

3.33pt

Modelos Lineares Generalizados - Regressão Logística

Erica Castilho Rodrigues

01 de Julho de 2016

3.33pt

AIC

Introdução

- ▶ Vamos ver um critério para comparação de modelos.
- ▶ É muito utilizado para vários tipos de modelo.
- ▶ Mede o quão bem o modelo se ajusta aos dados.
- ▶ Porém penaliza pelo número de parâmetros.
- ▶ Leva assim à escolha de um modelo mais parcimonioso.

Akaike information criterion (AIC)

- ▶ É uma medida de qualidade de um modelo estatístico.
- ▶ Lida com o balanceamento que devemos ter entre:
 - ▶ complexidade e qualidade do ajuste.
- ▶ Deve ser usado apenas para comparação entre modelos.
- ▶ Não pode ser usado para testar o ajuste de modo absoluto.

- ▶ O AIC é definido por

$$AIC = 2p - 2l(\mathbf{y}, \theta)$$

onde

- ▶ onde p é um número de parâmetros do modelo;
 - ▶ $l(\mathbf{y}, \theta)$ é o máximo da log-verossimilhança.
- ▶ Se um modelo é bom o AIC deve ser alto ou baixo?

- ▶ O AIC é definido por

$$AIC = 2p - 2l(\mathbf{y}, \theta)$$

onde

- ▶ onde p é um número de parâmetros do modelo;
- ▶ $l(\mathbf{y}, \theta)$ é o máximo da log-verossimilhança.
- ▶ Se um modelo é bom o AIC deve ser alto ou baixo? Baixo.
- ▶ O melhor modelo será aquele com menor AIC.

- ▶ Vamos ver com detalhes os modelos para dados binários.
- ▶ Exemplos de resposta:
 - ▶ morto/vivo;
 - ▶ presente/absente.
- ▶ Podemos ter dois tipos de resposta.
- ▶ Resposta zero/um:
 - ▶ a variável resposta (Y_i) é uma Bernoulli.
- ▶ Temos então que

$$Y_i = \begin{cases} 1 & \text{se ocorre um sucesso} \\ 0 & \text{se ocorre um fracasso.} \end{cases}$$

- ▶ A função de densidade conjunta então é dada por

$$f(\mathbf{y}, \boldsymbol{\pi}) =$$

- ▶ Vamos ver com detalhes os modelos para dados binários.
- ▶ Exemplos de resposta:
 - ▶ morto/vivo;
 - ▶ presente/absente.
- ▶ Podemos ter dois tipos de resposta.
- ▶ Resposta zero/um:
 - ▶ a variável resposta (Y_i) é uma Bernoulli.
- ▶ Temos então que

$$Y_i = \begin{cases} 1 & \text{se ocorre um sucesso} \\ 0 & \text{se ocorre um fracasso.} \end{cases}$$

- ▶ A função de densidade conjunta então é dada por

$$f(\mathbf{y}, \boldsymbol{\pi}) = \prod_i \pi_i^{y_i} (1 - \pi_i)^{1-y_i}$$

- ▶ Número de sucessos:
 - ▶ a variável resposta (Y_j) é uma Binomial.
- ▶ A função de densidade conjunta então é dada por

$$f(\mathbf{y}, \boldsymbol{\pi}) =$$

- ▶ Número de sucessos:
 - ▶ a variável resposta (Y_i) é uma Binomial.
- ▶ A função de densidade conjunta então é dada por

$$f(\mathbf{y}, \boldsymbol{\pi}) = \prod_i \binom{n_i}{y_i} \pi_i^{y_i} (1 - \pi_i)^{1-y_i}$$

- ▶ Queremos descrever a proporção de sucessos $P_i = \frac{Y_i}{n_i}$ em cada subgrupo.
- ▶ Essa proporção deve ser explicada por covariáveis do problema.

- ▶ Sabemos que

$$E(Y_i) =$$

- ▶ Sabemos que

$$E(Y_i) = n_i \pi_i \quad \Rightarrow \quad E\left(\frac{Y_i}{n_i}\right) = \pi_i.$$

- ▶ Vamos modelar $E(P_i) = \pi_i$ da seguinte maneira

$$g(\pi_i) = \mathbf{x}_i^t \boldsymbol{\beta}$$

onde $g(\cdot)$ é

- ▶ Sabemos que

$$E(Y_i) = n_i \pi_i \quad \Rightarrow \quad E\left(\frac{Y_i}{n_i}\right) = \pi_i.$$

- ▶ Vamos modelar $E(P_i) = \pi_i$ da seguinte maneira

$$g(\pi_i) = \mathbf{x}_i^t \boldsymbol{\beta}$$

onde $g(\cdot)$ é função de ligação.

