

APRENDIZADO DE MÁQUINAS PARA FÍSICA

Aula IV

Testes de Hipóteses e
Goodness-of-fit



TESTE DE HIPÓTESES

- Queremos decidir a concordância entre os dados experimentais e um (ou mais) modelo(s)
 - H_0 **hipótese nula** é testada, e a que se espera verdadeira
 - H_1 **modelo alternativo** que complementa H_0
- Se considerarmos H_0 como o *background* ou fundo e H_1 como o *sinal*, temos a matriz confusão:

		realidade	
		Background (H_0)	Sinal (H_1)
decisão	Background (H_0)	Verdadeiro -	Falso - erro tipo 2
	Sinal (H_1)	Falso + erro tipo 1	Verdadeiro +

Para quantificar o nível de concordância dos dados com nossas hipóteses definimos um **teste estatístico** $t(\{x_i\})$ como uma **função escalar da amostra** $\{x_i\}$.
A utilidade do teste depende do seu poder de discriminação entre as hipóteses.

QUANTIFICANDO O TESTE


- Temos uma amostra de n medidas $\{x_i\}$. O teste estatístico é uma variável aleatória com PDFs $g(t|H_0)$ e $g(t|H_1)$.

* A probabilidade de rejeitar H_0 sendo verdadeira $\alpha = \int_{t_c}^{\infty} g(t|H_0)dt$

erro tipo 1:
"descoberta"
falsa

* A probabilidade de aceitar H_0 (e rejeitar H_1) sendo falsa $\beta = \int_{-\infty}^{t_c} g(t|H_1)dt$

erro tipo 2:
"perder" a
descoberta



α é a significancia
 $1-\beta$ é o poder

Para testar a hipótese nula escolhemos um valor para α e a partir dele determinamos o valor crítico t_c . Logo avaliamos nos dados $t_{obs}=t(\{x_i\})$, e se $t_{obs}<t_c$ aceitamos H_0 , caso contrário rejeitamos ela.

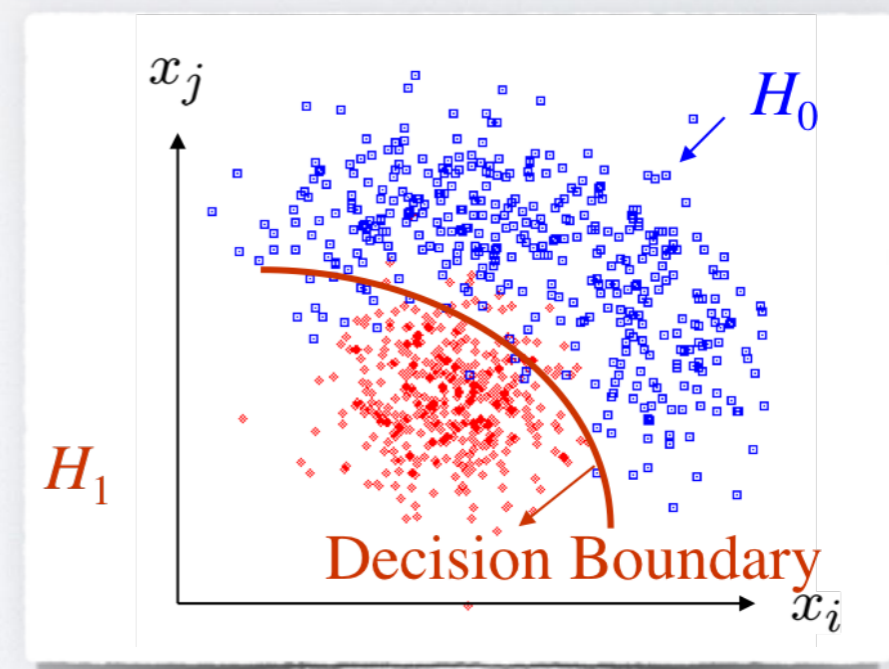
NEYMAN-PEARSON

- Existem muitas (infinitas!) possibilidades de estatística de teste t .
- Likelihood ratio : a razão entre os valores de máxima verossimilhança para H_0 e H_1

$$t(\{x_i\}) = \frac{\mathcal{L}(H_1 | \{x_i\})}{\mathcal{L}(H_0 | \{x_i\})} \text{ ou equivalente } t(\vec{x}) = \frac{f(\vec{x} | H_1)}{f(\vec{x} | H_0)}$$

- O lemma de Neyman-Pearson diz que para um nível de significância α fixo, o LR é o teste mais poderoso (menor β)

Após escolhermos um valor de α e um teste estatístico, o valor crítico $t_c = t(\vec{x})$ define uma “fronteira” de decisão (hyper-superfície no espaço \mathbb{R}^n) que separa a região de aceitação e a de rejeição.



