

Modelos de Regressão Múltipla - Parte VI

Erica Castilho Rodrigues

7 de Fevereiro de 2017

Transformação de Variáveis

Transformação para estabilizar a variância

Transformação para corrigir não-linearidade

- ▶ Podemos fazer uma transformação na variável resposta Y e/ou na preditora X para:
 - ▶ solucionar problemas de variância não constante;
 - ▶ não normalidade dos erros;
 - ▶ não linearidade do modelo.
- ▶ Violações que geralmente ocorrem ao mesmo tempo:
 - ▶ variância constante e distribuição normal.
- ▶ Suposições básicas

Y_i tem distribuição normal $Var(Y_i) = \sigma^2$.

Transformação para estabilizar a variância

- ▶ Frequentemente a variância das observações varia com sua média.
- ▶ Situações comuns:

$$Y \text{ são contagens} \Rightarrow \text{Var}(Y) \propto E(Y)$$

$$Y \text{ são proporções} \Rightarrow \text{Var}(Y) \propto E(Y)(1 - E(Y))$$

- ▶ Uma solução: fazer transformações em Y .
- ▶ Vimos que uma outra possibilidade é usar Mínimos Quadrados Generalizados.

- ▶ A tabela a seguir mostra:
 - ▶ tipos de relação mais comuns entre variância e esperança
 - ▶ tipo de transformação geralmente adequada.

Relação entre $Var(Y)$ e $E(Y)$	Transformação
$Var(Y) \propto E(Y)$	$Y^* = \sqrt{Y}$
$Var(Y) \propto E(Y)(1 - E(Y))$	$Y^* = \arcsin Y$
$Var(Y) \propto E(Y)^2$	$Y^* = \ln Y$
$Var(Y) \propto E(Y)^3$	$Y^* = 1/\sqrt{Y}$
$Var(Y) \propto E(Y)^4$	$Y^* = 1/Y$

- ▶ Vejamos com mais detalhes qual transformação é adequada para situações específicas.

 \sqrt{Y}

- ▶ É usada se a variância cresce um pouco com o valor de Y .
- ▶ Mais especificamente se

$$\text{Var}(Y) \propto E(Y).$$

- ▶ Observe que Y tem que ser positiva nesse caso.
- ▶ Essa transformação é adequada se a variável resposta é uma contagem.
- ▶ Muito usada quando Y segue uma distribuição de Poisson.

$\log(Y)$

- ▶ Usada para estabilizar a variância quando ela cresce mais rapidamente com Y .
- ▶ Mais especificamente se

$$\text{Var}(Y) \propto E(Y)^2 \quad \text{ou} \quad \sqrt{\text{Var}(Y)} \propto E(Y)$$

- ▶ Observe que Y precisa ser positiva.
- ▶ É usada quando intervalo de variação de Y é muito grande, de 1 a 10000 por exemplo.

1/Y

- ▶ Usada para estabilizar a variância quando ela cresce muito com Y

$$\text{Var}(Y) \propto E(Y)^4 .$$

- ▶ Pode ser usada, por exemplo, quando muitos valores de Y ficam próximos de zero e alguns são muito grandes.
- ▶ Os efeitos dos valores grandes são reduzidos nesse caso.
- ▶ Se Y_i é muito grande então $1/Y_i$ é muito próximo de zero.
- ▶ Considere dois valores Y_i e Y_j muito distantes.
- ▶ Essa diferença se torna pequena quando pegamos $1/Y_i$ e $1/Y_j$.
- ▶ Essa transformação é geralmente adequada quando Y representa tempo de espera até um evento (modelo exponencial).

arcsin(Y)

- ▶ É usada se Y uma proporção ou uma taxa.
- ▶ Nesse caso temos que

$$\text{Var}(Y) \propto E(Y)(1 - E(Y)) .$$

- ▶ Como Y é uma proporção temos que

$$Y_i \in [0, 1] \quad \forall i .$$

Observações:

- ▶ Se Y atinge valor negativo, não podemos usar as transformações

$$\log(Y) \quad \sqrt{Y}.$$

- ▶ Uma solução é somar uma pequena constante c em Y

$$\log(Y + c) \quad \sqrt{Y + c}.$$

- ▶ Essa constante tem que ser pequena comparada com o intervalo dos dados.
- ▶ Se não for possível encontrar essa constante, deve ser feita outra transformação.

