

MODELO DE REGRESSÃO LINEAR SIMPLES

O modelo de regressão linear simples considera apenas uma variável explicativa e a função de regressão é linear. O modelo é definido por:

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad (1)$$

em que:

- Y_i é o valor da variável resposta para a i -ésima observação,
- β_0 é o intercepto e β_1 é o coeficiente angular, ambos são parâmetros desconhecidos,
- X_i é uma constante conhecida, o valor da variável explicativa para a i -ésima observação. X_i é uma variável fixa (ou sem erro ou determinística),
- ε_i são independentes e $N(0, \sigma^2)$.

MODELO DE REGRESSÃO LINEAR GERAL

Em geral, a variável resposta Y pode estar relacionada com p variáveis explicativas. O modelo de regressão é definido por:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i, \quad (2)$$

é conhecido como modelo de primeira ordem, pois é linear nos parâmetros e linear nas variáveis explicativas. Esse modelo é conhecido como um modelo de regressão linear múltipla ou também como um modelo de regressão linear geral.

- Y_i é o valor da variável resposta para a i -ésima observação,
- $\beta_0, \beta_1, \dots, \beta_p$ são parâmetros desconhecidos,
- $X_{i1}, X_{i2}, \dots, X_{ip}$ são constantes conhecidas,
- ε_i são independentes e $N(0, \sigma^2)$, $i = 1, \dots, n$.

DIAGNÓSTICO

- A análise de diagnóstico é um importante procedimento para avaliar a adequabilidade do modelo de regressão múltipla.
- Para verificar a adequabilidade do modelo serão usados:
 - Métodos Gráficos
 - Testes de Hipóteses.

DIAGNÓSTICO

- É interessante iniciar a análise de dados com os seguintes gráficos: Box plot, ramo e folhas, diagrama de dispersão univariado de cada uma das variáveis explicativas e também da variável resposta.
- O próximo passo é realizar um estudo bidimensional entre cada variável explicativa e a variável resposta e também entre duas variáveis explicativas. Para esse estudo pode-se usar o diagrama de dispersão, bem como, o coeficiente de correlação linear de Pearson.
- Esse estudo dará informações preliminares sobre os dados.

DIAGNÓSTICO

- Gráficos do resíduo versus os valores ajustados é utilizado para:
 - Avaliar a adequação da função de regressão múltipla
 - Os erros do modelo tem Variância constante
 - Presença de valor atípico
- Gráfico do resíduo absoluto versus os valores ajustados também é usado para verificar se os erros do modelo tem Variância constante.
- Gráfico dos resíduos versus tempo ou uma outra sequência é usado para verificar se os Erros são Independentes.
- Box plot e o gráfico normal de probabilidade são usados para verificar se os Erros são Normais.

DIAGNÓSTICO

- Gráficos dos resíduos versus cada variável explicativa dará informação sobre a adequação da função de regressão com respeito a variável explicativa considerada.
- Gráficos dos resíduos versus cada variável explicativa também informará possível variação da variância que pode estar relacionada com a variável explicativa considerada.
- Gráficos dos resíduos versus variável explicativa não introduzida no modelo ou ainda, versus interação, $X_1X_2, X_1X_3, X_2X_3, \dots$, mostrará se a variável ou a interação devem ser introduzidas no modelo.

DIAGNÓSTICO

- Forma gráfica ideal e não ideal para os pressupostos do modelo serem válidos:

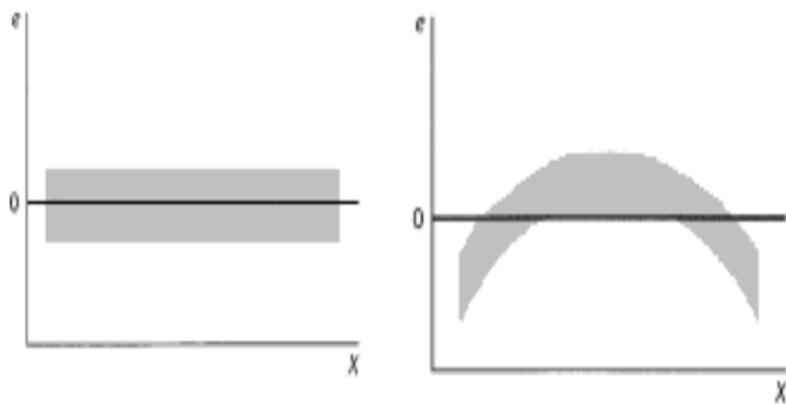


FIGURA : Modelo de regressão linear é apropriado. (b) Modelo de regressão linear não é apropriado

