

# Modelos Lineares Generalizados - Introdução

Erica Castilho Rodrigues

18 de Março de 2014

Introdução

Revisão - Regressão Múltipla

## Por que queremos modelar os dados?

- ▶ A forma do modelo revela padrões de interação e associação nos dados.
- ▶ Através de procedimentos de inferência podemos verificar:
  - ▶ quais variáveis explicativas estão relacionadas com a variável resposta;
  - ▶ enquanto controlamos outras variáveis relevantes.
- ▶ A estimativa dos parâmetros fornece a importância de cada variável no modelo.

- ▶ Suponha que temos uma variável resposta contínua  $Y$ .
- ▶ Temos ainda um conjunto de variáveis explicativas:

$$X_1, X_2, \dots, X_k.$$

- ▶ Queremos modelar  $Y$  como função das explicativas.
- ▶ Podemos usar um modelo de regressão

- ▶ Suponha que temos uma variável resposta contínua  $Y$ .
- ▶ Temos ainda um conjunto de variáveis explicativas:

$$X_1, X_2, \dots, X_k.$$

- ▶ Queremos modelar  $Y$  como função das explicativas.
- ▶ Podemos usar um modelo de regressão

$$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \epsilon_i$$

onde

- ▶  $Y_i$  é a variável resposta observada no  $i$ -ésimo indivíduo;
- ▶  $\beta_0, \dots, \beta_k$  são os coeficientes que descrevem o modelo;
- ▶  $x_{ki}$  é a  $k$ -ésima variável explicativa observada no  $i$ -ésimo indivíduo;
- ▶  $\epsilon_i$  são erros aleatórios iid tais que

$$\epsilon_i \sim N(0, \sigma^2).$$


- ▶ Em geral podemos escrever

$$\mathbf{Y} = E(\mathbf{Y}) + \epsilon$$

onde

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

- ▶ O modelo de regressão linear simples pode ser representado da seguinte maneira.



- ▶ Algumas técnicas que podem ser aplicadas para esse tipo de modelo:
  - ▶ Regressão Linear Simples;
  - ▶ Regressão Linear Múltipla;
  - ▶ ANCOVA;
  - ▶ ANOVA.

- ▶ O estimador de mínimos quadrados do vetor  $\beta$  é dado por

- ▶ O estimador de mínimos quadrados do vetor  $\beta$  é dado por

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

- ▶ O valor predito de  $\mathbf{Y}$  é dado por

- ▶ O estimador de mínimos quadrados do vetor  $\beta$  é dado por

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

- ▶ O valor predito de  $\mathbf{Y}$  é dado por

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

- ▶ A matriz  $\mathbf{H}$  pode ser usada para fazer vários diagnósticos de ajuste.
- ▶ Nos Modelos Lineares Generalizados veremos muitas semelhanças.


- ▶ Todas as conclusões do modelo estão pautadas em um suposição forte:
  - ▶ o vetor  $\mathbf{Y}$  tem distribuição normal.
- ▶ Muitas vezes essa suposição não será satisfeita.
- ▶ Se a resposta for uma variável categórica, isso não será verdade.
- ▶ Se  $\mathbf{Y}$  for quantitativa discreta a suposição também será violada.
- ▶ Precisamos, então, usar os Modelos Lineares Generalizados.

- ▶ Considere as seguintes situações:
  - ▶ Um paciente é submetido a um cirurgia.
  - ▶ Deseja-se prever a chance do paciente sobreviver.
  - ▶ Estima-se essa chance com base em dados clínicos pré-operatórios.
  
- ▶ Estamos analisando casos de dengue em municípios.
- ▶ Queremos tentar prever o número de casos.
- ▶ Podemos usar informações sócio-econômicas do município.


## Objetivo da Disciplina

- ▶ Fornecer ferramentas para a análise de dados que não apresentam uma distribuição Normal:
  - ▶ Bernoulli/Binomial;
  - ▶ Poisson;
  - ▶ Binomial Negativa;
  - ▶ Gama.

- ▶ Veremos modelos para tratar com dados binários.



- ▶ Modelos para lidar com dados heterocedásticos.