- ▶ Três tipos de funções de ligação mais usadas:
 - ▶ logística,
 - ▶ complemento log-log,
 - ▶ probit.

- ▶ A ligação logística é definida da seguinte maneira

- ▶ A ligação logística é definida da seguinte maneira

$$\log \left(\frac{\pi_i}{1 - \pi_i} \right) = \eta$$

- ▶ A ligação logística é definida da seguinte maneira

$$\log \left(\frac{\pi_i}{1 - \pi_i} \right) = \eta$$

$$\left(\frac{\pi_i}{1 - \theta_i} \right) = e^\eta$$

$$\pi_i = e^\eta - \theta_i e^\eta \quad \therefore \quad \theta_i(1 + e^\eta) = e^\eta$$

$$\pi_i = \frac{e^\eta}{1 + e^\eta}$$

- ▶ Dividindo o numerador e o denominador por e^η ficamos com

$$\theta_i = \frac{e^\eta(1/e^\eta)}{(1 + e^\eta)(1/e^\eta)} = \frac{1}{1 + e^{-\eta}}$$

- ▶ Ou seja, a função de ligação é dada por

$$E(Y_i) = \theta_i = \frac{1}{1 + e^{-x_i^T \beta}}$$

- ▶ Esse tipo de ligação é chamada ligação logística.
- ▶ Essa ligação pode levar a valores não válidos de θ_i ?

- ▶ Dividindo o numerador e o denominador por e^η ficamos com

$$\theta_i = \frac{e^\eta(1/e^\eta)}{(1 + e^\eta)(1/e^\eta)} = \frac{1}{1 + e^{-\eta}}$$

- ▶ Ou seja, a função de ligação é dada por

$$E(Y_i) = \theta_i = \frac{1}{1 + e^{-x_i^T \beta}}$$

- ▶ Esse tipo de ligação é chamada ligação logística.
- ▶ Essa ligação pode levar a valores não válidos de θ_i ? Não.
- ▶ Em que intervalo θ_i está definido?

- ▶ Dividindo o numerador e o denominador por e^η ficamos com

$$\theta_i = \frac{e^\eta(1/e^\eta)}{(1 + e^\eta)(1/e^\eta)} = \frac{1}{1 + e^{-\eta}}$$

- ▶ Ou seja, a função de ligação é dada por

$$E(Y_i) = \theta_i = \frac{1}{1 + e^{-x_i^T \beta}}$$

- ▶ Esse tipo de ligação é chamada ligação logística.
- ▶ Essa ligação pode levar a valores não válidos de θ_i ? Não.
- ▶ Em que intervalo θ_i está definido? $[0, 1]$.
- ▶ Observe que a função

$$\frac{1}{1 + e^{-\eta}}$$

está sempre dentro do intervalo $[0, 1]$.

- ▶ A ligação Probit é definida por

$$\Phi^{-1}(\theta_i) = x_i^T \beta \Rightarrow \theta_i = \Phi(x_i^T \beta)$$

onde $\Phi(\cdot)$ é a função de distribuição acumulada da $N(0, 1)$.

- ▶ Essa função também está definida no intervalo $[0, 1]$.
- ▶ A ligação Complemento log-log é dada por


$$\log(-\log(1 - \theta_i)) = x_i^T \beta$$

$$-\log(1 - \theta_i) = e^{x_i^T \beta} \quad \therefore \quad (1 - \theta_i) = \exp(-e^{x_i^T \beta})$$

$$\theta_i = 1 - \exp(-e^{x_i^T \beta})$$

- ▶ Também está definida no intervalo $[0, 1]$.
- ▶ Para valores pequenos de θ_i :
 - ▶ fica bem próxima da ligação logística.

O gráfico a seguir compara as três funções de ligação.