DIAGNÓSTICO

- Teste Shapiro Wilks - para normalidade dos erros
- Teste Brown-Forsythe e Breusch-Pagan para variância constante dos erros. São utilizados quando há evidências de que a variância do erro ou cresce ou decresce com uma determinada variável explicativa.
- Teste F para falta de ajustamento do modelo de regressão

Identificando observações discrepantes em relação à Y

RESÍDUOS

- Resíduos - como já definido, o resíduo é dado por:

$$e_i = Y_i - \hat{Y}_i$$

- Resíduo semistudentizado ou padronizado

$$e_i^* = \frac{e_i}{\sqrt{MSRes}}$$

MATRIZ \mathbf{H} - "CHAPÉU"

- A matriz \mathbf{H} é definida por:

$$\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$$

- Os valores de \hat{Y}_i podem ser expressos como uma combinação linear dos Y_i através da matriz \mathbf{H} :

$$\hat{\mathbf{Y}} = \mathbf{H}\mathbf{Y}$$

- E os resíduos e_i também podem ser expressos como uma combinação linear dos Y_i através da matriz \mathbf{H} :

$$\mathbf{e} = (\mathbf{I} - \mathbf{H})\mathbf{Y}$$

MATRIZ \mathbf{H} - "CHAPÉU"

- A matriz de variância e covariância do resíduo é definida como:

$$\text{Cov}(\mathbf{e}) = \sigma^2(\mathbf{I} - \mathbf{H})$$

- Dessa forma, a variância do resíduo, e_i é dada por:

$$\text{Var}(e_i) = \sigma^2(1 - h_{ii})$$

- E a covariância entre e_i e e_j , para $i \neq j$, é:

$$\text{Cov}(e_i, e_j) = \sigma^2(0 - h_{ij}) = -h_{ij}\sigma^2$$

em que h_{ii} são os elementos da diagonal principal da matriz \mathbf{H} e h_{ij} são os elementos da i -ésima linha e j -ésima coluna da matriz \mathbf{H} .

MATRIZ H - "CHAPÉU"

- Ao usar $MSRes$, o estimador da variância do erro - σ^2 , as estimativas das variâncias e covariâncias são definidas por:

$$Var(\hat{e}_i) = MSRes(1 - h_{ii})$$

e

$$Cov(\hat{e}_i, \hat{e}_j) = -h_{ij}MSRes$$

RESÍDUO STUDENTIZADO

- Os resíduos e_i podem ter variâncias substancialmente diferentes.
- Por isso, é importante considerar a magnitude de cada resíduo relativa ao desvio padrão estimado de cada resíduo. Dando origem ao Resíduo Studentizado:

$$r_i = \frac{e_i}{\sqrt{MSRes(1 - h_{ii})}}$$

- O resíduo studentizado tem variância constante, $Var(r_i) = 1$.

RESÍDUO EXCLUÍDO

- Se a i -ésima observação, Y_i , é realmente incomum, discrepante, o modelo de regressão ajustado usando todas as observações pode ser influenciado por essa observação.
- Uma outra medida para verificar se a i -ésima observação, Y_i , é discrepante, é o resíduo excluído definido por:

$$e_{(i)} = Y_i - \hat{Y}_{i(i)},$$

também conhecido como erro de predição PRESS para o i -ésimo caso.

- Uma expressão equivalente para $e_{(i)}$ é:

$$e_{(i)} = \frac{e_i}{(1 - h_{ii})}$$

- Dessa forma, o critério PRESS pode ser obtido por:

$$PRESS_{p+1} = \sum_{i=1}^n \left(\frac{e_i}{(1 - h_{ii})} \right)^2$$


RESÍDUO EXCLUÍDO

- A variância do resíduo excluído é dada por:

$$\begin{aligned} \text{Var}(e_{(i)}) &= \frac{1}{(1 - h_{ii})^2} \text{Var}(e_i) = \frac{1}{(1 - h_{ii})^2} [\sigma_{(i)}^2 (1 - h_{ii})] \\ &= \frac{\sigma_{(i)}^2}{(1 - h_{ii})} \end{aligned}$$

- Consequentemente, a variância estimada é definida por:

$$\text{Var}(\hat{e}_{(i)}) = \frac{MSRes_{(i)}}{(1 - h_{ii})},$$

em que $MSRes_{(i)}$ é o $MSRes$ do modelo quando a i -ésima observação é excluída.

RESÍDUO EXCLUÍDO STUDENTIZADO

- Seguindo a definição do resíduo studentizado, o resíduo excluído studentizado é definido por:

$$t_i = \frac{e_{(i)}}{\sqrt{\text{Var}(\hat{e}_{(i)})}} \sim \text{t-Student}_{n-1-(p+1)}$$

Identificando observações discrepantes em relação à X

- Pontos potencialmente distantes tem impacto nas estimativas dos parâmetros, erro padrão, valores preditos e estatísticas do modelo. A matriz \mathbf{H}

$$\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$$

é importante para detectar observações influentes.