- ▶ As tranformações

$$\log(Y) \quad \sqrt{Y} \quad 1/Y$$


são adequadas quando a variância cresce com Y .

- ▶ Mas cada uma delas é gradualmente mais forte que a anterior.
- ▶ A transformação raiz é a mais sutil.
- ▶ A transformação inversa é a mais forte de todas.
- ▶ A transformação mais usada é o logaritmo.

Exemplo:


- ▶ Deseja-se estimar o número de gansos de neve em uma área do Canadá.
- ▶ Um avião sobrevoa a área e um observador estima o tamanho dos bandos.
- ▶ Queremos estimar a precisão desse método.
- ▶ Dois observadores resgistraram o número de gansos em 45 bandos.
- ▶ Além disso, uma foto foi tirada de cada um dos bandos.
- ▶ A imagem fornece o número exato de gansos.
- ▶ O objetivo é verificar qual a relação entre o valor real do número de gansos e o valor estimado.

Exemplo: (continuação)



- ▶ A figura ao lado mostra:
 - ▶ o gráfico de dispersão entre os valores reais e os valores estimados por um dos pesquisadores.
- ▶ Um modelo linear usual parece adequado nesse caso?

Exemplo: (continuação)




- ▶ A figura ao lado mostra:
 - ▶ o gráfico de dispersão entre os valores reais e os valores estimados por um dos pesquisadores.
- ▶ Um modelo linear usual parece adequado nesse caso? Não.
- ▶ A relação entre as variáveis parece linear.
- ▶ Nota-se, porém, que a variância aumenta com o valor de X .

Exemplo: (continuação)


- ▶ A variância está aumentando muito com Y .
- ▶ Precisamos de uma transformação que reduza esse efeito.
- ▶ Vamos usar o logaritmo.
- ▶ A figura seguir mostra o gráfico de dispersão entre as variáveis após a transformação.

Exemplo: (continuação)



- ▶ O problema parece ter sido resolvido?

Exemplo: (continuação)




- ▶ O problema parece ter sido resolvido?
- ▶ Sim. A variância não parece estar mais aumentando com X .

Exemplo: (continuação)

- ▶ A relação se afastou um pouco da linearidade.
- ▶ Porém, no momento, estamos preocupados apenas em tornar a variância constante.
- ▶ Esse tipo de transformação é conhecida como:
 - ▶ transformação para estabilização da variância.
- ▶ Estudos anteriores podem indicar a transformação adequada.
- ▶ Mas em geral, essa escolha é feita com base nos:
 - ▶ gráficos de dispersão;
 - ▶ gráficos de resíduos.

Exemplo

- ▶ O tempo de cura do cimento afeta sua resistência.
- ▶ A resistência de lotes de cimento com tempo de curas distintos foram mensuradas.



Exemplo (continuação)

- ▶ A relação entre as variáveis é linear?

Exemplo (continuação)

- ▶ A relação entre as variáveis é linear?
- ▶ Não, se aproxima mais de uma curva.
- ▶ A variância é constante?


Exemplo (continuação)

- ▶ A relação entre as variáveis é linear?
- ▶ Não, se aproxima mais de uma curva.
- ▶ A variância é constante?
- ▶ Não, ela está aumentando com Y .
- ▶ Como a variância não está aumentando muito, não precisamos de uma transformação muito forte.
- ▶ Qual podemos pegar?