PROCEDIMENTO I

Se conhecemos $f(\vec{x} | H_0)$ and $f(\vec{x} | H_1)$ analiticamente os passos a seguir são:

1. determinar a PDF da estatística de teste no caso da hipótese nula $g(t | H_0)$
2. Definir um valor para α levando em consideração as probabilidades de error tipo 1 e 2, e obter a região crítica e fronteira.
3. determinar o valor de $t_{obs} = t(\{x_i\})$ para os dados
4. analisar se t_{obs} se encontra na região crítica (rejeitar H_0) ou na região de aceitação (não tem suficiente evidência para rejeitar H_0)

DEFINIÇÕES

Property of discriminator:

Selection efficiency: probability to correctly identify signal events $\epsilon = 1 - \beta$

Misidentification probability: probability to misidentify as a background event β

Purity: fraction of signal in a positively identified sample = N_{V+} / N_{TOT+}

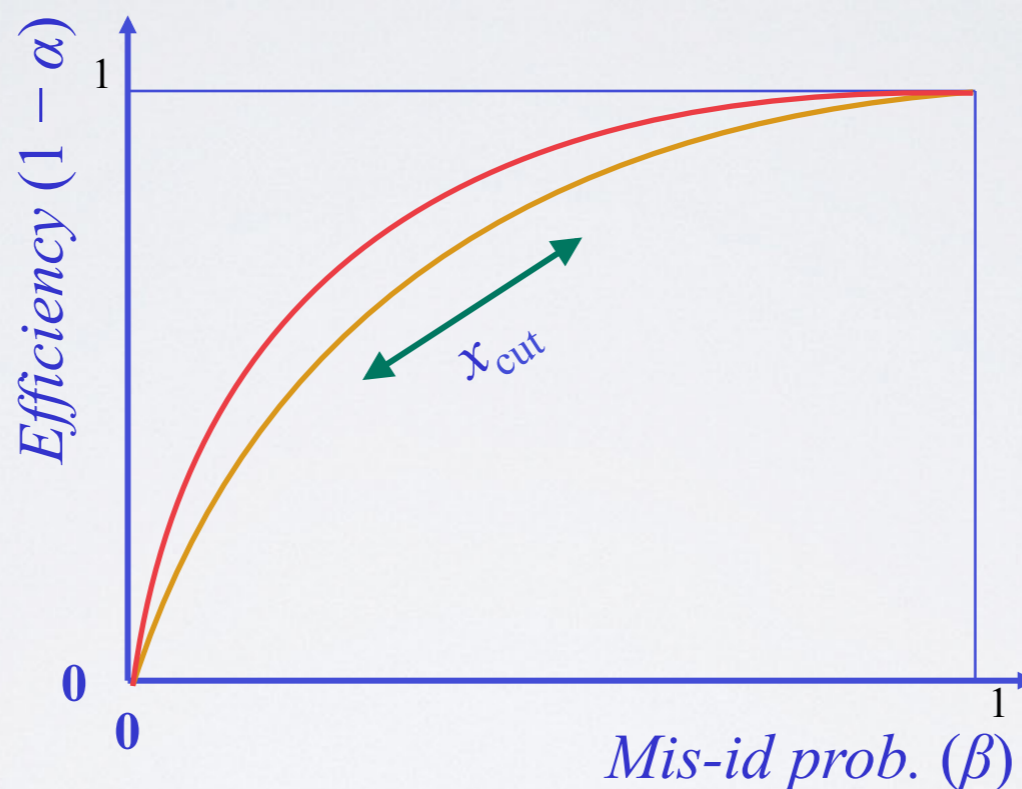
Depends on the signal and background composition! It is not a property of the discriminator only

Fake rate: fraction of background in a positively identified sample, = $1 - \text{Purity} = N_{F+} / N_{TOT+}$