- Os elementos h_{ii} da matriz \mathbf{H} são definidos por:

$$h_{ii} = \mathbf{X}'_i(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}_i,$$

em que \mathbf{X}_i é a i -ésima linha da matriz \mathbf{X} . A diagonal da matriz \mathbf{H} é uma medida padronizada da distância da i -ésima observação do centro do espaço de X .

- Valor grande de h_{ii} indica que a i -ésima observação está distante do centro das observações e que essa observação pode ser considerada um ponto de alavanca (leverage point).
- Outra forma de verificar ponto de alavanca é quando:
 $h_{ii} > 2\bar{h}$, em que $\bar{h} = \sum_{i=1}^n h_{ii}/n$.

- Após identificar valores discrepantes com respeito aos valores de Y ou X , o próximo passo é verificar se essas observações são ou não observações influentes.
- Medidas para identificar observações influentes são:
 - DFFITS
 - Distância de Cook
 - DFBETAS

DFFITS

- Medida da influência que a i -ésima observação tem sobre o valor ajustado \hat{Y}_i é dada por:

$$(\text{DFFITS})_i = \frac{\hat{Y}_i - \hat{Y}_{i(i)}}{\sqrt{MSRes_{(i)} h_{ii}}}$$

em que:

- \hat{Y}_i valor ajustado para o i -ésimo caso quando todas as n observações são usadas no ajuste do modelo
- $\hat{Y}_{i(i)}$ valor ajustado para o i -ésimo caso quando o i -ésimo caso é omitido no ajuste do modelo
- $MSRes_{(i)}$ quando o i -ésimo caso é omitido no ajuste do modelo.

DFFITS

- O valor de DFFITS pode ser obtido usando apenas o resultado do ajuste do modelo com todos os dados por meio de:

$$(\text{DFFITS})_i = t_i \left(\frac{h_{ii}}{1 - h_{ii}} \right)^{1/2}$$

- Para identificar se uma observação é influente:
- Se $|(\text{DFFITS})_i| > 1$, para conjunto de dados pequenos ou médios,
- Se $|(\text{DFFITS})_i| > 2\sqrt{p/n}$, para conjunto de dados grandes.

DISTÂNCIA DE COOK

- Cook(1977,1979) sugeriu uma medida usando a distância ao quadrado entre todas as estimativas $\hat{\beta}$, e a estimativa obtida ao excluir a i -ésima observação, $\hat{\beta}_{(i)}$. Essa medida da distância pode ser expressa por:

$$D_i = \frac{(\hat{\beta}_{(i)} - \hat{\beta})' \mathbf{M} (\hat{\beta}_{(i)} - \hat{\beta})}{c},$$

em que \mathbf{M} e c são usualmente $\mathbf{M} = (\mathbf{X}'\mathbf{X})$ e $c = (p + 1)MSRes$. Logo:

$$D_i = \frac{(\hat{\beta}_{(i)} - \hat{\beta})' (\mathbf{X}'\mathbf{X}) (\hat{\beta}_{(i)} - \hat{\beta})}{(p + 1)MSRes}.$$

DISTÂNCIA DE COOK

- A distância de Cook, medida da influência que a i -ésima observação tem sobre todos os n valores ajustados, também pode ser definida por:

$$D_i = \sum_{i=1}^n \frac{(\hat{Y}_i - \hat{Y}_{i(i)})^2}{(p+1)MSRes}$$

- A distância de Cook pode ser obtida usando apenas o resultado do ajuste do modelo com todos os dados por meio de:

$$D_i = \frac{e_i^2}{pMSRes} \left[\frac{h_{ii}}{(1-h_{ii})^2} \right]$$

- Valores de $D_i > 1$ são consideradas observações influentes.

DFBETAS

- Medida da influência que a i -ésima observação tem sobre cada um dos coeficientes de regressão estimados é dada por:

$$(DFBETAS)_{k(i)} = \frac{\hat{\beta}_k - \hat{\beta}_{k(i)}}{\sqrt{MSRes_i C_{kk}}}$$

em que:

- $\hat{\beta}_k$ coeficiente de regressão estimado considerando todos os n casos no ajuste do modelo
- $\hat{\beta}_{k(i)}$ coeficiente de regressão estimado considerando que o i -ésimo caso é omitido no ajuste do modelo
- $MSRes_i$ é o $MSRes$ quando o i -ésimo caso é omitido no ajuste do modelo
- C_{kk} o k -ésimo elemento da diagonal da matriz $(\mathbf{X}'\mathbf{X})^{-1}$.