Exemplo (continuação)

- ▶ A relação entre as variáveis é linear?
- ▶ Não, se aproxima mais de uma curva.
- ▶ A variância é constante?
- ▶ Não, ela está aumentando com Y .
- ▶ Como a variância não está aumentando muito, não precisamos de uma transformação muito forte.
- ▶ Qual podemos pegar? Log.
- ▶ A figura a seguir mostra o gráfico de dispersão entre as variáveis quando pegamos o log da variável resposta.

Exemplo (continuação)



- ▶ A transformação alcançou objetivo pretendido?

Figura: Gráfico do logaritmo da resistência do cimento em função do tempo de cura.

Exemplo (continuação)




Figura: Gráfico do logaritmo da resistência do cimento em função do tempo de cura.

- ▶ A transformação alcançou objetivo pretendido?
- ▶ Sim, a variância fica aproximadamente constante.
- ▶ A relação agora é linear?

Exemplo (continuação)




Figura: Gráfico do logaritmo da resistência do cimento em função do tempo de cura.

- ▶ A transformação alcançou objetivo pretendido?
- ▶ Sim, a variância fica aproximadamente constante.
- ▶ A relação agora é linear?
- ▶ Não, esse problema não foi corrigido.


Exemplo:

- ▶ Estamos analisando duas variáveis:
 - ▶ nível de poliamina no sangue;
 - ▶ idade.
- ▶ Qual é a varável respota?

Exemplo:

- ▶ Estamos analisando duas variáveis:
 - ▶ nível de poliamina no sangue;
 - ▶ idade.
- ▶ Qual é a varável respota? Nível de poliamina.
- ▶ A figura a seguir mostra o gráfico de dispersão entre as variáveis.

Exemplo (continuação)



- ▶ A relação entre as variáveis é linear?

Figura: Gráfico do nível de poliamina em função da idade.

Exemplo (continuação)




Figura: Gráfico do nível de poliamina em função da idade.

- ▶ A relação entre as variáveis é linear?
- ▶ Não, a relação se aproxima mais de uma curva.
- ▶ A variância é constante?

Exemplo (continuação)




Figura: Gráfico do nível de poliamina em função da idade.

- ▶ A relação entre as variáveis é linear?
- ▶ Não, a relação se aproxima mais de uma curva.
- ▶ A variância é constante?
- ▶ Não, ela diminui com o aumento de X .

Exemplo (continuação)

- ▶ Vamos aplicar a transformação logaritmo.

$$Y^* = \log Y .$$

- ▶ O modelo ajustado é o seguinte

$$\hat{Y}^* = 1.135 - 0.1023X .$$

- ▶ Se quisermos voltar para a escala original, basta fazer

$$Y =$$

Exemplo (continuação)

- ▶ Vamos aplicar a transformação logaritmo.

$$Y^* = \log Y .$$

- ▶ O modelo ajustado é o seguinte


$$\hat{Y}^* = 1.135 - 0.1023X .$$

- ▶ Se quisermos voltar para a escala original, basta fazer

$$Y = \exp\{1.135 - 0.1023X\} .$$

- ▶ Vejamos a seguir o gráfico de dispersão para as variáveis na escala transformada.

Exemplo (continuação)



- A transformação alcançou objetivo pretendido?

Figura: Gráfico do logaritmo dos níveis de poliamina em função da idade.

Exemplo (continuação)




Figura: Gráfico do logaritmo dos níveis de poliamina em função da idade.

- ▶ A transformação alcançou objetivo pretendido?
- ▶ Sim, a variância fica aproximadamente constante.
- ▶ A relação agora é linear?

Exemplo (continuação)








Figura: Gráfico do logaritmo dos níveis de poliamina em função da idade.

- ▶ A transformação alcançou objetivo pretendido?
- ▶ Sim, a variância fica aproximadamente constante.
- ▶ A relação agora é linear?
- ▶ Sim, a relação torna-se aproximadamente linear.

- ▶ A figura abaixo mostra os gráficos de resíduos para esse modelo.



- ▶ A figura abaixo mostra os gráficos de resíduos para esse modelo.



- ▶ As suposições do modelo não parecem ter sido violadas.

