

---

# Transformações e Ponderação para corrigir violações do modelo

# Diagnóstico na análise de regressão

## Relembrando suposições

- Os erros do modelo tem média zero e variância constante.
- Os erros do modelo tem distribuição normal.
- A forma paramétrica estabelecida para o modelo está correta.

# Algumas medidas para contornar problemas do modelo de regressão

Modelo de regressão linear simples não é adequado



Usar um modelo apropriado

Usar transformações

## Não linearidade do modelo de regressão

- Mudar o modelo

$$E(Y) = \beta_0 + \beta_1 X + \beta_2 X^2$$

$$E(Y) = \beta_0 \beta_1^X \quad (\textit{Exponencial})$$

$$E(Y) = \frac{\beta_0}{1 + \beta_1 \exp(\beta_2 X_i)} \quad (\textit{logístico})$$

- Usar transformação

## Variâncias heterogêneas

- Usar o método de mínimos quadrados ponderados para estimar os parâmetros
- Usar transformação

# Algumas medidas para contornar problemas do modelo de regressão

## Falta de normalidade

A falta de normalidade geralmente vem junto com falta de homogeneidade de variâncias. Frequentemente, a mesma transformação estabiliza a variância e aproxima para normalidade, portanto, primeiro usar uma transformação para estabilizar a variância (será visto na próxima seção).

## Omissão de variável preditora importante

→ Modificar o modelo de regressão múltipla

## Outliers

→ Usar procedimentos de estimação robustos (método dos mínimos quadrados ponderados iterativamente), pois os métodos de mínimos quadrados e máxima verossimilhança produzem estimativas distorcidas.

# Transformações para linearizar o modelo

Ocasionalmente detecta-se a suposição de linearidade é violada.

Como:

- diagramas de dispersão

- gráfico dos resíduos (gráfico de regressão parcial)

- experiência a priori (não usual).



No caso de experiência a priori, a função não linear pode ser linearizada. Esses modelos são chamados de intrinsecamente linear.

# Transformações para linearizar

Transformação da variável  $Y$  ou da variável preditora  $X$ , ou de *ambas*, frequentemente é suficiente para tornar o modelo de regressão linear simples apropriado para os dados transformados.

Padrões de relação entre  $X$  e  $Y$

---



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

$$y = \beta_0 e^{\beta_1 x}$$

**Transformação**  $x' = \log x$


$$y' = \ln y$$

**Forma linear**  $y' = \beta_0 + \beta_1 x'$

$$y' = \ln \beta + \beta_1 x$$

# Exemplo: Transformação nos regressores

Uma pesquisadora estava interessada em estudar o comportamento do pH de tomates Chronos (Y), inteiros minimamente processados, submetidos ao tratamento vácuo, durante 22 dias de estocagem (X), a uma temperatura média de 8°C e umidade relativa de 62,78%.




Condições aproximadamente  
satisfeitas:  
Normalidade  
Independência  
e variância constante

O diagrama de dispersão indica uma relação curvilínea. A variabilidade nos diferentes níveis de X parece constante.


Vamos considerar a transformação  $X' = 1/X$ .

# Exemplo



Os dados continuam mostrando um comportamento curvilíneo. A variabilidade nos diferentes níveis de  $X$  continua constante.

# Exemplo




A transformação  $\log_{10}$  (dias) linearizou a função de regressão. A variabilidade permanece constante.

Outra transformação muito usada é potência de  $x$ .

# Transformações para estabilizar variância

Variâncias heterogêneas e não normalidade dos erros frequentemente aparecem juntas. Necessita-se fazer uma transformação em  $Y$ , pois a forma e a dispersão em  $Y$  precisam ser modificadas. A transformação em  $Y$  pode também eliminar o problema de não linearidade do modelo. Outras vezes uma transformação também em  $X$  é necessária para manter ou obter uma relação linear.

A figura ilustra algumas formas de relacionamento onde a assimetria e as variâncias aumentam com a resposta média  $E(Y)$ .