- ▶ Para esses modelos temos duas formas de resíduos mais usados:
 - ▶ componente da Deviance;
 - ▶ componente da Estatística de Pearson generalizada.
- ▶ O **Resíduo de Pearson** é definido por

$$X_i = \frac{(y_i - n_i \hat{\pi}_i)}{\sqrt{n_i \hat{\pi}_i (1 - \hat{\pi}_i)}}$$

- ▶ A soma dos seus quadrados resulta na Estatística de Pearson Generalizada

$$X^2 = \sum_i X_i^2.$$

- ▶ Podemos a verãõ padronizada do Resíduo de Pearson

$$X'_i = \frac{X_i}{\sqrt{1 - h_{ii}}}$$

onde h_{ij} é do termo da diagonal da matriz **H**.

- ▶ Vimos que a Deviance desse modelo é dada por

$$D = 2 \left[\sum_i y_i \log \left(\frac{y_i}{\hat{y}_i} \right) + (n_i - y_i) \log \left(\frac{n_i - \hat{y}_i}{n_i - y_i} \right) \right].$$

- ▶ A **Deviance Residual** é então definida por

$$d_i = \text{sign}(y_i - \hat{y}_i) \left(y_i \log \left(\frac{y_i}{\hat{y}_i} \right) + (n_i - y_i) \log \left(\frac{n_i - \hat{y}_i}{n_i - y_i} \right) \right)$$

a Deviance Residual Padronizada é definida por

$$r_{d_i} = \frac{d_i}{\sqrt{1 - h_{ij}}}$$

onde h_{ij} é o i -ésimo termo da diagonal da matriz **H**.

Exemplo:

- ▶ Deseja-se verificar a presença de sintomas de senilidade em idosos.
- ▶ Um amostra é selecionado e aplica-se um exame psiquiátrico.
- ▶ Para cada indivíduo a variável resposta é dada por

$$S_i = \begin{cases} 1 & \text{se os sintomas estão presentes,} \\ 0 & \text{se os sintomas não estão presentes.} \end{cases}$$

- ▶ Mediu-se ainda um escore que mede a inteligência de adultos e adolescentes:
 - ▶ Wechsler Adult Intelligence Scale (WAIS) .

Exemplo: (continuação)

- A tabela a seguir apresenta os dados do problema

x	s	x	s	x	s	x	s	x	s
9	1	7	1	7	0	17	0	13	0
13	1	5	1	16	0	14	0	13	0
6	1	14	1	9	0	19	0	9	0
8	1	13	0	9	0	9	0	15	0
10	1	16	0	11	0	11	0	10	0
4	1	10	0	13	0	14	0	11	0
14	1	12	0	15	0	10	0	12	0
8	1	11	0	13	0	16	0	4	0
11	1	14	0	10	0	10	0	14	0
7	1	15	0	11	0	16	0	20	0
9	1	18	0	6	0	14	0		

Exemplo: (continuação)

- ▶ Algumas pessoas possuem o mesmo valor para o score WAIS.
- ▶ Podemos colocar essas pessoas em um mesmo grupo.
- ▶ E contamos o número de sucessos nesse grupo.
- ▶ Exemplo:
 - ▶ existem 3 pessoas com escore 7;
 - ▶ dessas 3, 2 tem os sintomas e uma não;
 - ▶ podemos agrupá-las em uma com $n_i=3$;
 - ▶ número de sucessos $y_i = 2$.

Exemplo: (continuação)

- ▶ Vamos usar a seguinte notação:
 - ▶ Y_i número de casos no i -ésimo grupo;
 - ▶ n_i número total de pessoas no grupo.
- ▶ Vamos ajustar um modelo Binomial com ligação logística, ou seja

Exemplo: (continuação)

- ▶ Vamos usar a seguinte notação:
 - ▶ Y_i número de casos no i -ésimo grupo;
 - ▶ n_i número total de pessoas no grupo.
- ▶ Vamos ajustar um modelo Binomial com ligação logística, ou seja

$$Y_i \sim \text{Bin}(n_i, \pi_i)$$

Exemplo: (continuação)

- ▶ Vamos usar a seguinte notação:
 - ▶ Y_i número de casos no i -ésimo grupo;
 - ▶ n_i número total de pessoas no grupo.
- ▶ Vamos ajustar um modelo Binomial com ligação logística, ou seja

$$Y_i \sim \text{Bin}(n_i, \pi_i) \quad \log \left(\frac{\pi_i}{1 - \pi_i} \right) = \beta_0 + \beta_1 x_i .$$