Métodos analíticos para seleção de transformação

- ▶ Em muitos casos é possível escolher a transformação empiricamente.
- ▶ O gráficos e o tipo de dado, nos mostram indícios de qual é a transformação mais adequada.
- ▶ Pode ser interessante ter um técnica mais objetiva e automática de escolha da transformação.
- ▶ Uma técnica usa para isso é:
 - ▶ **procedimento de Box-Cox.**

Procedimento de Box-Cox.

- ▶ É um método para escolher transformações de maneira automática.
- ▶ Essas transformações são escolhidas na família de transformações potência.
- ▶ Pode ser aplicada apenas se a variável resposta assumir só valores positivos.
- ▶ A transformação da variável Y é dada por

$$g_{\lambda}(y) = \begin{cases} \frac{(y^{\lambda}-1)}{\lambda} & \lambda \neq 0 \\ \log(\lambda) & \lambda = 0. \end{cases}$$

- ▶ O parâmetro λ precisa ser estimado.
- ▶ Ele é escolhido de maneira a minimizar a função

$$L(\lambda) = -\frac{n}{2} \log \left(\frac{SQR_\lambda}{n} \right) + (\lambda - 1) \sum_{i=1}^n \log(y_i)$$

onde SQR_λ é a soma de quadrados da regressão quando $g_\lambda(y)$ é a variável resposta.

- ▶ O valor estimado $\hat{\lambda}$ pode ser encontrado através de métodos numéricos de maximização de funções.
- ▶ O intervalo de 95% de confiança para λ é

$$\left\{ \lambda : L(\lambda) > L(\hat{\lambda}) - \frac{1}{2} \chi_{1;1-\alpha}^2 \right\}$$

- ▶ Observe que para $\lambda = 1$ temos que

$$g_{\lambda}(y) = \begin{cases} \frac{(y^{\lambda}-1)}{\lambda} & \lambda \neq 0 \\ \log(\lambda) & \lambda = 0. \end{cases}$$

fica

$$g_{\lambda}(y) =$$

- ▶ Observe que para $\lambda = 1$ temos que

$$g_{\lambda}(y) = \begin{cases} \frac{(y^{\lambda}-1)}{\lambda} & \lambda \neq 0 \\ \log(\lambda) & \lambda = 0. \end{cases}$$

fica

$$g_{\lambda}(y) = \frac{(y^1 - 1)}{1} = y.$$

- ▶ Construimos o IC para λ .
- ▶ Se o valor 1 pertencer ao intervalo, o que isso indica?

- ▶ Observe que para $\lambda = 1$ temos que

$$g_{\lambda}(y) = \begin{cases} \frac{(y^{\lambda}-1)}{\lambda} & \lambda \neq 0 \\ \log(\lambda) & \lambda = 0. \end{cases}$$

fica

$$g_{\lambda}(y) = \frac{(y^1 - 1)}{1} = y.$$

- ▶ Construimos o IC para λ .
- ▶ Se o valor 1 pertencer ao intervalo, o que isso indica?
- ▶ Que não é necessário fazer a transformação.

Exemplo:

- ▶ Está sendo analisado o número de espécies (Specie) de tartaruga em 30 ilhas de Gálapagos.
- ▶ As variáveis explicativas são as seguintes:
 - ▶ área da ilha em km^2 (Area);
 - ▶ altura da elevação mais alta em metros (Elevation);
 - ▶ distância da ilha mais próxima em km (Nearest);
 - ▶ distância da ilha de Santa Cruz em km (Scruz);
 - ▶ área da ilha adjacente em km^2 (Adjacent).

Exemplo: (continuação)

- ▶ Aplicando a transformação Box-Cox obteve-se

$$\hat{\lambda} = 0,33 .$$

- ▶ O intervalo de confiança para o parâmetro é dado por

$$IC_{\lambda}(95\%) = [0,15; 0,55] .$$

- ▶ Devemos aplicar a transformação?

