf{x}) \end{bmatrix} \rightarrow E(\mathbf{f}) = \begin{bmatrix} E[f_1(\mathbf{x})] \\ E[f_2(\mathbf{x})] \\ \vdots \\ E[f_n(\mathbf{x})] \end{bmatrix} = \sum_{\mathbf{x}} \mathbf{f}(\mathbf{x})P(\mathbf{x})$$

$$\boldsymbol{\mu} = E[\mathbf{x}] = \begin{bmatrix} E[x_1] \\ E[x_2] \\ \vdots \\ E[x_d] \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_d \end{bmatrix} = \sum_{\mathbf{x}} \mathbf{x}P(\mathbf{x})$$

■ Matriz de covariância

$$\sigma_{ij} = \sigma_{ji} = E[(x_i - \mu_i)(x_j - \mu_j)] \quad i, j = 1, \dots, d$$

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1d} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{d1} & \sigma_{d2} & \cdots & \sigma_{dd} \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1d} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{d1} & \sigma_{d2} & \cdots & \sigma_d^2 \end{bmatrix}$$

$$\Sigma = E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^t]$$

Σ matriz positiva semidefinida (nenhum autovalor negativo)

- Variáveis aleatórias contínuas

Probabilidade $x \in (a, b)$

$$\Pr[x \in (a, b)] = \int_a^b p(x) dx$$

$$p(x) \geq 0 \quad \text{e} \quad \int_{-\infty}^{\infty} p(x) dx = 1$$

$p(x)$ função densidade de probabilidade

- Valor esperado, média e variância

$$E[f(x)] = \int_{-\infty}^{\infty} f(x)p(x)dx$$

$$\mu = E[x] = \int_{-\infty}^{\infty} xp(x)dx$$

$$\text{Var}[x] = \sigma^2 = E[(x - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 p(x)dx$$

$$\sigma^2 = E[x^2] - (E[x])^2$$

■ Caso multivariável

$$p(\mathbf{x}) \geq 0 \quad \text{e} \quad \int_{-\infty}^{\infty} p(\mathbf{x}) d\mathbf{x} = 1$$

$$E[\mathbf{f}(\mathbf{x})] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} \mathbf{f}(\mathbf{x}) p(\mathbf{x}) dx_1 dx_2 \cdots dx_d = \int_{-\infty}^{\infty} \mathbf{f}(\mathbf{x}) p(\mathbf{x}) d\mathbf{x}$$

$$\boldsymbol{\mu} = E[\mathbf{x}] = \int_{-\infty}^{\infty} \mathbf{x} p(\mathbf{x}) d\mathbf{x}$$

$$\boldsymbol{\Sigma} = E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^t] = \int_{-\infty}^{\infty} (\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^t p(\mathbf{x}) d\mathbf{x}$$

- Componentes dos vetores estatisticamente independentes

$$P(\mathbf{x}) = \prod_{i=1}^d p_{x_i}(x_i)$$

matriz de covariância é diagonal

- Funções densidade de probabilidade condicional

$$P(x|y) = \frac{p(x, y)}{p(y)}$$

- Regra de Bayes

$$P(x|y) = \frac{p(y|x)p(x)}{\int_{-\infty}^{\infty} p(y|x)p(x)dx}$$

- Esperança em função de variáveis particulares

$$E_{x_1}[f(x_1, x_2)] = \int_{-\infty}^{\infty} f(x_1, x_2)p(x_1)dx_1$$

■ Distribuição de soma de variáveis aleatórias independentes

x, y : variáveis aleatórias independentes e seja $z = x + y$

$$\mu_z = E[z] = E[x + y] = E[x] + E[y] = \mu_x + \mu_y$$

$$\sigma_z^2 = E[(z - \mu_z)^2] = E[(x + y - (\mu_x + \mu_y))^2] = \sigma_x^2 + \sigma_y^2$$

$$p(z) = p_x(x) * p_y(y) = \int_{-\infty}^{\infty} p_x(x) p_y(z - y) dx$$

média da soma é a soma das médias

variância da soma é a soma das variâncias

função densidade de probabilidade da soma é a convolução das densidades


■ Distribuição normal

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-1/2((x-\mu)^2/\sigma^2)}$$

$$E[1] = \int_{-\infty}^{\infty} p(x) dx = 1$$

$$E[x] = \int_{-\infty}^{\infty} xp(x) dx = \mu$$

$$E[(x-\mu)^2] = \int_{-\infty}^{\infty} (x-\mu)^2 p(x) dx = \sigma^2$$



$$\Pr[|x - \mu| \leq \sigma] \approx 0.68$$

$$\Pr[|x - \mu| \leq 2\sigma] \approx 0.95$$

$$\Pr[|x - \mu| \leq 3\sigma] \approx 0.997$$

- Distância de Mahalanobis

$$r = \frac{|x - \mu|}{\sigma}$$

- Variável aleatória padronizada

$$u = \frac{(x - \mu)}{\sigma}$$


$$p(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2} \sim N(0,1)$$

■ Derivadas de Gaussianas

$$\frac{\partial}{\partial x} \left[\frac{1}{\sqrt{2\pi}\sigma} e^{-1/2(x)^2/\sigma^2} \right] = \frac{-x}{\sqrt{2\pi}\sigma^3} e^{-1/2(x^2/\sigma^2)} = \frac{-x}{\sigma^2} p(x)$$

