

# Modelos de Regressão Múltipla - Parte V

Erica Castilho Rodrigues

3 de Fevereiro de 2017

## Mínimos Cuadrados Generalizados

# Mínimos Quadrados Generalizados

---

- ▶ O modelo de regressão linear supõe que:

- ▶ O modelo de regressão linear supõe que:
  - ▶ os erros são não correlacionados

- ▶ O modelo de regressão linear supõe que:
  - ▶ os erros são não correlacionados

$$\text{Cov}(\epsilon_i, \epsilon_j) = 0, \forall i \neq j$$

- ▶ O modelo de regressão linear supõe que:
  - ▶ os erros são não correlacionados

$$\text{Cov}(\epsilon_i, \epsilon_j) = 0, \forall i \neq j$$

- ▶ e possuem a mesma variância

$$\text{Var}(\epsilon_i) =$$

- ▶ O modelo de regressão linear supõe que:
  - ▶ os erros são não correlacionados

$$\text{Cov}(\epsilon_i, \epsilon_j) = 0, \forall i \neq j$$

- ▶ e possuem a mesma variância

$$\text{Var}(\epsilon_i) = \sigma^2, \forall i.$$

- ▶ Em notação matricial temos que

$$\text{Var}(\epsilon) =$$

- ▶ O modelo de regressão linear supõe que:
  - ▶ os erros são não correlacionados

$$\text{Cov}(\epsilon_i, \epsilon_j) = 0, \forall i \neq j$$

- ▶ e possuem a mesma variância

$$\text{Var}(\epsilon_i) = \sigma^2, \forall i.$$

- ▶ Em notação matricial temos que

$$\text{Var}(\epsilon) = \sigma^2 \mathbf{I} = \sigma^2 \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & & & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}$$

- ▶ Pode acontecer de algumas observações serem menos confiáveis que outras.
- ▶ Isso significa que a variância de  $Y_i$  e  $\epsilon_i$  não é constante.
- ▶ Dessa maneira não é verdade que

$$\text{Var}(\epsilon) = \sigma^2 \mathbf{I}$$

e sim que

$$\text{Var}(\epsilon) = \begin{bmatrix} v_1 & 0 & \dots & 0 \\ 0 & v_2 & \dots & 0 \\ \vdots & & & \vdots \\ 0 & 0 & \dots & v_n \end{bmatrix} \Rightarrow \text{Var}(\mathbf{Y}) =$$

- ▶ Pode acontecer de algumas observações serem menos confiáveis que outras.
- ▶ Isso significa que a variância de  $Y_i$  e  $\epsilon_i$  não é constante.
- ▶ Dessa maneira não é verdade que

$$\text{Var}(\epsilon) = \sigma^2 \mathbf{I}$$

e sim que

$$\text{Var}(\epsilon) = \begin{bmatrix} v_1 & 0 & \dots & 0 \\ 0 & v_2 & \dots & 0 \\ \vdots & & & \vdots \\ 0 & 0 & \dots & v_n \end{bmatrix} \Rightarrow \text{Var}(\mathbf{Y}) = \begin{bmatrix} v_1 & 0 & \dots & 0 \\ 0 & v_2 & \dots & 0 \\ \vdots & & & \vdots \\ 0 & 0 & \dots & v_n \end{bmatrix}$$

- ▶ Pode acontecer também que, mesmo condicionando em  $X$ , as variáveis  $Y_i$  sejam correlacionadas.
- ▶ Por exemplo, se as variáveis  $Y_i$  tem estrutura temporal ou espacial.
- ▶ Se as variáveis  $X$  não refletem essa estrutura,
  - ▶ os erros não serão independentes.
- ▶ Os elementos fora da diagonal da matriz  $Var(\epsilon)$  não serão todos zero.
- ▶ Essa matriz fica da forma

$$Var(\epsilon) = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1n} \\ v_{21} & v_{22} & \dots & v_{2n} \\ \vdots & & & \vdots \\ v_{n1} & v_{n2} & \dots & v_{nn} \end{bmatrix} \Rightarrow Var(\mathbf{Y}) = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1n} \\ v_{21} & v_{22} & \dots & v_{2n} \\ \vdots & & & \vdots \\ v_{n1} & v_{n2} & \dots & v_{nn} \end{bmatrix}$$

- ▶ Em ambos casos o método de Mínimos Quadrados usual

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

não pode ser aplicado.

- ▶ Vamos denotar o método usual por **Mínimos Quadrados Ordinários** (MQO).
- ▶ Para o caso de variância não constante aplicaremos o método:
  - ▶ **Mínimos Quadrados Ponderados** (MQP) .
- ▶ Para o caso de correlação diferente de zero entre os erros e os  $Y$  usaremos:
  - ▶ **Mínimos Quadrados Generalizados** (MQG) .