## Revisão - Regressão Múltipla

---

## Interpretação dos Coeficientes

### Interpretação do $\beta_j$ pra $j \geq 1$

- ▶ Considere o modelo

$$Y_i = \beta_0 + \beta_1 X_{1i} + \cdots + \beta_p X_{pi} + \alpha_1 Z_i + \epsilon_i .$$

## Interpretação dos Coeficientes

### Interpretação do $\beta_j$ pra $j \geq 1$

- ▶ Considere o modelo

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_p X_{pi} + \alpha_1 Z_i + \epsilon_i .$$

- ▶ Mantemos constantes todos  $X_i$  com exceção do  $X_j$ .
- ▶  $\beta_j$  representa a variação no  $Y$  quando  $X_j$  aumenta em uma unidade.
- ▶ Se  $\beta_j > 0$ ,  $Y$  aumenta.
- ▶ Se  $\beta_j < 0$ ,  $Y$  diminui.

## Suposições do Modelo

- ▶ Os erros

$$\epsilon_1, \epsilon_2, \dots, \epsilon_n$$

tem média igual a zero e variância igual a  $\sigma^2$ .

- ▶ Isso implica que

$$E(Y_i|\mathbf{X}) = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip}$$

$$\text{Var}(Y_i|\mathbf{X}) = \sigma^2 .$$

- ▶ Os erros

$$\epsilon_1, \epsilon_2, \dots, \epsilon_n$$

são não correlacionados.

- ▶ Isso implica que os  $Y_i$  são não correlacionados.
- ▶ Os erros

$$\epsilon_1, \epsilon_2, \dots, \epsilon_n$$

têm distribuição normal.

- ▶ Isso implica que os  $Y_i$  têm distribuição normal.

## Estimador de Mínimos Quadrados

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

- ▶ Propriedades:

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

## Estimador de Mínimos Quadrados

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

- ▶ Propriedades:

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

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

► A Tabela ANOVA

Fonte de Variação	Graus de Liberdade	Soma de Quadrados	Quadrado Médio
Regressão	$p$	$\hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2$	QMR=SQR/p
Resíduo	$n - p - 1$	$\mathbf{Y}'\mathbf{Y} - \hat{\beta}'\mathbf{X}'\mathbf{Y}$	QME=SQE/(n-p-1)
Total	$n - 1$	$\mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$	

Tabela : Tabela ANOVA

## Teste F da significância da Regressão

- ▶ Queremos testar as seguintes hipóteses:

$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$ , ou seja, nenhum dos  $\beta_j$  é significativo

$H_1 : \beta_j \neq 0$  para pelo menos um  $j \geq 1$ , ou seja,  $\beta_j$  é significativo

- ▶ A estatística de teste é dada por

$$F = \frac{QMR}{QME} \sim F_{p, n-p-1} \text{ sob } H_0$$

- ▶ Região crítica da forma

## Teste F da significância da Regressão

- ▶ Queremos testar as seguintes hipóteses:

$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$ , ou seja, nenhum dos  $\beta_j$  é significativo

$H_1 : \beta_j \neq 0$  para pelo menos um  $j \geq 1$ , ou seja,  $\beta_j$  é significativo

- ▶ A estatística de teste é dada por

$$F = \frac{QMR}{QME} \sim F_{p, n-p-1} \text{ sob } H_0$$

- ▶ Região crítica da forma  $F_{obs} > F$ .

**Observação:** não estamos testando o intercepto, queremos verificar quais variáveis são significativas.

## Testes $t$ individuais

- ▶ Para  $j = 1, 2, \dots, q$ , podemos testar a significância do coeficiente  $\beta_j$  na presença dos demais coeficientes no modelo:

$H_0 : \beta_j = 0$  na presença dos demais coeficientes ;

$H_1 : \beta_j \neq 0$  na presença dos demais coeficientes.

- ▶ A estatística de teste é dada por

$$t_j = \frac{\hat{\beta}_j}{\sqrt{\text{Var}(\hat{\beta}_j)}} \sim t_{n-p-1} \text{ sob } H_0 .$$

- ▶ Teste bilateral.