- ▶ O modelo foi ajustado e os valores estimados são dados por

$$\log \left(\frac{\hat{\pi}_i}{1 - \hat{\pi}_i} \right) = 2,404 - 0,3235 x_i .$$

Exemplo: (continuação)

- ▶ Qual interpretação do coeficiente de x_i ?
- ▶ Temos que

$$e^{-0,3235} = 0.7237$$

isso significa que

Exemplo: (continuação)

- ▶ Qual interpretação do coeficiente de x_i ?
- ▶ Temos que

$$e^{-0,3235} = 0.7237$$

isso significa que para cada aumento em uma unidade no score WAIS espera-se uma redução de 28% na chance de ter os sintomas.

- ▶ A Deviance e Estatística de Pearson são dados por

$$D = 8,083 \quad X^2 = 9,419 .$$

- ▶ Devemos comparar com a distribuição

Exemplo: (continuação)

- ▶ Qual interpretação do coeficiente de x_i ?
- ▶ Temos que

$$e^{-0,3235} = 0.7237$$

isso significa que para cada aumento em uma unidade no escore WAIS espera-se uma redução de 28% na chance de ter os sintomas.

- ▶ A Deviance e Estatística de Pearson são dados por

$$D = 8,083 \quad X^2 = 9,419 .$$

- ▶ Devemos comparar com a distribuição $X_{n-p}^2 = X_{17-2}^2$.
- ▶ O valor crítico é dado por 24,95.
- ▶ Conclusão:

Exemplo: (continuação)

- ▶ Qual interpretação do coeficiente de x_i ?
- ▶ Temos que

$$e^{-0,3235} = 0.7237$$

isso significa que para cada aumento em uma unidade no escore WAIS espera-se uma redução de 28% na chance de ter os sintomas.

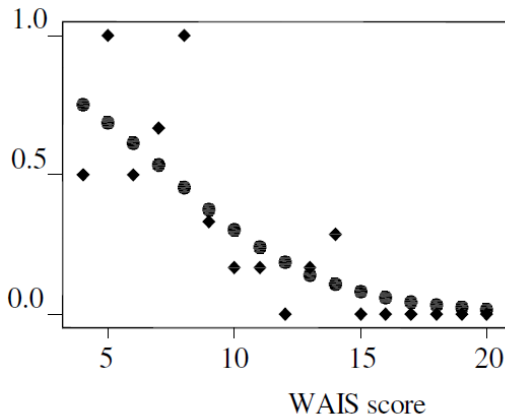
- ▶ A Deviance e Estatística de Pearson são dados por

$$D = 8,083 \quad X^2 = 9,419 .$$

- ▶ Devemos comparar com a distribuição $X_{n-p}^2 = X_{17-2}^2$.
- ▶ O valor crítico é dado por 24,95.
- ▶ Conclusão: o modelo parece estar bem ajustado.

Exemplo: (continuação)

- ▶ No gráfico a seguir os círculos são as proporções estimadas pelo modelo e os losangos são as proporções observadas.



- ▶ O modelo parece se ajustar bem aos dados.

Exemplo: (continuação)

- ▶ A tabela a seguir mostra os valores ajustados e os resíduos de Pearson (X) e Deviance residual (d).

x	y	n	$\hat{\pi}$	X	d
4	1	2	0.751	-0.826	-0.766
5	0	1	0.687	0.675	0.866
6	1	2	0.614	-0.330	-0.326
7	1	3	0.535	0.458	0.464
8	0	2	0.454	1.551	1.777
9	4	6	0.376	-0.214	-0.216
10	5	6	0.303	-0.728	-0.771
11	5	6	0.240	-0.419	-0.436
12	2	2	0.186	-0.675	-0.906
13	5	6	0.142	0.176	0.172
14	5	7	0.107	1.535	1.306
15	3	3	0.080	-0.509	-0.705
16	4	4	0.059	-0.500	-0.696
17	1	1	0.043	-0.213	-0.297
18	1	1	0.032	-0.181	-0.254
19	1	1	0.023	-0.154	-0.216
20	1	1	0.017	-0.131	-0.184

Exemplo: (continuação)

- ▶ Os resíduos não apresentam nenhum valor muito discrepante.