- ▶ A idéia básica é transformar o vetor de variáveis  $\mathbf{Y}$  em um novo vetor  $\mathbf{Z}$ .
- ▶ Esse novo vetor deve satisfazer as suposições do modelo

$$\text{Var}(\mathbf{Z}) =$$

- ▶ A idéia básica é transformar o vetor de variáveis  $\mathbf{Y}$  em um novo vetor  $\mathbf{Z}$ .
- ▶ Esse novo vetor deve satisfazer as suposições do modelo

$$\text{Var}(\mathbf{Z}) = \sigma^2 \mathbf{I}.$$

- ▶ Esse vetor será definido da seguinte maneira

$$\mathbf{Z} = \mathbf{QX} + \mathbf{f}$$

com  $\mathbf{f}$  satisfazendo as seguintes suposições

$$E(\mathbf{f}) = \mathbf{0} \quad \text{Var}(\mathbf{f}) = \sigma^2 \mathbf{I}.$$

- ▶ Para que os testes e intervalos sejam válidos precisamos ainda que

$$\mathbf{f} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}).$$

- ▶ Queremos ajustar o seguinte modelo

$$Y = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$$

onde

$$E(\boldsymbol{\epsilon}) = \mathbf{0} \quad \text{Var}(\boldsymbol{\epsilon}) = \sigma^2 \mathbf{V} \quad \boldsymbol{\epsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{V})$$

e

$$\mathbf{V} = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1n} \\ v_{21} & v_{22} & \dots & v_{2n} \\ \vdots & & & \vdots \\ v_{n1} & v_{n2} & \dots & v_{nn} \end{bmatrix}$$

por ser matriz de covariância, é simétrica e positiva definida.

- ▶ Como  $\mathbf{V}$  é positiva definida, existe uma matriz  $\mathbf{P}$  simétrica, não singular, tal que

$$\mathbf{V} = \mathbf{P}'\mathbf{P} = \mathbf{P}\mathbf{P} = \mathbf{P}^2 .$$

- ▶ Então para

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f}$$

vamos definir

$$\mathbf{f} = \mathbf{P}^{-1}\boldsymbol{\epsilon}$$

e veremos que as suposições do modelo serão válidas.

- ▶ Temos que

$$E(\mathbf{f}) =$$

- ▶ Como  $\mathbf{V}$  é positiva definida, existe uma matriz  $\mathbf{P}$  simétrica, não singular, tal que

$$\mathbf{V} = \mathbf{P}'\mathbf{P} = \mathbf{P}\mathbf{P} = \mathbf{P}^2 .$$

- ▶ Então para

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f}$$

vamos definir

$$\mathbf{f} = \mathbf{P}^{-1}\epsilon$$

e veremos que as suposições do modelo serão válidas.

- ▶ Temos que

$$E(\mathbf{f}) = E(\mathbf{P}^{-1}\epsilon) =$$

- ▶ Como  $\mathbf{V}$  é positiva definida, existe uma matriz  $\mathbf{P}$  simétrica, não singular, tal que

$$\mathbf{V} = \mathbf{P}'\mathbf{P} = \mathbf{P}\mathbf{P} = \mathbf{P}^2 .$$

- ▶ Então para

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f}$$

vamos definir

$$\mathbf{f} = \mathbf{P}^{-1}\epsilon$$

e veremos que as suposições do modelo serão válidas.

- ▶ Temos que

$$E(\mathbf{f}) = E(\mathbf{P}^{-1}\epsilon) = \mathbf{P}^{-1}E(\epsilon) =$$

- ▶ Como  $\mathbf{V}$  é positiva definida, existe uma matriz  $\mathbf{P}$  simétrica, não singular, tal que

$$\mathbf{V} = \mathbf{P}'\mathbf{P} = \mathbf{P}\mathbf{P} = \mathbf{P}^2 .$$

- ▶ Então para

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f}$$

vamos definir

$$\mathbf{f} = \mathbf{P}^{-1}\epsilon$$

e veremos que as suposições do modelo serão válidas.

- ▶ Temos que

$$E(\mathbf{f}) = E(\mathbf{P}^{-1}\epsilon) = \mathbf{P}^{-1}E(\epsilon) = \mathbf{0} .$$

- ▶ Vamos agora usar um resultado que diz que se  $\mathbf{Y}$  é um vetor aleatório então

$$\text{Var}(\mathbf{Y}) = E(\mathbf{Y}\mathbf{Y}') - [E(\mathbf{Y})]'[E(\mathbf{Y})].$$

- ▶ Temos então que

$$\text{Var}(\mathbf{f}) =$$

- ▶ Vamos agora usar um resultado que diz que se  $\mathbf{Y}$  é um vetor aleatório então

$$\text{Var}(\mathbf{Y}) = E(\mathbf{Y}\mathbf{Y}') - [E(\mathbf{Y})]'[E(\mathbf{Y})].$$