		<i>realidade</i>	
		Background (H_0)	Sinal (H_1)
<i>decisão</i>	Background (H_0)	background rejection $\epsilon = 1 - \alpha$	β (misID)
	Sinal (H_1)	α N_{V+}	signal efficiency $\epsilon = 1 - \beta$ N_{T+}

$$N_{TOT+} = N_{T+} + N_{V+}$$

ANALISANDO A ESCOLHA DE t E O VALOR DO CORTE



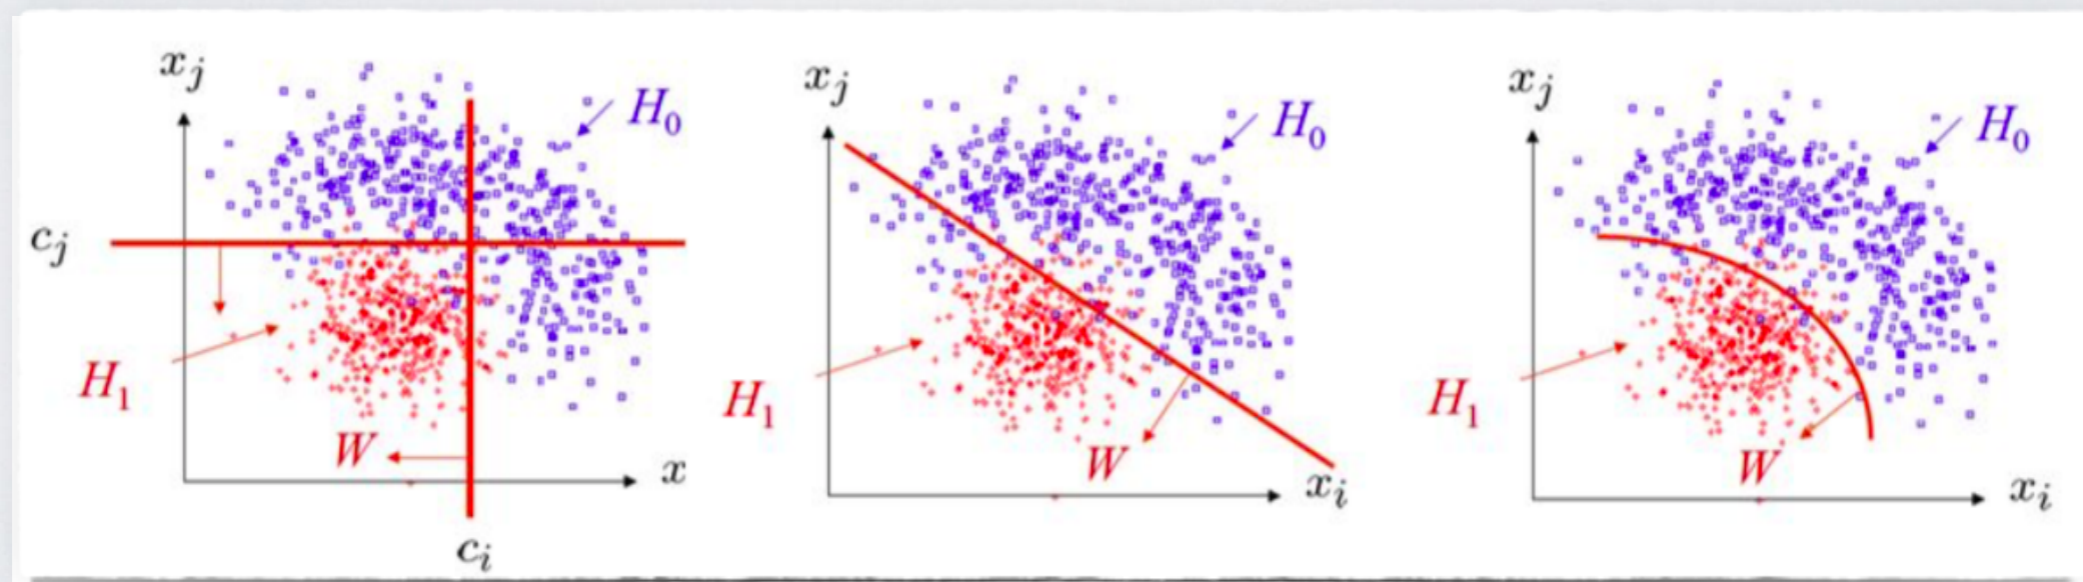
curvas ROC

Eficiência na identificação do background e taxa de falso negativo variam com a escolha do valor de “corte” (fronteira) no t . Um teste é melhor que outro para um mesmo valor de α se o valor de β é menor.