Exemplo: (continuação)

- ▶ Aplicando a transformação Box-Cox obteve-se

$$\hat{\lambda} = 0,33 .$$



- ▶ O intervalo de confiança para o parâmetro é dado por

$$IC_{\lambda}(95\%) = [0,15; 0,55] .$$

- ▶ Devemos aplicar a transformação?
- ▶ Sim, pois o $\hat{\lambda}$ não pertence ao intervalo.

Exemplo: (continuação)

- ▶ A figura mostra o gráfico de $L(\lambda)$ e o intervalo de 95% de confiança para λ são mostrados abaixo.



Exemplo:

- ▶ Estamos interessados em analisar a taxa de aplicação em poupança em 50 países.
- ▶ Essa taxa é dada por

$$\frac{\text{valor poupado}}{\text{renda}}$$

- ▶ As variáveis explicativas são as seguintes:
 - ▶ porcentagem da população abaixo de 15 anos de idades;
 - ▶ porcentagem da população acima de 75 anos;
 - ▶ renda *per capita* em dólares;
 - ▶ taxa de crescimento da renda *per capita*.

Exemplo: (continuação)

- ▶ Aplicando a transformação Box-Cox obteve-se

$$\hat{\lambda} = 0,95 .$$

- ▶ O intervalo de confiança para o parâmetro é dado por

$$IC_{\lambda}(95\%) = [0,06; 1,4] .$$

- ▶ Devemos aplicar a transformação?

Exemplo: (continuação)

- ▶ Aplicando a transformação Box-Cox obteve-se

$$\hat{\lambda} = 0,95 .$$



- ▶ O intervalo de confiança para o parâmetro é dado por

$$IC_{\lambda}(95\%) = [0,06; 1,4] .$$

- ▶ Devemos aplicar a transformação?
- ▶ Não, pois o 1 pertence ao intervalo.

Exemplo: (continuação)

- ▶ A figura mostra o gráfico de $L(\lambda)$ e o intervalo de 95% de confiança para λ são mostrados abaixo.



Transformação para corrigir não-linearidade

- ▶ Vimos até agora transformações para estabilizar a variância.
- ▶ Porém essas transformações também afetam as relações entre as variáveis.
- ▶ Resultando geralmente em relações curvas entre as variáveis.
- ▶ Maneira de voltar a termos uma relação linear é:
 - ▶ fazer transformações na variável explicativa.
- ▶ Variáveis explicativas são aleatórias?

- ▶ Vimos até agora transformações para estabilizar a variância.
- ▶ Porém essas transformações também afetam as relações entre as variáveis.
- ▶ Resultando geralmente em relações curvas entre as variáveis.
- ▶ Maneira de voltar a termos uma relação linear é:
 - ▶ fazer transformações na variável explicativa.
- ▶ Variáveis explicativas são aleatórias? Não.
- ▶ Ao fazermos transformações nelas vamos afetar a variância?

- ▶ Vimos até agora transformações para estabilizar a variância.
- ▶ Porém essas transformações também afetam as relações entre as variáveis.
- ▶ Resultando geralmente em relações curvas entre as variáveis.
- ▶ Maneira de voltar a termos uma relação linear é:
 - ▶ fazer transformações na variável explicativa.
- ▶ Variáveis explicativas são aleatórias? Não.
- ▶ Ao fazermos transformações nelas vamos afetar a variância? Não.

- ▶ Transformar a variável resposta afeta a variância e a linearidade.
- ▶ Transformar a variável explicativa só afeta linearidade.
- ▶ Então devemos primeiro trabalhar com a variância:
 - ▶ transformar a variável Y .
- ▶ Em seguida corrigir a linearidade:
 - ▶ transformar a variável explicativa.

Exemplo:

- ▶ Estamos querendo analisar a relação entre duas variáveis:
 - ▶ a velocidade do vento registrada em um gerador;
 - ▶ e a velocidade real do vento.




Figura: Gráfico de dispersão da velocidade registrada pelo gerador e a velocidade real do vento.