- ▶ Temos então que

$$\text{Var}(\mathbf{f}) = E(\mathbf{f}\mathbf{f}') - [E(\mathbf{f})]'[E(\mathbf{f})]$$

mas vimos que  $E(\mathbf{f}) = \mathbf{0}$ , logo

$$\begin{aligned} \text{Var}(\mathbf{f}) &= E(\mathbf{f}\mathbf{f}') = E([\mathbf{P}^{-1}\boldsymbol{\epsilon}][\mathbf{P}^{-1}\boldsymbol{\epsilon}']) = E(\mathbf{P}^{-1}\boldsymbol{\epsilon}\boldsymbol{\epsilon}'\mathbf{P}^{-1}) \\ &= \mathbf{P}^{-1}E(\boldsymbol{\epsilon}\boldsymbol{\epsilon}')\mathbf{P}^{-1} \end{aligned}$$

mas

$$\text{Var}(\boldsymbol{\epsilon}) = E([\boldsymbol{\epsilon}][\boldsymbol{\epsilon}']) - [E(\boldsymbol{\epsilon})][E(\boldsymbol{\epsilon})]'$$

como  $E(\boldsymbol{\epsilon}) = \mathbf{0}$

$$\text{Var}(\boldsymbol{\epsilon}) = E([\boldsymbol{\epsilon}][\boldsymbol{\epsilon}']) = \sigma^2\mathbf{V}.$$

- ▶ Substituindo  $E([\epsilon][\epsilon]')$  por  $\sigma^2\mathbf{V}$  ficamos com

$$\text{Var}(\mathbf{f}) = \mathbf{P}^{-1}\sigma^2\mathbf{V}\mathbf{P}^{-1}$$

mas vimos que  $\mathbf{V} = \mathbf{P}\mathbf{P}$ , logo

$$\text{Var}(\mathbf{f}) = \mathbf{P}^{-1}\sigma^2\mathbf{P}\mathbf{P}\mathbf{P}^{-1} = \sigma^2\mathbf{I}.$$

- ▶ Mostramos assim que se definirmos

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f} \quad \text{e} \quad \mathbf{f} = \mathbf{P}^{-1}\epsilon$$

então

$$E(\mathbf{f}) = \mathbf{0} \quad \text{e} \quad \text{Var}(\mathbf{f}) = \sigma^2\mathbf{I}$$

o que implica que

$$E(\mathbf{Z}) =$$

- ▶ Substituindo  $E([\epsilon][\epsilon]')$  por  $\sigma^2\mathbf{V}$  ficamos com

$$\text{Var}(\mathbf{f}) = \mathbf{P}^{-1}\sigma^2\mathbf{V}\mathbf{P}^{-1}$$

mas vimos que  $\mathbf{V} = \mathbf{P}\mathbf{P}$ , logo

$$\text{Var}(\mathbf{f}) = \mathbf{P}^{-1}\sigma^2\mathbf{P}\mathbf{P}\mathbf{P}^{-1} = \sigma^2\mathbf{I}.$$

- ▶ Mostramos assim que se definirmos

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f} \quad \text{e} \quad \mathbf{f} = \mathbf{P}^{-1}\epsilon$$

então

$$E(\mathbf{f}) = \mathbf{0} \quad \text{e} \quad \text{Var}(\mathbf{f}) = \sigma^2\mathbf{I}$$

o que implica que

$$E(\mathbf{Z}) = \mathbf{Q}\mathbf{X} \quad \text{Var}(\mathbf{Z}) =$$

- ▶ Substituindo  $E([\epsilon][\epsilon]')$  por  $\sigma^2\mathbf{V}$  ficamos com

$$\text{Var}(\mathbf{f}) = \mathbf{P}^{-1}\sigma^2\mathbf{V}\mathbf{P}^{-1}$$

mas vimos que  $\mathbf{V} = \mathbf{P}\mathbf{P}$ , logo

$$\text{Var}(\mathbf{f}) = \mathbf{P}^{-1}\sigma^2\mathbf{P}\mathbf{P}\mathbf{P}^{-1} = \sigma^2\mathbf{I}.$$

- ▶ Mostramos assim que se definirmos

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} + \mathbf{f} \quad \text{e} \quad \mathbf{f} = \mathbf{P}^{-1}\epsilon$$

então

$$E(\mathbf{f}) = \mathbf{0} \quad \text{e} \quad \text{Var}(\mathbf{f}) = \sigma^2\mathbf{I}$$

o que implica que

$$E(\mathbf{Z}) = \mathbf{Q}\mathbf{X} \quad \text{Var}(\mathbf{Z}) = \sigma^2\mathbf{I}$$

ou seja, o vetor  $\mathbf{Z}$  satisfaz as propriedades do modelo usual.