CONSTRUINDO t

Se não conhecemos as PDFs analiticamente, temos 2 opções:

- utilizar o método de Monte Carlo para gerar amostras e histogramas (em multiples dimensões) para H_0 e H_1 . (problema se temos muitas variáveis x_i)
- ou utilizar análise multi-variada para achar a fronteira (Fisher discriminant, BDT ou NN)

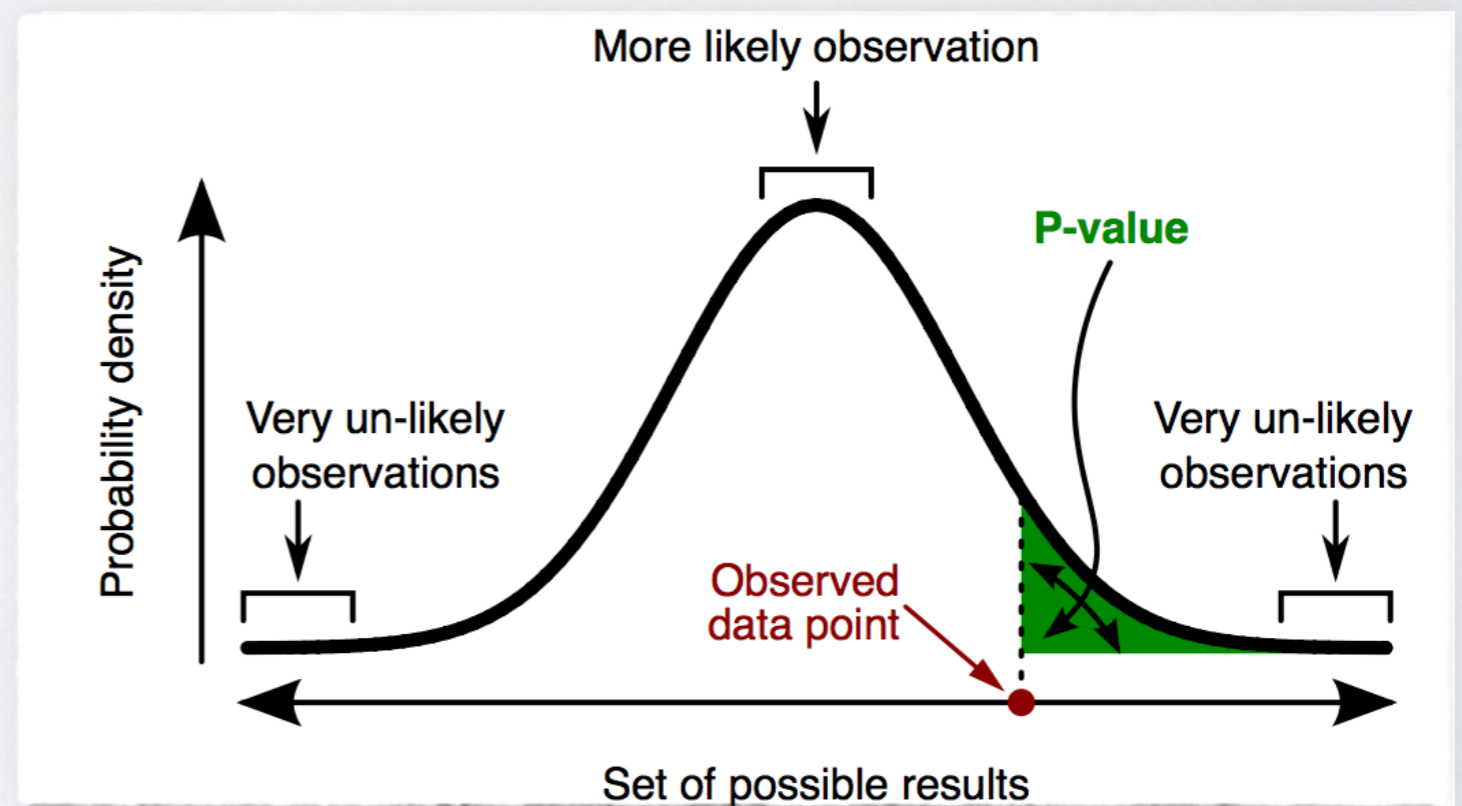


GOODNESS-OF-FIT

Se queremos quantificar a concordância de um teste com uma hipótese H_0 sem ter um modelo alternativo podemos avaliar o *goodness-of-fit*, quantificado pelo **p-value**: a probabilidade de se obter dados **tão ou mais** afastados da hipótese nula quanto os observados