## Variáveis Indicadoras

- ▶ As variáveis categóricas podem também ser vistas como subgrupos dos dados.
- ▶ Nesse caso as variáveis indicadoras recebem 1 se o indivíduo pertence ao grupo e 0 caso contrário.
- ▶ Elas permitem representar vários grupos em uma única equação.
- ▶ Não precisamos escrever uma equação para cada grupo.
- ▶ As variáveis indicadoras podem ser tratadas como qualquer outra no modelo de regressão.

- ▶ Suponha que queremos comparar dois grupos:
  - ▶ grupo controle e tratamento.
- ▶ Vamos definir a variável  $Z_i$  tal que

$$Z_i = \begin{cases} 1 & \text{se o } i\text{-ésimo indivíduo pertence ao grupo tratamento} \\ 0 & \text{se o } i\text{-ésimo indivíduo pertence ao grupo controle.} \end{cases}$$

- ▶ O modelo fica

$$Y_i = \beta_0 + \beta_1 X_{1i} + \cdots + \beta_p X_{pi} + \alpha_1 Z_i + \epsilon_i$$

onde

- ▶  $Y_i$  é a variável resposta,
- ▶  $X_i$ 's são variáveis explicativas quantitativas.

- ▶ Qual parâmetro estima a diferença entre os grupos?

- ▶ Qual parâmetro estima a diferença entre os grupos?  $\alpha_1$ .
- ▶ Interpretação de  $\alpha_1$ ?
- ▶ Aumento (ou redução) esperado em  $Y$  quando passamos do grupo controle para o grupo tratamento.

## Análise de Resíduos

- ▶ O erro  $\epsilon_i$  é estimado pelo resíduo  $e_i$

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

- ▶ Representa a quantidade da varilibilidade que  $Y$  que o modelo ajustado não consegue explicar.
- ▶ Os resíduos contem informação sobre o motivo do modelo não ter se ajustado bem aos dados.
- ▶ Conseguem indicar se uma ou mais suposições do modelo foram violadas.

- ▶ Principais problemas detectados através da análise dos resíduos:
  - ▶ Não-linearidade da relação entre X e Y ;
  - ▶ Não normalidade dos erros;
  - ▶ Variância não-constante dos erros (heterocedasticidade);
  - ▶ Correlação entre os erros;
  - ▶ Presença de *outliers* ou observações atípicas;
  - ▶ O modelo foi mal especificado.

## Gráficos para análise de resíduos

## Gráficos para análise de resíduos

- ▶ Gráfico de Probabilidade Normal dos resíduos;
- ▶ Gráfico dos resíduos versus valores de  $Y$ ;
- ▶ Gráfico dos resíduos versus valores de  $X$  (incluída no modelo);
- ▶ Gráfico dos resíduos versus outras  $X$ s (não incluídas no modelo);
- ▶ Gráfico dos resíduos versus tempo ou ordem de coleta dos dados.


## Verificação de Não-Normalidade dos Erros

- ▶ Assumimos que os erros  $\epsilon_i \sim N(0, \sigma^2)$  para  $i = 1, \dots, n$ .
- ▶ Desvios da normalidade afetam:
  - ▶ os intervalos de confiança;
  - ▶ testes  $t$  e  $F$ .
- ▶ Usamos os resíduos como estimativa do erro para verificar a suposição.

- ▶ Para testar normalidade podemos usar:
  - ▶ Histograma: deve ser simétrico em torno de zero;
  - ▶ Gráfico de Probabilidade Normal: verifica visualmente se os dados seguem uma normal;
  - ▶ Testes de normalidade (Shapiro-Wilk, Anderson Darling).
    - ▶ A hipótese nula é de que os dados são normais e deverá ser rejeitada se o p-valor é pequeno.


## Gráfico dos Resíduos $e_i$ contra Valores Ajustados $\hat{Y}_i$

- ▶ Aparência desejada:
  - ▶ nuvem de pontos aleatória e homogênea em torno do eixo horizontal  $Y = 0$ .



Útil para detectar as seguintes inadequações do modelo:


- ▶ A variância do erro não é constante.
  - ▶ Solução: fazer transformação em  $Y$  ou usar Mínimos Quadrados Ponderados.