- ▶ Além disso, como

$$\epsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{V})$$

e  $\mathbf{f}$  é uma combinação linear do vetor  $\epsilon$  então

$$\mathbf{f} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}) .$$

- ▶ O nosso modelo original é dado por

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon .$$

- ▶ Para que apareça o termo  $\mathbf{P}^{-1}\epsilon$  vamos multiplicar toda equação por  $\mathbf{P}^{-1}$

$$\mathbf{P}^{-1}\mathbf{Y} = \mathbf{P}^{-1}\mathbf{X}\beta + \mathbf{P}^{-1}\epsilon .$$

- ▶ Temos que

$$\mathbf{P}^{-1}\epsilon = \mathbf{f} .$$

- ▶ Vamos denotar

$$\mathbf{P}^{-1}\mathbf{Y} = \mathbf{Z} \quad \mathbf{P}^{-1}\mathbf{X} = \mathbf{Q}.$$

- ▶ E assim

$$\mathbf{P}^{-1}\mathbf{Y} = \mathbf{P}^{-1}\mathbf{X}\boldsymbol{\beta} + \mathbf{P}^{-1}\boldsymbol{\epsilon} \quad \Leftrightarrow \quad \mathbf{Z} = \mathbf{Q}\boldsymbol{\beta} + \mathbf{f}.$$

- ▶ Podemos agora para o novo modelo, em função de  $\mathbf{Z}$ , aplicar o método de mínimos quadrados usual.
- ▶ Podemos fazer isso, pois esse modelo satisfaz as suposições de homocedasticidade e independência.

- ▶ O erro é dado por

$$\mathbf{f} = \mathbf{Z} - \mathbf{Q}\beta .$$

- ▶ Portanto, estamos interessados em minimizar

$$\mathbf{f}'\mathbf{f}$$

como  $\mathbf{f} = \mathbf{P}^{-1}\epsilon$ , ficamos com

$$\mathbf{f}'\mathbf{f} = [\mathbf{P}^{-1}\epsilon]'[\mathbf{P}^{-1}\epsilon] = \epsilon'[\mathbf{P}^{-1}]'\mathbf{P}^{-1}\epsilon$$

como  $\mathbf{P}$  é simétrica,  $\mathbf{P}^{-1}$  também é, logo

$$[\mathbf{P}^{-1}]' = [\mathbf{P}^{-1}]$$

e ficamos com

$$\mathbf{f}'\mathbf{f} = \epsilon'[\mathbf{P}^{-1}][\mathbf{P}^{-1}]\epsilon .$$

- ▶ Já vimos que  $\mathbf{P}\mathbf{P} = \mathbf{V}$  e

$$\mathbf{V}^{-1} = [\mathbf{P}\mathbf{P}]^{-1} = \mathbf{P}^{-1}\mathbf{P}^{-1}$$

substituindo ficamos com

$$\mathbf{f}'\mathbf{f} = \boldsymbol{\epsilon}'[\mathbf{P}^{-1}]'\mathbf{P}^{-1}\boldsymbol{\epsilon} = \boldsymbol{\epsilon}'\mathbf{V}^{-1}\boldsymbol{\epsilon}$$

- ▶ Mas sabemos que  $\boldsymbol{\epsilon} = \mathbf{Y} - \mathbf{X}\boldsymbol{\beta}$  logo

$$\mathbf{f}'\mathbf{f} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'\mathbf{V}^{-1}(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$$

$$= (\mathbf{Y}' - \boldsymbol{\beta}'\mathbf{X}')(\mathbf{V}^{-1}\mathbf{Y} - \mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta})$$

$$= \mathbf{Y}'\mathbf{V}^{-1}\mathbf{Y} - \mathbf{Y}'\mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta}$$

mas, como  $\mathbf{Y}'\mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta}$  é um escalar,

$$[\mathbf{Y}'\mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta}]' = \boldsymbol{\beta}'\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y}.$$

- ▶ Ficamos então com

$$\mathbf{f}'\mathbf{f} = \mathbf{Y}'\mathbf{V}^{-1}\mathbf{Y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta}.$$

- ▶ Derivando e relação a  $\boldsymbol{\beta}$  e igualando a zero

$$-2\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y} + 2\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}\boldsymbol{\beta} = 0.$$

- ▶ Isso implica que

$$\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y} = \mathbf{X}'\mathbf{V}^{-1}\mathbf{X}\hat{\boldsymbol{\beta}}$$

e esse é o nosso novo conjunto de equações normais.

- ▶ Multiplicando por  $[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}$  dos dois lados ficamos com

$$[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}\hat{\beta} = [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y}$$

- ▶ O estimador de  $\beta$  é dado por

$$\hat{\beta} = [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y}.$$

- ▶ Comparando esse estimador como o estimador de Mínimos Quadrados Ordinários

$$\hat{\beta} = [\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'\mathbf{Y}$$

nota-se que a única diferença é a inclusão da matriz  $\mathbf{V}^{-1}$ .