- ▶ O modelo binomial retorna uma estimativa das probabilidade de sucesso.
- ▶ Em muitos casos queremos classificar os elementos:
 - ▶ e-mail \Rightarrow Spam ou não;
 - ▶ cliente \Rightarrow inadimplente ou não;
 - ▶ cliente \Rightarrow alto ou baixo risco.
- ▶ Precisamos definir um ponto de corte para as probabilidades estimadas.
- ▶ Veremos uma ferramenta para nos auxiliar nessa escolha.

- ▶ Quando estamos classificando itens em sucesso/fracasso podemos cometer dois erros.

- ▶ Quando estamos classificando itens em sucesso/fracasso podemos cometer dois erros.
- ▶ Dizer que é sucesso quando é fracasso (falso positivo).
- ▶ Dizer que é fracasso quando é sucesso (falso negativo).
- ▶ Esses dois tipos de erros levam duas medidas de qualidade do modelo:
 - ▶ **Sensibilidade:** 1-proporção de falsos positivos;
 - ▶ **Especificidade:** 1-proporção de falsos negativos.

- ▶ Em ensaios clínicos esse tipo de nomenclatura é muito comum.
- ▶ A **Sensibilidade** e **Especificidade** são usadas para medir a confiabilidade do teste para diagnóstico de doenças.
- ▶ Suponha que queremos verificar se o paciente tem uma doença observando seus sintomas.
- ▶ Para verificar a qualidade do teste precisamos de dois grupos de pacientes:
 - ▶ um grupo saudável, temos certeza que não tem a doença;
 - ▶ um grupo que tem a doença com certeza.

- ▶ Podemos construir uma tabela de contingência.
- ▶ Ela contém o número de vezes que o resultado do teste condiz com a realidade.

Doença	Teste		Total
	Poisitivo	Negativo	
Presente	a	b	$n_1 = a + b$
Ausente	c	d	$n_2 = c + d$
Total	$a+c$	$b+d$	

- ▶ Dentre os n_1 pacientes com a doença o teste detectou a .
- ▶ Dentre os n_2 pacientes sem a doença o teste foi correto d vezes.

Sensibilidade

- ▶ Probabilidade do teste acertar em detectar a doença

Sensibilidade

- ▶ Probabilidade do teste acertar em detectar a doença

$$P(\text{positivo} | \text{paciente tem a doença}) .$$

- ▶ Quão sensível o teste é para detectar a doença.
- ▶ A partir da tabela pode ser estimada por

Sensibilidade =

Sensibilidade

- ▶ Probabilidade do teste acertar em detectar a doença

$$P(\text{positivo}|\text{paciente tem a doença}) .$$

- ▶ Quão sensível o teste é para detectar a doença.
- ▶ A partir da tabela pode ser estimada por

$$\text{Sensibilidade} = \frac{a}{n_1} .$$

Especificidade

- ▶ Probabilidade do teste diagnosticar corretamente um paciente saudável

Especificidade

- ▶ Probabilidade do teste diagnosticar corretamente um paciente saudável

$$P(\text{negativo} | \text{paciente não tem a doença}) .$$

- ▶ Quão específico o teste é para aquela doença? Não sei detectando o que não deveria.
- ▶ A partir da tabela pode ser estimada por

Especificidade =

Especificidade

- ▶ Probabilidade do teste diagnosticar corretamente um paciente saudável


$$P(\text{negativo} | \text{paciente não tem a doença}) .$$

- ▶ Quão específico o teste é para aquela doença? Não sei detectando o que não deveria.
- ▶ A partir da tabela pode ser estimada por

$$\text{Especificidade} = \frac{d}{n_2} .$$

Curva ROC (Receiver operating characteristic)

- ▶ É um gráfico que descreve a qualidade de um operador binário.
- ▶ É uma representação gráfica das seguintes quantidades:
 - ▶ sensibilidade vs 1-especificidade.
- ▶ Ou seja, consiste em fazer o gráfico de:
 - ▶ verdadeiros positivos vs falsos positivos
- ▶ Tais quantidades variam de acordo com o limiar de probabilidade que é considerado na classificação.
- ▶ Pode ser usada para determinar qual o limiar ideal.



- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como sucesso;
 - ▶ a taxa de verdadeiros positivos é

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como sucesso;
 - ▶ a taxa de verdadeiros positivos é alta;
 - ▶ a taxa de verdadeiros negativos é

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como sucesso;
 - ▶ a taxa de verdadeiros positivos é alta;
 - ▶ a taxa de verdadeiros negativos é baixa;
 - ▶ a taxa de falso positivos é

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como sucesso;
 - ▶ a taxa de verdadeiros positivos é alta;
 - ▶ a taxa de verdadeiros negativos é baixa;
 - ▶ a taxa de falso positivos é alta;
 - ▶ sensibilidade

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como sucesso;
 - ▶ a taxa de verdadeiros positivos é alta;
 - ▶ a taxa de verdadeiros negativos é baixa;
 - ▶ a taxa de falso positivos é alta;
 - ▶ sensibilidade alta;
 - ▶ especificidade

- ▶ O nome “Receiver operating characteristic” vem do fato de:
 - ▶ comparar duas características do teste.
- ▶ Se colocamos um limiar de probabilidade baixo:
 - ▶ todo mundo é classificado como sucesso;
 - ▶ a taxa de verdadeiros positivos é alta;
 - ▶ a taxa de verdadeiros negativos é baixa;
 - ▶ a taxa de falso positivos é alta;
 - ▶ sensibilidade alta;
 - ▶ especificidade baixa.

- ▶ Se colocamos um limiar de probabilidade alto:

- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como

- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como fracasso;
 - ▶ a taxa de verdadeiros positivos é

- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como fracasso;
 - ▶ a taxa de verdadeiros positivos é baixa;
 - ▶ a taxa de verdadeiros negativos é


- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como fracasso;
 - ▶ a taxa de verdadeiros positivos é baixa;
 - ▶ a taxa de verdadeiros negativos é alta;
 - ▶ a taxa de falso positivos é

- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como fracasso;
 - ▶ a taxa de verdadeiros positivos é baixa;
 - ▶ a taxa de verdadeiros negativos é alta;
 - ▶ a taxa de falso positivos é baixa;
 - ▶ sensibilidade

- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como fracasso;
 - ▶ a taxa de verdadeiros positivos é baixa;
 - ▶ a taxa de verdadeiros negativos é alta;
 - ▶ a taxa de falso positivos é baixa;
 - ▶ sensibilidade baixa;
 - ▶ especificidade


- ▶ Se colocamos um limiar de probabilidade alto:
 - ▶ todo mundo é classificado como fracasso;
 - ▶ a taxa de verdadeiros positivos é baixa;
 - ▶ a taxa de verdadeiros negativos é alta;
 - ▶ a taxa de falso positivos é baixa;
 - ▶ sensibilidade baixa;
 - ▶ especificidade alta.
- ▶ Conclusão:
 - ▶ a especificidade diminui com o aumento da sensibilidade;
 - ▶ existe um “trade-off”, como no erro do tipo I e tipo II;
 - ▶ 1-especificidade aumenta com o aumento da sensibilidade.

- ▶ A figura abaixo ilustra como essas duas quantidades variam.




- ▶ A curva ROC é uma representação gráfica da:
 - ▶ sensibilidade vs 1-especificidade;
 - ▶ verdadeiros positivos (TPR) vs falsos positivos (FPR).
- ▶ É uma comparação entre duas características de operação de um classificador:
 - ▶ TPR e FPR.
- ▶ Mede quão bem um parâmetro consegue distinguir dois grupos.

- ▶ Os indivíduos com e sem a doença têm distribuições distintas.
- ▶ Definimos um ponto de corte.
- ▶ Podemos errar nas interceções.
- ▶ Semelhante ao teste de hipótese para comparar populações.



- ▶ As quantidades são plotadas para diferentes limiares de probabilidade.
- ▶ Cada ponto corresponde ao TPR e FPR para um limiar específico.



- ▶ Qual ponto ideal?

- ▶ Qual ponto ideal?
- ▶ O ponto onde:
 - ▶ sensibilidade=TPR=

- ▶ Qual ponto ideal?
- ▶ O ponto onde:
 - ▶ sensibilidade=TPR=100%;
 - ▶ 1-especificidade=FPR=

- ▶ Qual ponto ideal?
- ▶ O ponto onde:
 - ▶ sensibilidade=TPR=100%;
 - ▶ 1-especificidade=FPR=0%.
- ▶ Uma curva ideal passa pela quina à esquerda (como aquela mostrada no exemplo).
- ▶ O que acontece com uma curva que passa na reta?