## A homocedasticidade é provavelmente violada se...

- ▶ Se os resíduos aumentam ou diminuem com os valores ajustados.
- ▶ Se os pontos formam uma curva ao redor de zero e não estão dispostos aleatoriamente.
- ▶ Poucos pontos no gráfico ficam muito distantes dos demais.

- ▶ A equação de regressão não é linear.
  - ▶ Solução: transformações em  $Y$  e/ou  $X$ ; inclusão do termo quadrático de  $X$ .



## Gráfico dos Resíduos contra a Variável Explicativa

- ▶ Na Regressão Linear Simples, tem o mesmo papel do gráfico  $e_i$  vs  $\hat{Y}_i$ .
- ▶ Em Regressão Múltipla, pode ser usado para verificar a necessidade de se incluir variáveis.
- ▶ Nesse último caso, é feito o gráfico dos resíduos vs variáveis não incluídas no modelo.
- ▶ Se houver algum padrão, significa que a variável deve ser incluída.

## Gráfico dos Resíduos contra o Tempo ou Ordem de Coleta

- ▶ Os erros devem ser independentes entre si.
- ▶ Esse gráfico verifica apenas se eles estão correlacionados no tempo.
- ▶ Só pode ser usado caso os dados sejam coletados sequencialmente.
- ▶ Os erros são plotados na ordem em que foi feita a coleta.
- ▶ A presença de algum padrão indica correlação entre eles.
- ▶ A existência de correlação temporal pode ser consequência da:
  - ▶ não inclusão de uma variável explicativa relacionada ao tempo.

## Resumindo...

- ▶ Os erros são assumidos não correlacionados e com variância constante.
- ▶ Usamos os resíduos (estimativas do erro) para verificar essas suposições.

Gráfico dos Resíduos	Suposições Avaliadas
$e_i$ vs $\hat{Y}_i$	Variância Constante
$e_i$ vs $X_i$	Linearidade
$e_i$ vs Variáveis não incluídas	Suficiência das variáveis incluídas.
Probabilidade Normal	Normalidade
$e_i$ vs tempo de coleta	Ausência se autocorrelação temporal.

## Transformações de Variáveis

- ▶ 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  $Y$ .
- ▶ 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
$Var(Y) \propto E(Y)$	$Y^* = \sqrt{Y}$
$Var(Y) \propto E(Y)(1 - E(Y))$	$Y^* = \arcsin Y$
$Var(Y) \propto E(Y)^2$	$Y^* = \ln Y$
$Var(Y) \propto E(Y)^3$	$Y^* = 1/\sqrt{Y}$
$Var(Y) \propto E(Y)^4$	$Y^* = 1/Y$

## 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:

## 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

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

## 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?

## 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? Não.
- ▶ Ao fazermos transformações nelas vamos afetar a variância?

## 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? 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.

## 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.

## Regressão Polinomial

- ▶ A relação entre a variável resposta e a explicativa é modelada por um polinômio de ordem  $p$ .
- ▶ Ajustamos um polinômio de ordem 2, 3 ou 4 e então verificamos se podemos eliminar alguns termos do modelo.
- ▶ Com polinômios podemos:
  - ▶ determinar se existe uma relação curvilínea entre  $Y$  e  $X$ ;
  - ▶ determinar se essa curva é quadrática, cúbica, etc;
  - ▶ obter a equação polinomial de  $Y$  em função de  $X$  (podemos ter várias preditoras).


## Polinômio mais simples - de segunda ordem e com uma variável explicativa

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \epsilon_i$$




Um polinômio um pouco mais complexo - de terceira ordem e com uma variável explicativa

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 + \epsilon_i$$



Um polinômio um pouco mais complexo - de quarta ordem e com uma variável explicativa

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 + \beta_4 X_i^4 + \epsilon_i$$



## Multicolinearidade

- ▶ Sabemos que, para ajustar o modelo

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

a solução de mínimos quadrados é dada por

$$\hat{\beta} =$$

## Multicolinearidade

- ▶ Sabemos que, para ajustar o modelo

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

a solução de mínimos quadrados é dada por

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

- ▶ Porém, se  $(\mathbf{X}'\mathbf{X})$  é singular:
  - ▶ o estimador não pode ser obtido dessa forma;
  - ▶ as equações normais não têm solução única.
- ▶ Isto acontece porque?