- ▶ A matriz de covariâncias desse estimador é dada por

$$\text{Var}(\hat{\beta}) =$$

- ▶ A matriz de covariâncias desse estimador é dada por

$$\text{Var}(\hat{\beta}) = \text{Var}([\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y})$$

$$\begin{aligned}\text{Var}(\mathbf{A}\mathbf{Y}) &= \mathbf{A}\text{Var}(\mathbf{Y})\mathbf{A}' \\ &= [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\text{Var}(\mathbf{Y})\mathbf{V}^{-1}\mathbf{X}[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\end{aligned}$$

pois  $[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}$  é simétrica.

- ▶ Substituindo  $\text{Var}(\mathbf{Y}) = \sigma^2\mathbf{V}$  ficamos com

$$\begin{aligned}&= [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\sigma^2\mathbf{V}\mathbf{V}^{-1}\mathbf{X}[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1} \\ &= \sigma^2[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\end{aligned}$$

ou seja

$$\text{Var}(\hat{\beta}) = \sigma^2[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}$$

antes tínhamos

$$\text{Var}(\hat{\beta}) = \sigma^2[\mathbf{X}'\mathbf{X}]^{-1}$$

- ▶ A Soma de Quadrados da Regressão é dada por

$$\hat{\beta}'\mathbf{Q}'\mathbf{Z}$$

- ▶ A Soma de Quadrados da Regressão é dada por

$$\begin{aligned} & \hat{\beta}' \mathbf{Q}' \mathbf{Z} \\ &= ([\mathbf{X}' \mathbf{V}^{-1} \mathbf{X}]^{-1} \mathbf{X}' \mathbf{V}^{-1} \mathbf{Y})' (\mathbf{P}^{-1} \mathbf{X})' \mathbf{P}^{-1} \mathbf{Y} \\ &= \mathbf{Y}' \mathbf{V}^{-1} \mathbf{X} [\mathbf{X}' \mathbf{V}^{-1} \mathbf{X}]^{-1} \mathbf{X}' \mathbf{P}^{-1} \mathbf{P}^{-1} \mathbf{Y} \end{aligned}$$

pois  $\mathbf{V}^{-1}$  e  $[\mathbf{X}' \mathbf{V}^{-1} \mathbf{X}]^{-1}$  são simétricas.

- ▶ Como  $\mathbf{P}^{-1} \mathbf{P}^{-1} = \mathbf{V}^{-1}$  ficamos com

$$\mathbf{Y}' \mathbf{V}^{-1} \mathbf{X} [\mathbf{X}' \mathbf{V}^{-1} \mathbf{X}]^{-1} \mathbf{X}' \mathbf{V}^{-1} \mathbf{Y}$$

- ▶ A Soma de Quadrados Totais fica

$$\mathbf{Z}'\mathbf{Z} =$$

- ▶ A Soma de Quadrados Totais fica

$$\mathbf{Z}'\mathbf{Z} = (\mathbf{P}^{-1}\mathbf{Y})'\mathbf{P}^{-1}\mathbf{Y} =$$

$$\mathbf{Y}'\mathbf{P}^{-1}\mathbf{P}^{-1}\mathbf{Y} = \mathbf{Y}'\mathbf{V}^{-1}\mathbf{Y}$$

pois  $\mathbf{P}^{-1}$  é simétrica.

- ▶ A Soma de Quadrados dos Resíduos fica então

$$\mathbf{Y}'\mathbf{V}^{-1}\mathbf{Y} - \mathbf{Y}'\mathbf{V}^{-1}\mathbf{X}[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y}$$

- ▶ Os resíduos a serem analisados são as estimativas de

$$\mathbf{f} = \mathbf{P}^{-1}\epsilon$$

e são dados por

$$\mathbf{f} = \mathbf{Z} - \hat{\mathbf{Z}} = \mathbf{P}^{-1}(\mathbf{Y} - \hat{\mathbf{Y}})$$

## Observações

- ▶ Nos problemas práticos, é difícil saber a forma da matriz  $\mathbf{V}$ .
- ▶ Será necessário, as vezes, primeiro fazer a suposição de que

$$\mathbf{V} \propto I$$

mesmo sabendo que é errada.

- ▶ Em seguida fazer a inferência via mínimos quadrados ordinários.
- ▶ E então, examinar os resíduos para se descobrir algo sobre a forma de  $\mathbf{V}$ .

## Observações

- ▶ Considere um caso em que é necessário usar Mínimos Quadrados Generalizados.
- ▶ Suponha que o método dos Mínimos Quadrados Ordinários é usado erroneamente.
- ▶ A estimativa de  $\beta$  ainda sim será não- viciada

$$E(\hat{\beta}) = \beta .$$

- ▶ Porém não terá variância mínima.
- ▶ Usar Mínimos Quadrados Ordinários no lugar de Mínimos Quadrados Generalizados produz estimadores com maior variabilidade.

