



# Regressão Logística

---

Prof Dr. Vladimir C. Alencar  
LANA/UEPB  
[www.valencar.com](http://www.valencar.com)




# Regressão Logística



# Regressão Logística

- É um método estatístico usado para modelar a relação entre uma variável dependente binária (ou categórica) e uma ou mais variáveis independentes (preditoras).
- Embora o nome sugira, a regressão logística não é usada para previsões contínuas, mas sim para estimar a probabilidade de um determinado evento ocorrer, ou seja, é especialmente útil para classificação.



# Regressão Logística


---

- A regressão logística é um modelo de classificação que trabalha muito bem com classes linearmente separáveis.
- É um dos algoritmos de classificação mais amplamente utilizados na indústria.
- É um modelo de classificação binária que pode ser estendido para mutliclasse.

# Regressão Logística

---


- A regressão logística é uma técnica estatística que tem como objetivo modelar, a partir de um conjunto de observações, a relação “logística” entre uma variável resposta e uma série de variáveis explicativas numéricas (contínuas, discretas) e/ou categóricas.



# Regressão Logística

---

- A regressão logística é amplamente usada em ciências médicas e sociais, e tem outras denominações, como **modelo logístico**, **modelo logit**, e **classificador de máxima entropia**.



# Regressão Logística

- O modelo tem um comportamento probabilístico.
- Trabalha com a probabilidade relacionada ao sucesso.
- Um evento de sucesso não necessariamente significa um evento bom, mas um evento que desejamos prever.
- Ex. A probabilidade que um paciente tenha certa doença

O evento positivo é relacionado com um Rótulo ou Classe

(1 – Tem doença, 0 – Não tem)

- Para mapearmos os eventos, usamos uma função logística (usa o logaritmo da probabilidade do evento).

# Regressão Logística

- **Na Regressão Logística, a variável resposta é binária**

1 - acontecimento de interesse (sucesso)

0 - acontecimento complementar (insucesso)

# Regressão Logística - Formulação

Tranformação Logit

Considere o seguinte exemplo: uma organização quer determinar o aumento salarial de um funcionário com base em seu desempenho




# Regressão Logística

## Tranformação Logit

Agora, e se a organização quiser saber se um funcionário obteria uma promoção ou não com base em seu desempenho?

O gráfico linear acima não será adequado neste caso.

Como tal, cortamos a linha em zero e um, e a convertemos em uma curva sigmoide (curva S).



# Regressão Logística

## Transformação Logit


Para entender a regressão logística, vamos analisar as probabilidades de sucesso.

Probabilidades ( $\theta$ ) = Probabilidade de um evento acontecer / Probabilidade de um evento não acontecer  
 $\theta = p / 1 - p$

Os valores das probabilidades variam de zero a  $\infty$  e os valores da probabilidade estão entre zero e um.

Considere a equação de uma linha reta:

$$y = \beta_0 + \beta_1 * x$$



Agora, para prever as probabilidades de sucesso, usamos a seguinte fórmula:

$$\log \left( \frac{p(x)}{1-p(x)} \right) = \beta_0 + \beta_1 x$$

log (Probabilidade) = Valores entre 0 e 1

Exponenciando ambos os lados, temos:

$$e^{\ln \left( \frac{p(x)}{1-p(x)} \right)} = e^{\beta_0 + \beta_1 x}$$

$$\left( \frac{p(x)}{1-p(x)} \right) = e^{\beta_0 + \beta_1 x}$$

# Regressão Logística

Transformação Logit

Seja  $Y = e^{\beta_0 + \beta_1 x}$

Então  $p(x) / 1 - p(x) = Y$

$p(x) = Y(1 - p(x))$

$p(x) = Y - Y(p(x))$

$p(x) + Y(p(x)) = Y$

$p(x)(1+Y) = Y$

$p(x) = Y / 1+Y$

$$p(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}$$

A equação da função sigmóide é:

$$p(x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}}$$

# Regressão Logística


Transformação Logit

A curva sigmóide obtida a partir da equação acima é a seguinte:




$$p(x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}}$$

# Regressão Logística



# Regressão Logística

$$\phi(z) = \frac{1}{1 + e^{-z}}$$



- Função Sigmóide

$$z = \mathbf{w}^T \mathbf{x} = w_0 x_0 + w_1 x_1 + \dots + w_m x_m$$

# Regressão Logística

- O log se refere ao logaritmo natural.
- A função logit trabalha com valores na faixa de 0 a 1 e os transforma em números reais, nos quais expressam o relacionamento linear entre valores e suas probabilidades logarítmicas

$$\text{logit}(p(y = 1 | \mathbf{x})) = w_0x_0 + w_1x_1 + \dots + w_mx_m = \sum_{i=0}^m w_ix_i = \mathbf{w}^T \mathbf{x}$$