Transformações sobre  $Y$ :  
Seleciona-se empiricamente

$$Y' = \sqrt{Y}$$
$$Y' = \log_{10} Y$$
$$Y' = 1/Y$$


Nota: uma transformação em  $X$  pode ser útil ou necessário.

Fazer análise de resíduos

# Exemplo

objetivo: estimar o volume da árvore em pé a partir de medidas mais facilmente obtidas.


Y=volume da árvore em pés cúbicos; X1=diâmetro da árvore em polegadas a 4 pés e 6 polegadas acima do solo; X2=altura da árvore em pés.



Observamos maior variabilidade para valores maiores de altura. A relação entre volume e altura é linear.

# Exemplo

Transformação: valores inverso de  $Y$  ( $1/Y$ ).




Note que a transformação tornou a variância razoavelmente constante para os diferentes níveis de  $X$ .

O modelo de regressão linear simples ajustado aos dados com a transformação

$Y' = 1/Y$  é dado por:

$$\hat{Y}' = 0,22386 - 0,002377X$$

# Exemplo



Indica que o modelo é apropriado para os dados transformados

Se desejamos estimar os valores de  $Y$ , na unidade original, fazemos:

$$\hat{Y} = \frac{1}{0,22386 - 0,002377 X}$$

# Método analítico de seleção da melhor Transformação

## Transformação Box-Cox (Box and Cox (1964))

A transformação Box-Cox automaticamente identifica uma transformação a partir de uma família de transformações potência de  $Y$ . A família de transformações potência é dada por:

$$Y' = Y^\lambda$$

Onde  $\lambda$  é um parâmetro a ser determinado a partir dos dados da amostra. Esta família inclui, por exemplo,

$$\lambda = 2 \rightarrow Y' = Y^2$$

$$\lambda = 0,5 \rightarrow Y' = \sqrt{Y}$$

$$\lambda = -0,5 \rightarrow Y' = \frac{1}{\sqrt{Y}}$$

$$\lambda = 0 \rightarrow Y' = \log_e Y \text{ (por definição)}$$

$$\lambda = -1,0 \rightarrow Y' = \frac{1}{Y}$$

# Método analítico de seleção da melhor Transformação

O modelo de regressão com erros normais com a variável resposta pertencente a família de transformação potência fica:

$$Y_i^{(\lambda)} = \beta_0 + \beta_1 X_i + \varepsilon_i$$

onde

$$Y_i^{(\lambda)} = \frac{y^\lambda - 1}{\lambda y^{\lambda-1}}, \lambda \neq 0$$
$$y \ln y, \lambda = 0$$

$$\dot{y} = \ln^{-1} \left[ \frac{1}{n} \sum_{i=1}^n \ln y_i \right]$$

Seleciona-se diferentes valores para  $\lambda$ . Ajusta-se os modelos usando  $y^{(\lambda)}$  e seleciona a transformação ( $\lambda$ ) tal que a soma de quadrados de resíduos  $SS_R$  é mínima.

Usualmente 10 a 20 valores de  $\lambda$  são suficientes. Usar diferenças pequenas.

# Exemplo

Continuamos com o exemplo das árvores ( $X$ =altura e  $Y$ =volume). Vamos tomar os seguintes valores para lambda

$$\lambda = -1 \quad \lambda = -0,3 \quad \lambda = -0,2 \quad \lambda = -0,1 \quad \lambda = 0 \quad \lambda = 0,1 \quad \lambda = 0,2 \quad \lambda = 0,3 \quad \lambda = 1$$


$\lambda$	-1,00	-0,30	-0,2	-0,10	0,00	0,10	0,20	0,30	1,00
SQR	4201,9	<b>3324,5</b>	<b>3310,3</b>	<b>3319,8</b>	<b>3352,9</b>	3409,7	3490,5	3596,3	5204,9

Observe na tabela acima que a transformação Box-Cox indica  $\lambda$  próximo de -0,20. Entretanto, a SQR é aproximadamente estável na faixa de -0,30 a 0,00, portanto, vamos usar a transformação logarítmica por ser a preferida dos pesquisadores (é uma transformação que os pesquisadores entendem melhor). A transformação Box-Cox dá um direção no sentido da escolha da melhor transformação.