- ▶ Vejamos alguns exemplos de forma da matriz  $\mathbf{V}$ .
- ▶ Considere o caso em que temos apenas uma parâmetro

$$Y_i = \beta_1 X_i + \epsilon_i \quad \epsilon_i \sim N(0, 1/w_i) .$$

- ▶ Nesse caso temos que

$$\text{Var}(\mathbf{Y}) =$$

- ▶ Vejamos alguns exemplos de forma da matriz  $\mathbf{V}$ .
- ▶ Considere o caso em que temos apenas uma parâmetro

$$Y_i = \beta_1 X_i + \epsilon_i \quad \epsilon_i \sim N(0, 1/w_i) .$$

- ▶ Nesse caso temos que

$$\text{Var}(\mathbf{Y}) = \sigma^2 \mathbf{V} = \sigma^2 \begin{bmatrix} 1/w_1 & 0 & \dots & 0 \\ 0 & 1/w_2 & \dots & 0 \\ 0 & 0 & \dots & 1/w_n \end{bmatrix}$$

onde os  $w$ 's são pesos a serem especificados.

- ▶ Temos então nesse caso que

$$\mathbf{V}^{-1} =$$

- ▶ Temos então nesse caso que

$$\mathbf{V}^{-1} = \begin{bmatrix} w_1 & 0 & \dots & 0 \\ 0 & w_2 & \dots & 0 \\ 0 & 0 & \dots & w_n \end{bmatrix}$$

- ▶ Vimos que o estimador de  $\beta$  é dado por

$$\hat{\beta} = [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y}.$$

- ▶ Vejamos como fica esse estimador para esse caso específico.

- ▶ Temos que

$$\begin{aligned} \mathbf{X}'\mathbf{V}^{-1} &= [X_{11} \quad X_{21} \quad \dots \quad X_{n1}] \sigma^2 \begin{bmatrix} w_1 & 0 & \dots & 0 \\ 0 & w_2 & \dots & 0 \\ 0 & 0 & \dots & w_n \end{bmatrix} \\ &= \sigma^2 [X_{11}w_1 \quad X_{21}w_2 \quad \dots \quad X_{n1}w_n] \end{aligned}$$

- ▶ Logo

$$\mathbf{X}'\mathbf{V}^{-1}\mathbf{X} = \sigma^2 [X_{11}w_1 \quad X_{21}w_2 \quad \dots \quad X_{n1}w_n] \begin{bmatrix} X_{11} \\ X_{21} \\ \vdots \\ X_{n1} \end{bmatrix} = \sigma^2 \sum_{i=1}^n w_i X_{i1}^2$$

- ▶ Logo

$$[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1} = \frac{1}{\sigma^2 \sum_{i=1}^n w_i X_{i1}^2}$$

- ▶ Além disso

$$\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y} = \sigma^2 [X_{11}w_1 \quad X_{21}w_2 \quad \dots \quad X_{n1}w_n] \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \sum_{i=1}^n w_i X_{i1} Y_i$$

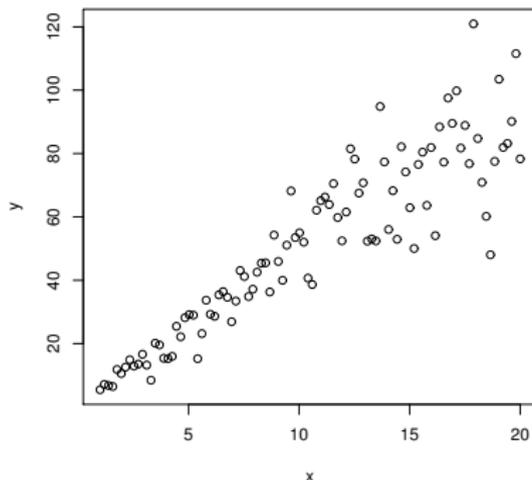
- ▶ Portanto

$$\hat{\beta} = [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{Y} = \frac{\sum_{i=1}^n w_i X_{i1} Y_i}{\sum_{i=1}^n w_i X_{i1}^2}.$$

- ▶ Vejamos agora alguns exemplos de pesos possíveis.

## Exemplo

- ▶ Vamos considerar o caso em que a variância é proporcional a  $X_j$ .
- ▶ Quanto maior o valor da variável explicativa, maior a variabilidade.



## Exemplo (continuação)

- ▶ Temos então que

$$w_i = \frac{1}{kX_i} \Rightarrow \hat{\beta}_1 = \frac{\sum_{i=1}^n w_i X_{i1} Y_i}{\sum_{i=1}^n w_i X_{i1}^2} =$$

## Exemplo (continuação)

- ▶ Temos então que

$$w_i = \frac{1}{kX_i} \Rightarrow \hat{\beta}_1 = \frac{\sum_{i=1}^n w_i X_{i1} Y_i}{\sum_{i=1}^n w_i X_{i1}^2} = \frac{\sum_{i=1}^n X_{i1} Y_i / (kX_i)}{\sum_{i=1}^n X_{i1}^2 / (kX_i)}$$
$$= \frac{\sum_{i=1}^n Y_i}{\sum_{i=1}^n X_{i1}} =$$