---

Onde:

$\mathbf{p}(y=1|\mathbf{x})$  é a probabilidade condicional de um particular evento onde a classe pertence a 1 (sucesso) dado os atributos de  $\mathbf{x}$


# Regressão Logística

- Nós estamos interessados em prever a probabilidade de certos dados pertencerem a uma classe em particular, então utilizaremos a forma inversa da função logit.
- Nós também chamamos de função logística sigmóide ou função sigmóide, e tem um comportamento em forma de S.

$$\phi(z) = \frac{1}{1 + e^{-z}}$$

$$Z = \mathbf{w}^T \mathbf{x} = w_0 x_0 + w_1 x_1 + \dots + w_m x_m$$

Onde Z são os dados de entrada, uma combinação linear dos pesos e dos valores dos atributos




# Regressão Logística

- Função Sigmóide

$$\phi(z) = \frac{1}{1 + e^{-z}}$$

$$Z = \mathbf{w}^T \mathbf{x} = w_0 x_0 + w_1 x_1 + \dots + w_m x_m$$

e = 2,718281



# Regressão Logística

- A saída da função sigmoid pode ser interpretada com a probabilidade de uma amostra particular pertencer a classe 1, dado seus atributos  $\mathbf{x}$ , parametrizados pelos pesos  $\mathbf{w}$ .

$$\phi(z) = P(y = 1 | \mathbf{x}; \mathbf{w})$$

- Ex. Se  $\phi(z) = 0.8$ , para uma determinada doença, Isto significa 80% de probabilidade de ter a doença ( $y=1$ ).


$$P(y = 0 | \mathbf{x}; \mathbf{w}) = 1 - P(y = 1 | \mathbf{x}; \mathbf{w}) = 0.2$$

Significa a probabilidade de que 20% não tem a doença ( $y=0$ )

# Otimizador (achar os pesos $w$ )

O método de Newton, é um algoritmo de localização de raízes que produz aproximações sucessivamente melhores para as raízes (ou zeros) de uma função de valor real


$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$$



# Otimizador (achar os pesos $w$ )

O método de  
Newton


$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$$



# Regressão Logística

A probabilidade prevista será :


$$\hat{y} = \begin{cases} 1 & \text{if } \phi(z) \geq 0.5 \\ 0 & \text{otherwise} \end{cases}$$



# Regressão Logística

---

- Regressão Logística é útil para modelar a probabilidade de um evento ocorrer como função de outros fatores.
- É um modelo linear generalizado que usa como função de ligação a função logit.



# Regressão Logística - utilização

- Diagnóstico médico
- Previsões climáticas
- Segmentação e categorização de imagens
- Reconhecimento de escrita/caligrafia
- Previsão de tempo, não só para prever se vai chover em determinado dia, mas também a chance de chover
- Prever a chance que um paciente ter uma certa doença, dados os sintomas. Um campo onde a regressão logística é muito popular, que é a medicina.
- Também, em medicina, permite determinar os fatores que caracterizam um grupo de indivíduos doentes em relação a indivíduos saudáveis.
- Na área de seguros, permite encontrar frações de clientes que sejam sensíveis a determinada política securitária em relação a um dado risco particular.
- Em instituições financeiras, pode detectar os grupos de risco para a subscrição de um crédito.

$$g(x) = \ln\left(\frac{\pi(x)}{1 - \pi(x)}\right)$$

$$g(x) = \ln\left(\frac{\frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}}{1 - \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}}\right) = \ln\left(\frac{\frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}}{\frac{1}{1 + e^{\beta_0 + \beta_1 x}}}\right)$$

$$g(x) = \ln(e^{\beta_0 + \beta_1 x}) = \beta_0 + \beta_1 x$$