- ▶ Qual ponto ideal?
- ▶ O ponto onde:
 - ▶ sensibilidade=TPR=100%;
 - ▶ 1-especificidade=FPR=0%.
- ▶ Uma curva ideal passa pela quina à esquerda (como aquela mostrada no exemplo).
- ▶ O que acontece com uma curva que passa na reta?
- ▶ $TPR=FPR$
- ▶ Erra o mesmo tanto que acerta.
- ▶ Esse resultado pode ser obtido sem modelo nenhum.
- ▶ Basta jogar uma moeda para cima e classificar como sucesso ou fracasso.

- ▶ Considere um elemento que é sucesso.
- ▶ Nesse caso temos que:
 - ▶ probabilidade de ser detectado=probabilidade de não ser detectado.
- ▶ O modelo não consegue distinguir os dois grupos:
 - ▶ não consegue fazer com que probabilidade de detecção seja maior do que a probabilidade de não detecção para um objeto que é sucesso.
- ▶ Chega um paciente no consultório.
- ▶ O médico não tem uma probabilidade maior de dizer que está doente do que dizer que não está.

- ▶ Uma medida para verificar se o classificador é bom:
 - ▶ área abaixo da curva (AUC - Area Under Curve).
- ▶ Mede o quanto a curva se afasta da reta.
- ▶ Considere um elemento que é positivo.
- ▶ É a probabilidade do classificador ter maior chance de dizer que ele é positivo do que negativo.
- ▶ Quanto **maior** a AUC \Rightarrow **maior** poder de classificação.
- ▶ Pode ser usada para escolher qual o melhor modelo.

Exemplo:

- ▶ Considere os seguintes dados e o modelo ajustado.

```
x1<-c(29, 30, 31, 31, 32, 29, 30, 31, 32, 33)
```

```
x2<-c(62, 83, 74, 88, 68, 41, 74, 21, 50, 33)
```

```
Y<-c(0, 0, 0, 0, 0, 1, 1, 1, 1, 1)
```

```
modelo=glm(Y~x1+x2, family="binomial")
```

Exemplo: (continuaçã)

- ▶ O resultado do ajuste do modelo é mostrado a seguir.

```
> summary(modelo)
```

```
Coefficients:
```

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	7.941953	24.469012	0.325	0.746
x1	0.009833	0.770999	0.013	0.990
x2	-0.132726	0.081249	-1.634	0.102

```
Residual deviance: 6.7789 on 7 degrees of freedom
```

```
AIC: 12.779
```


Exemplo: (continuação)

- ▶ Queremos encontrar um ponto de corte para as probabilidades estimadas.
- ▶ A tabela a seguir mostra os resultados para alguns valores testados.

$$Pr\{Y = 1\} > 0.5 \quad \begin{array}{c|cc} & \hat{Y} & \\ & 0 & 1 \\ \hline Y & 0 & 5 & 0 \\ & 1 & 1 & 4 \end{array} \quad Pr\{Y = 1\} > 0.7 \quad \begin{array}{c|cc} & \hat{Y} & \\ & 0 & 1 \\ \hline Y & 0 & 5 & 0 \\ & 1 & 1 & 4 \end{array}$$

$$Pr\{Y = 1\} > 0.4 \quad \begin{array}{c|cc} & \hat{Y} & \\ & 0 & 1 \\ \hline Y & 0 & 4 & 1 \\ & 1 & 1 & 4 \end{array} \quad Pr\{Y = 1\} > 0.3 \quad \begin{array}{c|cc} & \hat{Y} & \\ & 0 & 1 \\ \hline Y & 0 & 3 & 2 \\ & 1 & 1 & 4 \end{array}$$

Exemplo: (continuação)

- ▶ Quais pontos de corte parecem adequados?