Exemplo: (continuação)

- ▶ A relação entre as variáveis é linear?

Exemplo: (continuação)


- ▶ A relação entre as variáveis é linear?
- ▶ Aproximadamente sim.
- ▶ O modelo de regressão linear simples foi ajustado

$$\hat{y} = 0,131 + 0,241x .$$


- ▶ Vamos verificar os gráficos de resíduos para ver se as suposições do modelo são válidas.

Exemplo: (continuação)

- ▶ A figura seguir mostra o gráfico de resíduos vs valores ajustados e o gráfico de probabilidade normal.




(a) fitted values




(b) observed
quantiles

Exemplo: (continuação)

- ▶ A figura seguir mostra o gráfico de resíduos vs valores ajustados e o gráfico de probabilidade normal.



(a) fitted values



(b) observed quantiles

- ▶ Os resíduos não parecem ser normais e nem ter variância constante.

Exemplo: (continuação)

- ▶ O modelo linear simples não parece ser o mais adequado nesse caso.
- ▶ Vamos analisar o gráfico de dispersão para encontrar uma transformação adequada em X .
- ▶ Essa transformação deve ser monótona e crescente.
- ▶ Algumas possibilidades

$$\log(x) \quad \sqrt{x} \quad 1/x .$$

- ▶ Devemos testar cada uma delas e analisar os resíduos e gráfico de dispersão.
- ▶ A mais adequada nesse caso é a transformação inversa $1/x$.

Exemplo: (continuação)

- ▶ O modelo ajustado fica

$$\hat{Y} = 2.98 - 6.93/x .$$

- ▶ Vejamos como ficam os resíduos.

Exemplo: (continuação)

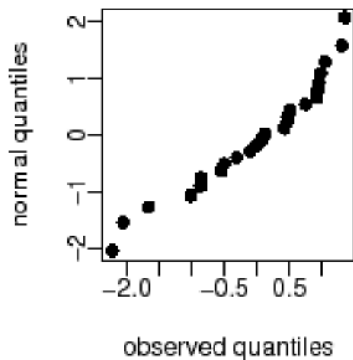



Figura: Gráfico de resíduos vs valores ajustados e gráfico de probabilidade normal.

Exemplo: (continuação)

- ▶ Conclusões:

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;
 - ▶ no segundo gráfico os pontos caem em torno de uma reta;
 - ▶ isso é um indício de que

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;
 - ▶ no segundo gráfico os pontos caem em torno de uma reta;
 - ▶ isso é um indício de que os erros tem distribuição normal.
- ▶ Percebemos então que a transformação apenas em X resolveu o problema de ajuste do modelo.

Exemplo:

- ▶ Vamos retomar o exemplo do cimento.
- ▶ Aplicamos a transformação logaritmo na variável resposta.
- ▶ A variância ficou constante.
- ▶ Mas a relação deixou de ser linear.
- ▶ Para corrigir esse problema, vamos aplicar uma transformação em X .





Figura: Gráfico do logaritmo da resistência do cimento em função do tempo de cura.


Exemplo: (continuação)

- ▶ Vamos aplicar a transformação $1/x$ e verificar como fica o gráfico de dispersão.



Exemplo: (continuação)

- ▶ Vamos aplicar a transformação $1/x$ e verificar como fica o gráfico de dispersão.



- ▶ A relação entre as variáveis parece linear.

Exemplo: (continuação)

- ▶ O modelo ajustado foi o seguinte

$$\log(\hat{Y}) = 3.69 - 1.15/x .$$

- ▶ Vejamos agora o gráfico de resíduos para verificar se as suposições do modelo são válidas.

Exemplo: (continuação)





Figura: Gráfico de resíduos vs valores ajustados e gráfico de probabilidade normal.

Exemplo: (continuação)

- ▶ Conclusões:

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;
 - ▶ no segundo gráfico os pontos caem em torno de uma reta;
 - ▶ isso é um indício de que

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;
 - ▶ no segundo gráfico os pontos caem em torno de uma reta;
 - ▶ isso é um indício de que os erros tem distribuição normal.
- ▶ Percebemos então que a transformação apenas em X resolveu o problema de ajuste do modelo.