## Exemplo (continuação)

- ▶ Temos então que

$$w_i = \frac{1}{kX_i} \Rightarrow \hat{\beta}_1 = \frac{\sum_{i=1}^n w_i X_{i1} Y_i}{\sum_{i=1}^n w_i X_{i1}^2} = \frac{\sum_{i=1}^n X_{i1} Y_i / (kX_i)}{\sum_{i=1}^n X_{i1}^2 / (kX_i)}$$

$$= \frac{\sum_{i=1}^n Y_i}{\sum_{i=1}^n X_{i1}} = \frac{\sum_{i=1}^n Y_i / n}{\sum_{i=1}^n X_{i1} / n} = \frac{\bar{Y}}{\bar{X}}.$$

- ▶ Além disso, sabemos que

$$\text{Var}(\hat{\beta}) = \sigma^2 [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}$$

mas vimos que

$$[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1} =$$

## Exemplo (continuação)

- ▶ Temos então que

$$w_i = \frac{1}{kX_i} \Rightarrow \hat{\beta}_1 = \frac{\sum_{i=1}^n w_i X_{i1} Y_i}{\sum_{i=1}^n w_i X_{i1}^2} = \frac{\sum_{i=1}^n X_{i1} Y_i / (kX_i)}{\sum_{i=1}^n X_{i1}^2 / (kX_i)}$$

$$= \frac{\sum_{i=1}^n Y_i}{\sum_{i=1}^n X_{i1}} = \frac{\sum_{i=1}^n Y_i / n}{\sum_{i=1}^n X_{i1} / n} = \frac{\bar{Y}}{\bar{X}}.$$

- ▶ Além disso, sabemos que

$$\text{Var}(\hat{\beta}) = \sigma^2 [\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1}$$

mas vimos que

$$[\mathbf{X}'\mathbf{V}^{-1}\mathbf{X}]^{-1} = \sum_{i=1}^n w_i X_{i1}^2.$$

## Exemplo (continuação)

- ▶ Portanto

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n w_i X_{i1}^2} = \frac{\sigma^2}{\sum_{i=1}^n X_{i1}^2 / (kX_{i1})} =$$

## Exemplo (continuação)

- ▶ Portanto

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n w_i X_{i1}^2} = \frac{\sigma^2}{\sum_{i=1}^n X_{i1}^2 / (kX_{i1})} = \sigma^2 \frac{k}{\sum_{i=1}^n X_{i1}}$$

## Exemplo

- ▶ Vejamos agora um exemplo numérico.
- ▶ Um modelo linear simples é ajustado usando Mínimos Quadrados Ordinários.
- ▶ O gráfico a seguir mostra os resíduos em função dos valores ajustados e variável explicativa.

## Exemplo (continuação)

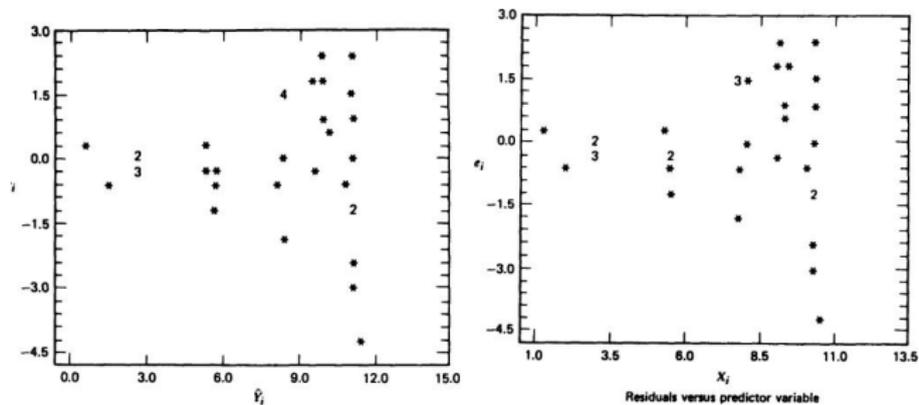


Figura: Gráfico de Resíduos.

## Exemplo (continuação)

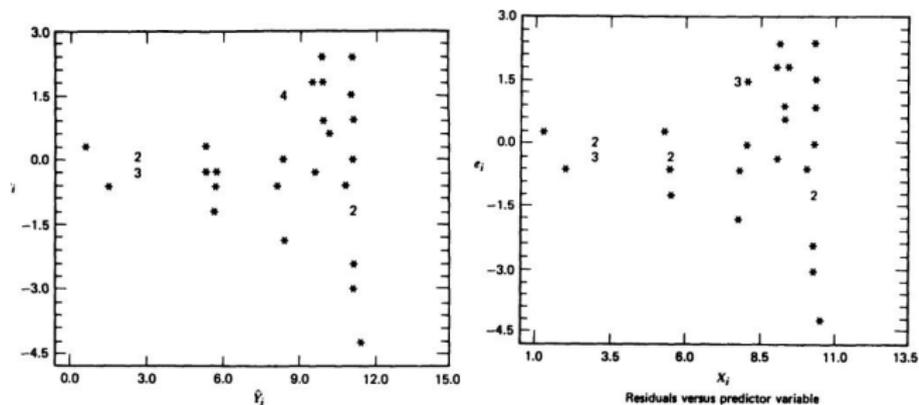


Figura: Gráfico de Resíduos.