$$\frac{\partial^2}{\partial x^2} \left[\frac{1}{\sqrt{2\pi}\sigma} e^{-1/2(x^2/\sigma^2)} \right] = \frac{1}{\sqrt{2\pi}\sigma^5} (-\sigma^2 + x^2) e^{-1/2(x^2/\sigma^2)} = \frac{-\sigma^2 + x^2}{\sigma^4} p(x)$$

$$\frac{\partial^3}{\partial x^3} \left[\frac{1}{\sqrt{2\pi}\sigma} e^{-1/2(x^2/\sigma^2)} \right] = \frac{1}{\sqrt{2\pi}\sigma^7} (3x\sigma^2 - x^3) e^{-1/2(x^2/\sigma^2)} = \frac{-3x\sigma^2 - x^3}{\sigma^6} p(x)$$



■ Integrais de Gaussianas

$$\operatorname{erf}(u) = \frac{1}{\sqrt{\pi}} \int_0^u e^{-x^2} dx$$

Função erro


$$\Gamma(n+1) = \int_0^{\infty} x^n e^{-x} dx$$

Função Gama

$$\Gamma(n+1) = n\Gamma(n)$$

$$\Gamma(1/2) = \sqrt{\pi}$$

$$\Gamma(n+1) = n! \quad n \text{ inteiro}$$



- Densidades normais multivariáveis

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

$$\boldsymbol{\mu} = E[\mathbf{x}] = \int_{-\infty}^{\infty} \mathbf{x} p(\mathbf{x}) d\mathbf{x}$$


$$\boldsymbol{\Sigma} = E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^t] = \int_{-\infty}^{\infty} (\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^t p(\mathbf{x}) d\mathbf{x}$$

$$d = 2$$

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix} \quad \rho = \frac{\sigma_{12}}{\sigma_1\sigma_2}$$

$$|\Sigma| = \sigma_1^2\sigma_2^2(1-\rho^2)$$

$$\Sigma^{-1} = \frac{1}{1-\rho^2} \begin{bmatrix} 1/\sigma_1^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & 1/\sigma_2^2 \end{bmatrix}$$



5-Teste de hipóteses

- Conceito

- Mecanismo formal para decidir se os resultados de um experimento são significativos ou acidentais.

- Conjunto de amostras (observações)

$$\chi_n = \{x_1, x_2, \dots, x_n\}$$

x_i : amostras com distribuição D_0 ou outra distribuição

Classificação: qual distribuição é a fonte das amostras?
 D_0 ou a outra distribuição?

- Teste de hipóteses

Assume inicialmente que D_0 é a fonte das amostras: hipótese nula H_0
A partir do valor de uma amostra pergunta-se se podemos rejeitar a hipótese nula, isto é, afirmar com certo grau de confiança (expresso como uma probabilidade) que a amostra não foi gerada por D_0 .


- Exemplo: suponha que D_0 seja $p(x) \sim N(0,1)$ e $x = 0.3$

$$\Pr[|x - \mu| \leq \sigma] \approx 0.68$$

é provável que $x = 0.3$ tenha sido gerado por D_0 ?
e se $x = 5$?

H_0 : amostra é proveniente de uma Gaussiana com $\mu = 0$

■ Teste Qui-quadrado



● classe ω_1 (n_1)

● classe ω_2 (n_2)

$$n_1 + n_2 = n$$

$$\chi^2 = \sum_{i=1}^2 \frac{(n_{iL} - n_{ie})^2}{n_{ie}}$$

n_{iL} = número padrões classe ω_i colocadas em L pela regra candidata

$$n_{ie} = Pn_i$$

$$\chi^2 \geq 0$$

$\chi_{\alpha,df}^2 > v_{cri}$ hipótese nula é rejeitada

α = nível de significância; df = graus de liberdade

Valores críticos Qui-quadrado para $\alpha = 0.05$ e 0.02

<i>df</i>	.05	.01	<i>df</i>	.05	.01	<i>df</i>	.05	.01
1	3.84	6.64	11	19.68	24.72	21	32.67	38.93
2	5.99	9.21	12	21.03	26.22	22	33.92	40.29
3	7.82	11.34	13	22.36	27.69	23	35.17	41.64
4	9.49	13.28	14	23.68	29.14	24	36.42	42.98
5	11.07	15.09	15	25.00	30.58	25	37.65	44.31
6	12.59	16.81	16	26.30	32.00	26	38.88	45.64
7	14.07	18.48	17	27.59	33.41	27	40.11	46.96
8	15.51	20.09	18	28.87	34.80	28	41.34	48.28
9	16.92	21.67	19	30.14	37.57	29	42.56	49.59
10	18.31	23.21	20	31.41	37.57	30	43.77	50.89