Transformação log-log

- ▶ Já vimos que podemos transformar a variável resposta e a explicativa.
- ▶ A transformação mais comum é a log-log.
- ▶ Tiramos o log da variável resposta e da explicativa.
- ▶ Essa transformação é útil quando a verdadeira relação entre X e Y é dada por

$$Y_i = \beta_0 x_i^{\beta_1} \times \epsilon_i .$$

- ▶ O erro aleatório é multiplicativo.

- ▶ Tomando o logaritmo ficamos com

- ▶ Tomando o logaritmo ficamos com

$$\log(Y_i) = \log(\beta_0) + \beta_1 \log x_i + \log(\epsilon_i) .$$

- ▶ Portanto o erro volta ser aditivo como no modelo original.
- ▶ Essa transformação é útil quando:
 - ▶ a relação entre X e Y parece linear, mas a variância está aumentando;
 - ▶ os intervalos de valores de X e Y são muito grandes;
 - ▶ ambos possuem muitos valores pequenos e alguns extremamente grandes.

Exemplo:

- ▶ Estamos analisando a relação entre as seguintes medidas de mamíferos:
 - ▶ peso do cérebro;
 - ▶ peso do corpo.

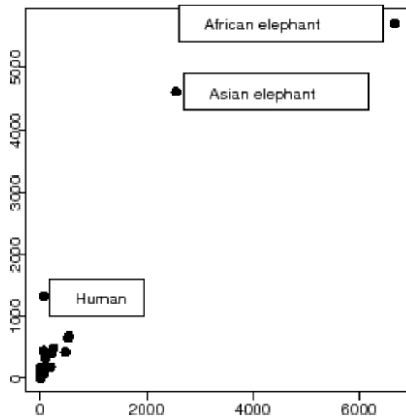


Figura: Peso do cérebro em função do peso do corpo.


Exemplo: (continuação)

- ▶ Esse gráfico não é muito informativo.
- ▶ Quase todas observações estão concentradas no canto esquerdo inferior.
- ▶ Como as duas variáveis apresentam muitos valores pequenos e alguns muito altos, devemos aplicar a transformação log-log.
- ▶ O modelo ajustado é o seguinte

$$\log(\hat{Y}) = 2.092 + 0.763 \log(x) .$$

Exemplo: (continuação)

- ▶ A figura a seguir mostra o gráfico de dispersão para as duas variáveis na escala logaritma.



- ▶ Notamos que agora a relação se aproxima muito mais de uma reta.

Exemplo: (continuação)

- ▶ Vejamos agora os gráficos de resíduos.

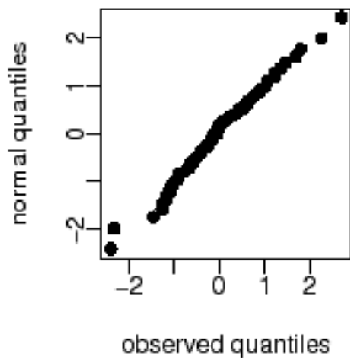



Figura: Gráfico de resíduos vs valores ajustados e gráfico de probabilidade normal.

Exemplo: (continuação)

- ▶ Conclusões:

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;
 - ▶ no segundo gráfico os pontos caem em torno de uma reat;
 - ▶ isso é um indício de que

Exemplo: (continuação)

- ▶ Conclusões:
 - ▶ no primeiro gráfico os pontos estão distribuídos de maneira aleatória;
 - ▶ isso é um indício de que a variância é constante e a relação entre as variáveis é linear;
 - ▶ no segundo gráfico os pontos caem em torno de uma reat;
 - ▶ isso é um indício de que os erros tem distribuição normal.
- ▶ Percebemos então que a transformação apenas em X e em Y problema de ajuste do modelo.