- Notamos claramente que a variância não é constante.

## Exemplo (continuação)

- ▶ Esses gráficos mostram que usar Mínimos Quadrados Ordinários não é o mais adequado nesse caso.
- ▶ Devemos usar mínimos quadrados generalizados.
- ▶ Vamos assumir que os  $Y_i$  são independentes, ou seja, a matriz de covariâncias é diagonal.
- ▶ Iremos permitir, porém, que as variâncias mudem de uma observação para a outra.
- ▶ A base de dados possui alguns valores repetidos de  $X$  ou muito próximos.
- ▶ Esses valores serão usados para estimar os pesos  $w$ 's.

## Exemplo (continuação)

- ▶ Foram calculadas as médias e o quadrado médio do erro puro para cada conjunto de valores repetido de  $X$

$\bar{X}_j$	3.0	5.4	7.8	9.1	10.2
$s_{ej}^2$	0.0072	0.3440	1.7404	0.8683	3.8964

- ▶ Como alguns valores de  $X$  foram arredondados, precisamos estimar  $s_{ej}^2$  para esses valores.
- ▶ Ajustamos um polinômio de segundo grau

$$\hat{s}_{ej}^2 = 1.5329 - 0.7334\bar{X} + .0883\bar{X}^2 .$$

## Exemplo (continuação)

- ▶ Substituindo os valores de  $X_i$  na equação, obtemos os valores de  $\hat{S}_{ej}^2$ .
- ▶ Os pesos são dados por

$$w_j = \frac{1}{\hat{S}_{ej}^2} .$$

- ▶ A Figura a seguir mostra os gráficos de resíduos obtidos com esse novo modelo ajustado.

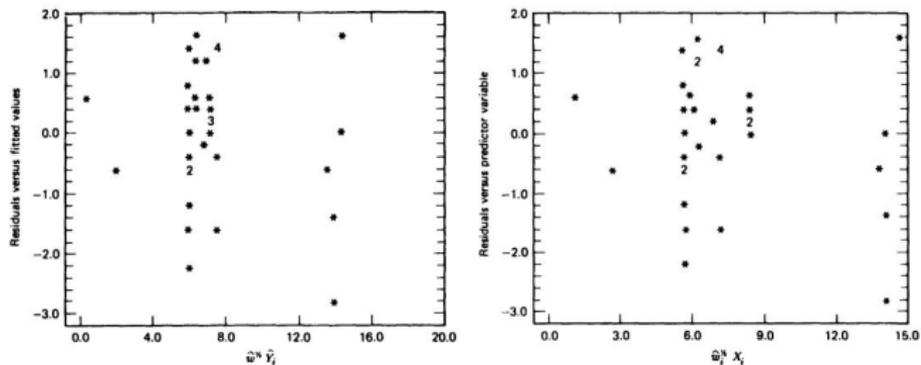


Figura: Gráfico de Resíduos usando Mínimos Cuadrados Generalizados.

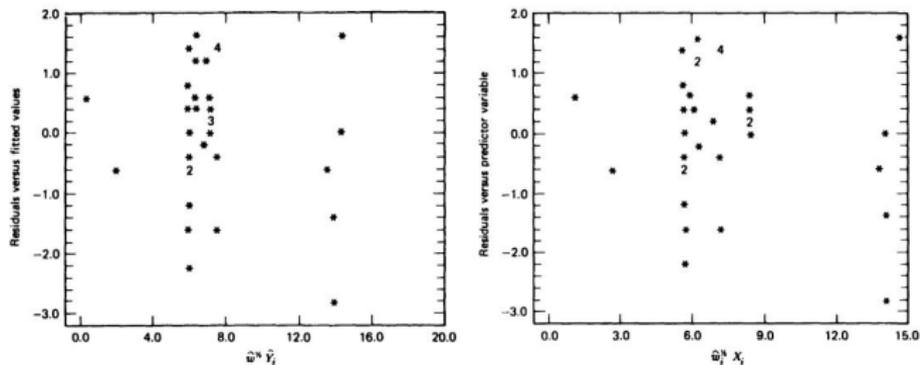


Figura: Gráfico de Resíduos usando Mínimos Quadrados Generalizados.

- Notamos claramente que o problema de heterocedasticidade foi resolvido.

- ▶ Veremos como usar esse método no R.

```
lm.gls(formula, data, W, subset, na.action,  
        inverse = FALSE,  
        method = "qr", model = FALSE,  
        x = FALSE, y = FALSE,  
        contrasts = NULL, ...)
```