■ Exemplo teste Qui-quadrado

Em 180 lances de um par de dados, foram observados 37 *setes* e 12 *três*. Testar a hipótese do dado ser honesto, para um nível de significância $\alpha = 0.05$

H_0 : dado é honesto

H_1 : dado não é honesto

$\alpha = 0.05$

$df = k - 1 = 2 - 1 = 1$ ($k =$ número classes/valores observados)

Eventos	<i>sete</i>	<i>três</i>
n_{iL} (observado)	37	12
n_{ie} (esperado)	30	10

$$P(\textit{sete}) = 6/36 = 1/6 \rightarrow n_{ie}(\textit{sete}) = 180(1/6) = 30$$

$$P(\textit{três}) = 2/36 = 1/18 \rightarrow n_{ie}(\textit{três}) = 180(1/18) = 10$$

$$\chi^2 = \frac{(37-30)^2}{30} + \frac{(12-10)^2}{10} = \frac{49}{30} + \frac{4}{10} = 2.03$$

$$\chi^2 < \nu_{crit} = 3.84$$

Aceita-se H_0

6-Teoria da informação

- Entropia

$\{v_1, v_2, \dots, v_m\}$ conjunto de símbolos

$\{P_1, P_2, \dots, P_m\}$ probabilidades associadas

$$H = -\sum_{i=1}^m P_i \log_2 P_i \quad \text{bits}$$

$$H(f(x)) \leq H(x)$$

$$H = - \int_{-\infty}^{+\infty} p(x) \ln p(x) dx$$

$$H = 0.5 + \log_2(\sqrt{2\pi\sigma}) \quad p / \text{Gaussiana}$$

$$\sigma \rightarrow 0$$

$$\delta(x-a) = \begin{cases} 0 & x \neq a \\ \infty & x = a \end{cases} \quad \int_{-\infty}^{\infty} \delta(x) dx = 1$$

■ Entropia relativa

variável aleatória x

distribuições de probabilidades $p(x)$ e $q(x)$

$$D_{KL}(p(x), q(x)) = \sum_x q(x) \ln \frac{q(x)}{p(x)} \quad \text{Distância de Kullback-Leibler}$$

$$D_{KL}(p(x), q(x)) = \int_{-\infty}^{\infty} q(x) \ln \frac{q(x)}{p(x)} dx$$

distância entre distribuições de probabilidade

■ Informação mútua


variáveis aleatórias diferentes x e y

distribuições de probabilidades $p(x)$ e $q(y)$

$$I(p; q) = H(p) - H(p | q) = \sum_{x, y} r(x, y) \log_2 \frac{r(x, y)}{p(x)q(y)}$$

redução da incerteza sobre uma variável devido ao conhecimento de outra variável


- Relações entre entropia, entropia relativa e informação mútua



7-Complexidade computacional


- Limitante superior assintótico

$$O(g(x)) = \{ f(x) : \exists c > 0 \text{ e } x_0 > 0 \text{ tal que } 0 \leq f(x) \leq cg(x), \forall x \geq x_0 \}$$




- Limitante inferior assintótico

$$\Omega(g(x)) = \{ f(x) : \exists c > 0 \text{ e } x_0 > 0 \text{ tal que } 0 \leq cg(x) \leq f(x), \forall x \geq x_0 \}$$



- Limitantes assintóticos

$$\Theta(g(x)) = \{ f(x) : \exists c_1, c_2 > 0 \text{ e } x_0 > 0 \text{ tal que } 0 \leq c_1g(x) \leq f(x) \leq c_2g(x), \forall x \geq x_0 \}$$



Observação

Este material refere-se às notas de aula do curso CT 720 Tópicos Especiais em Aprendizagem de Máquina e Classificação de Padrões da Faculdade de Engenharia Elétrica e de Computação da Unicamp e do Centro Federal de Educação Tecnológica do Estado de Minas Gerais. Não substitui o livro texto, as referências recomendadas e nem as aulas expositivas. Este material não pode ser reproduzido sem autorização prévia dos autores. Quando autorizado, seu uso é exclusivo para atividades de ensino e pesquisa em instituições sem fins lucrativos.