Interpretação da medida DFBETAS:

- Sinal - indica se a inclusão do i -ésimo caso leva ao aumento ou a diminuição da estimativa do coeficiente de regressão
- Valor grande de $(DFBETAS)_{k(i)}$ indica grande influência do i -ésimo caso na estimativa do k -ésimo coeficiente de regressão.
- Se $|(DFBETAS)_{k(i)}| > 1$, para conjunto de dados pequenos ou médios, \Rightarrow observação é influente
- Se $|(DFBETAS)_{k(i)}| > 2\sqrt{p/n}$, para conjunto de dados grandes \Rightarrow observação é influente.

Diagnóstico de Multicolinearidade

DIAGNÓSTICO DE MULTICOLINEARIDADE

Diagnóstico informal

- Coeficientes de correlação alto entre pares de variáveis explicativas.
- Mudanças grandes nas estimativas dos coeficientes de regressão quando:
 - uma variável explicativa é adicionada ou retirada do modelo;
 - uma observação é alterada ou apagada.
- Nos testes individuais sobre os coeficientes de regressão para variáveis explicativas importantes do modelo aceita-se $H_0 : \beta_k = 0$
- Coeficientes de regressão estimados com sinal algébrico oposto do que se espera através de considerações teóricas ou experiência anterior
- Intervalos de confiança para os coeficientes de regressão de variáveis explicativas importantes apresentam grande amplitude.

DIAGNÓSTICO DE MULTICOLINEARIDADE

Limitações:

- Estes métodos informais não fornecem medidas quantitativas do impacto da multicolinearidade e não podem identificar a natureza da multicolinearidade.
- Algumas vezes o comportamento observado pode ocorrer sem que exista de fato multicolinearidade.

Fator de inflação da Variância (VIF)

- Esse fator mede quanto a variância dos estimadores de mínimos quadrados são influenciadas quando comparada com variáveis explicativas que não são correlacionadas.
- Para entender esse fator, começa-se com a matriz de variâncias e covariâncias dos estimadores de mínimos quadrados:

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

- Para medir o impacto da multicolinearidade, é útil utilizar o modelo de regressão padronizado definido em aulas anteriores para reduzir os erros de arredondamento no cálculo da matriz $(\mathbf{X}'\mathbf{X})^{-1}$.

DIAGNÓSTICO DE MULTICOLINEARIDADE

- No modelo transformado os coeficientes de regressão estimados $\hat{\beta}_k^*$ são padronizados e sua matriz de covariâncias é dada por:

$$\text{Var}(\beta^*) = (\sigma^*)^2(\mathbf{r}_{\mathbf{X}\mathbf{X}})^{-1},$$

em que $\mathbf{r}_{\mathbf{X}\mathbf{X}}$ é a matriz de correlação simples entre os pares de variáveis X e $(\sigma^*)^2$ é a variância do erro do modelo transformado.

DIAGNÓSTICO DE MULTICOLINEARIDADE

- Porém, $(\mathbf{r}_{\mathbf{xx}})^{-1}$ é o fator de inflação da variância (VIF) para β_k^* . Logo:

$$\text{Var}(\beta_k^*) = (\sigma^*)^2(\text{VIF})_k,$$

- Os elementos da diagonal de $(\text{VIF})_k$ é o fator de inflação da variância (VIF) para β_k^* e é igual a:

$$(\text{VIF})_k = (1 - R_k^2)^{-1},$$

em que R_k^2 é o coeficiente de determinação múltipla quando X_k é retirado do modelo que contém $(p = (p + 1) - 1)$ variáveis .

DIAGNÓSTICO DE MULTICOLINEARIDADE

- Se $R_k^2 = 0 \Rightarrow (VIF)_k = 1$ e X_k não está correlacionada com as demais variáveis.
- Se $R_k^2 \neq 0 \Rightarrow (VIF)_k > 1$ e X_k está correlacionada com as demais variáveis.
- Quando X_k está perfeitamente relacionada com as outras variáveis do modelo $\Rightarrow R_k^2 = 1$ e $(VIF)_k$ será ilimitado (valor grande).

DIAGNÓSTICO DE MULTICOLINEARIDADE

Indicador de Multicolinearidade

- Se o máximo dos $(VIF)_k > 10 \Rightarrow$ Multicolinearidade está influenciando as estimativas dos parâmetros.
- Se $R_k^2 = 0 \Rightarrow (VIF)_k = 1 \Rightarrow$ Não existe Multicolinearidade
- Outra forma de verificar é obter:

$$(V\bar{I}F)_k = \frac{\sum_{k=1}^p (VIF)_k}{p}$$

- Se $(V\bar{I}F)_k$ for um valor consideravelmente maior que 1 \Rightarrow Multicolinearidade está influenciando as estimativas dos parâmetros.