$$p = \int_{t_{obs}}^{\infty} g(t | H_0) dt$$

- t_{obs} depende dos dados
- quanto menor o valor de p , maior a evidência **contra** H_0 (menor a chance de ser apenas flutuação)
- também chamado *nível de significância observado*



TESTE DE HIPÓTESE VS GOF

- If one had defined a critical region, the significance level α of the hypothesis test would correspond to the *P-value*
- In hypothesis test α is a constant chosen a priori, before looking into data, while in GOF the observed *P-value* is a random variable
- In hypothesis test the critical value (boundary) t_c is a function of the chosen α , while in GOF it's the value of the test statistic evaluated on data t_{obs}
- Although *P-value* are not confidence levels, sometimes one uses the notations $CL_b = 1 - P_0$ and $CL_{s+b} = P_1$ in analyses, where P_0 and P_1 are *P-values* for H_0 (*background*) and H_1 (*signal + background*) hypotheses

SIGNIFICÂNCIA EM Z

- Frequentemente em vez de usar *p-value* alguns estudos utilizam o valor **z**: o número de desvios padrões que o ponto teria se uma distribuição normal padrão ($\mu = 0$, $\sigma = 1$) tiver a área equivalente na calda da direita

$$p = \frac{1}{\sqrt{2\pi}} \int_z^{\infty} e^{-x^2/2} dx = \frac{1}{2} \left[1 - \text{Erf} \left(\frac{z}{\sqrt{2}} \right) \right]$$

p vem dos dados e a pdf, então **z** é achado invertendo a relação (ou tabelado)

- Em geral (em FAE) dizemos que temos uma observação quando $z \geq 3$ e uma evidência ou descobrimento se $z \geq 5$

EXEMPLO DIST. POISSON

- Probabilidade de uma observação de $n = n_s + n_b$ eventos com média esperada $\nu = \nu_s + \nu_b$

$$f(n | \nu_s, \nu_b) = \frac{(\nu_s + \nu_b)^n}{n!} e^{-(\nu_s + \nu_b)}$$

- Significância observada seria a probabilidade de se observar $n \geq n_{obs}$ considerando a hipótese nula, quer dizer que seja só uma flutuação do background, sem sinal no modelo ($\nu_s = 0$)

$$P(n \geq n_{obs} | H_0 : \nu_s = 0) = \sum_{k=n_{obs}}^{\infty} P(k | H_0) = \sum_{k=n_{obs}}^{\infty} \frac{\nu_b^k}{k!} e^{-\nu_b} = 1 - \sum_{k=0}^{n_{obs}-1} \frac{\nu_b^k}{k!} e^{-\nu_b}$$

TESTE DO χ^2 DE PEARSON

- Se temos um histograma com N classes e n_i eventos por classe (bin) e no modelo esperamos ter ν_i eventos, a estatística de teste χ^2 de Pearson quantifica a concordância dos dados ao modelo

$$\chi^2 = \sum_i^N \frac{(n_i - \nu_i)^2}{\nu_i}$$

- Se os dados em cada bin seguem uma distribuição de Poisson com média (e variância) = ν_i e $n_i > 5$, este teste segue a distribuição χ^2 com N variáveis e podemos avaliar o **p-value**

$$p = P(z \geq \chi^2) = \int_{\chi^2}^{\infty} f(x|N) dx = 1 - \int_0^{\chi^2} f(x|N) dx$$

lembrando

$$f(x|N) = \frac{1}{2^{N/2} \Gamma(N/2)} x^{(N/2-1)} \exp(-x/2)$$

⇒ dado um valor de χ^2 observado nos dados para um determinado N , podemos achar (tabelado, p.ex.) o **p-value**.