Observe que a transformação usada anteriormente,  $1/Y$ , não foi razoável de acordo com transformação de Box-Cox. (compare os dois gráficos de resíduos).

Quando a transformação Box-Cox produz um  $\lambda$  próximo de 1, não é necessário transformar os dados.

# Exemplo



Indica a adequação do modelo de regressão para os dados transformados (transformação logarítmica)

# Estabilizar variância: Mínimos quadrados generalizados.

Uso: Observações  $y$  são correlacionadas e variâncias desiguais.

Modelo

$$y = X\beta + \varepsilon$$

$$E(\varepsilon) = \mathbf{0}$$

$$Var(\varepsilon) = \sigma^2 V$$

$V$  deve ser não singular e definida positiva. Então existe uma matriz simétrica  $K$  tal que

$$K^T K = V$$

Tipicamente  $\sigma^2$  é desconhecido. Nesse caso,  $V$  é assumida como a matriz de variâncias covariâncias entre os erros a menos de uma constante.  $K$  é a matriz raiz quadrada de  $V$ .

# Estabilizar variância: Mínimos quadrados generalizados.

Novas variáveis.

$$\begin{array}{ll} z = K^{-1}y & \text{Modelo original} \quad y = X\beta + \varepsilon \\ B = K^{-1}X & \text{Novo Modelo} \\ g = K^{-1}\varepsilon & K^{-1}y = K^{-1}X\beta + K^{-1}\varepsilon \\ & z = B\beta + g \end{array}$$

Após uma algebra:  $\hat{\beta} = (X^T V^{-1} X)^{-1} X^T V^{-1} y$

Estimador de mínimos quadrados generalizados

# Estabilizar variância: Mínimos quadrados ponderado

Uso: Observações y independentes e variâncias desiguais.

$$\text{Var}(\boldsymbol{\varepsilon}) = \sigma^2 \mathbf{V} = \sigma^2 \begin{bmatrix} 1/w_1 & 0 \\ 0 & 1/w_n \end{bmatrix}$$

As observações com grandes variâncias tem peso menores.

Seja  $\mathbf{W} = \mathbf{V}^{-1}$ , após uma algebra

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{W} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} \mathbf{y}$$

Estimador de mínimos quadrados ponderados.

# Estabilizar variância: Mínimos quadrados ponderado

Estimativas de Mínimos quadrados ponderados podem ser facilmente obtidos pelos Mínimos quadrados ordinários.

Pode-se reescrever o estimador dos coeficientes da seguinte forma:

$$\hat{\boldsymbol{\beta}} = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{z}$$

onde:

$$\mathbf{B} = \begin{bmatrix} 1\sqrt{w_1} & x_1\sqrt{w_1} & x_{p-1}\sqrt{w_1} \\ 1\sqrt{w_2} & x_1\sqrt{w_2} & x_{p-1}\sqrt{w_2} \\ \dots & \dots & \dots \\ 1\sqrt{w_n} & x_1\sqrt{w_n} & x_{p-1}\sqrt{w_n} \end{bmatrix} \quad \mathbf{z} = \begin{bmatrix} y_1\sqrt{w_1} \\ y_2\sqrt{w_2} \\ \dots \\ y_n\sqrt{w_n} \end{bmatrix}$$

# Como estimar $V$

1. Ordene as observações em  $y$ .
2. Encontre clusters de valores de  $x$  na ordem obtida.
3. Dentro de cada cluster calcule a média de  $x$  e para os correspondentes valores de  $y$  calcule a variância.
4. Os valores da variância de  $y$  devem aumentar ou diminuir quando os valores médios de  $x$  aumentam.
5. Construa uma regressão para a variância de  $y$  usando a média de  $x$  como regressor.
6. Para cada valor de  $x$  do conjunto encontre o valor da estimativa da média da variância de  $y$ .
7. Calcule os pesos como o inverso dos valores obtidos no passo 6.
8. Obtenha  $\mathbf{B}$  e  $\mathbf{z}$ .
9. Ajuste o modelo:

$$\hat{\beta} = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{z}$$