Exemplo: (continuação)

- ▶ Quais pontos de corte parecem adequados?
 - ▶ 0,5 ou 0,7.
- ▶ Vamos calcular a sensibilidade e especificidades do teste.
- ▶ Os comandos a seguir fazem esse cálculo para $p = 0,5$

```
p=.5
```

```
> predicted=ifelse(modelo$fitted>p,1,0)
```

```
>
```

```
> (sensibilidade=sum(predicted==modelo$y  
& predicted==1)/sum(Y==1))
```

```
[1] 0.8
```

```
> (especificidade=sum(predicted==modelo$y  
& predicted==0)/sum(Y==0))
```

```
[1] 1
```

Exemplo: (continuação)

- ▶ Os comandos a seguir fazem o gráfico das duas quantidades para vários valores de p .

```
p=seq(0,1,length=100)
```

```
sensibilidade=NULL
```

```
especificidade=NULL
```

```
for( i in 1:length(p)){
```

```
  predicted=ifelse(modelo$fitted>p[i],1,0)
```

```
  sensibilidade[i]=sum(predicted==modelo$y  
    & predicted==1)/sum(Y==1)
```

```
  especificidade[i]=sum(predicted==modelo$y  
    & predicted==0)/sum(Y==0)
```


```
}
```

```
plot(p,sensibilidade,type='l',col='red')
```

```
lines(p,especificidade,col='blue')
```

Exemplo: (continuação)

- ▶ O gráfico obtido é mostrado a seguir.



Exemplo: (continuação)

- ▶ Para p grande, classifica todo mundo como

Exemplo: (continuação)

- ▶ Para p grande, classifica todo mundo como fracasso.
- ▶ A chance de errar ao classificar como fracasso é

Exemplo: (continuação)

- ▶ Para p grande, classifica todo mundo como fracasso.
- ▶ A chance de errar ao classificar como fracasso é alta.
- ▶ A especificidade é

Exemplo: (continuação)

- ▶ Para p grande, classifica todo mundo como fracasso.
- ▶ A chance de errar ao classificar como fracasso é alta.
- ▶ A especificidade é baixa.
- ▶ Classifica poucos como sucesso.
- ▶ A chance de errar ao classificar como sucesso é

Exemplo: (continuação)

- ▶ Para p grande, classifica todo mundo como fracasso.
- ▶ A chance de errar ao classificar como fracasso é alta.
- ▶ A especificidade é baixa.
- ▶ Classifica poucos como sucesso.
- ▶ A chance de errar ao classificar como sucesso é baixa.
- ▶ A sensibilidade é

Exemplo: (continuação)

- ▶ Para p grande, classifica todo mundo como fracasso.
- ▶ A chance de errar ao classificar como fracasso é alta.
- ▶ A especificidade é baixa.
- ▶ Classifica poucos como sucesso.
- ▶ A chance de errar ao classificar como sucesso é baixa.
- ▶ A sensibilidade é alta.

Exemplo: (continuação)

- ▶ Para p pequeno, classifica todo mundo como

Exemplo: (continuação)

- ▶ Para p pequeno, classifica todo mundo como sucesso.
- ▶ A chance de errar ao classificar como sucesso é

Exemplo: (continuação)

- ▶ Para p pequeno, classifica todo mundo como sucesso.
- ▶ A chance de errar ao classificar como sucesso é alta.
- ▶ A sensibilidade é

Exemplo: (continuação)

- ▶ Para p pequeno, classifica todo mundo como sucesso.
- ▶ A chance de errar ao classificar como sucesso é alta.
- ▶ A sensibilidade é baixa.
- ▶ Classifica poucos como fracasso.
- ▶ A chance de errar ao classificar como fracasso é

Exemplo: (continuação)

- ▶ Para p pequeno, classifica todo mundo como sucesso.
- ▶ A chance de errar ao classificar como sucesso é alta.
- ▶ A sensibilidade é baixa.
- ▶ Classifica poucos como fracasso.
- ▶ A chance de errar ao classificar como fracasso é baixa.
- ▶ A especificidade é

Exemplo: (continuação)

- ▶ Para p pequeno, classifica todo mundo como sucesso.
- ▶ A chance de errar ao classificar como sucesso é alta.
- ▶ A sensibilidade é baixa.
- ▶ Classifica poucos como fracasso.
- ▶ A chance de errar ao classificar como fracasso é baixa.
- ▶ A especificidade é alta.
- ▶ Podemos escolher como corte o ponto em que

sensibilidade = especificidade $\approx 0,5$.