## Multicolinearidade

- ▶ Sabemos que, para ajustar o modelo

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

a solução de mínimos quadrados é dada por

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

- ▶ Porém, se  $(\mathbf{X}'\mathbf{X})$  é singular:
  - ▶ o estimador não pode ser obtido dessa forma;
  - ▶ as equações normais não têm solução única.
- ▶ Isto acontece porque?
- ▶ A colunas da matriz  $\mathbf{X}$  não são linearmente independentes.
- ▶ Uma delas é combinação linear das demais.

- ▶ Dizemos que existe multicolinearidade entre as colunas de  $X$ :
  - ▶ as variáveis explicativas são fortemente correlacionadas entre si.
- ▶ Se as variáveis são altamente correlacionadas, mas a correlação não é um:
  - ▶ uma não será exatamente combinação linear das demais.
- ▶ A matriz  $(\mathbf{X}'\mathbf{X})$  tem inversa, ou seja  $\det((\mathbf{X}'\mathbf{X})) \neq 0$ .
- ▶ Porém  $\det((\mathbf{X}'\mathbf{X})) \approx 0$ .
- ▶ Dizemos que a matriz é mal condicionada.
- ▶ A inversa

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

é muito instável.

- ▶ Alterações pequenas na matriz modificam muito sua inversa.

- ▶ Esse tipo de comportamento não é desejável em um modelo de regressão.
- ▶ Veremos como identificar o problema e algumas possíveis soluções.
- ▶ Consequências para o ajuste do modelo:
  - ▶ estimadores dos coeficientes não são confiáveis;
  - ▶ estimadores com alta variância e covariância.

## Indicações da presença de multicolinearidade:

## Indicações da presença de multicolinearidade:

- ▶ Coeficientes de correlação linear entre pares de variáveis explicativas ficam muito próximos de -1 ou 1.
- ▶ Gráficos de dispersão entre pares de variáveis explicativas apresentam configurações especiais:
  - ▶ indicando algum tipo de relação entre elas.
- ▶ Coeficientes de regressão apresentam sinais algébricos opostos ao esperado a partir de conhecimento teórico.
- ▶ Coeficientes de regressão sofrem grandes alterações quando:
  - ▶ uma coluna ou linha da matrix  $\mathbf{X}$  é extraída;
  - ▶ ou seja, quando uma variável explicativa é retirada do modelo ou uma observação é retirada da amostra.

## Indicações da presença de multicolinearidade:

## Indicações da presença de multicolinearidade:

- ▶ O teste F rejeita

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

mas nenhuma das

$$H_0 : \beta_j = 0$$

é rejeitada pelos testes  $t$  individuais.

- ▶ Variáveis explicativas que teoricamente são consideradas importantes:
  - ▶ apresentam coeficientes de regressão com estatística  $t$  muito baixa.
- ▶ Os erros padrão dos coeficientes de regressão são muito altos.

- ▶ Estes métodos de diagnósticos são informais.
- ▶ Possuem limitações importantes:
  - ▶ não fornecem uma medida do impacto da multicolinearidade;
  - ▶ não identificam a natureza da multicolinearidade.
- ▶ Diagramas de dispersão e coeficientes de correlação revelam relações entre pares de variáveis.
- ▶ Não mostram a relação entre grupos de variáveis.
- ▶ Como por exemplo, a relação entre  $X_1$  e uma combinação linear de  $X_2$ ,  $X_3$  e  $X_4$ .

- ▶ Método formal de detectar e medir multicolinearidade:
  - ▶ análise dos fatores de inflação da variância (VIF).
- ▶ Para o modelo

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + \epsilon$$

ajustado por mínimos quadrados. A matriz de Covariâncias dos estimadores dos coeficientes é dada por

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

- ▶ Método formal de detectar e medir multicolinearidade:
  - ▶ análise dos fatores de inflação da variância (VIF).
- ▶ Para o modelo

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + \epsilon$$

ajustado por mínimos quadrados. A matriz de Covariâncias dos estimadores dos coeficientes é dada por

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

os elementos da diagonal são iguais a

$$\text{Var}(\hat{\beta}_k) = \text{VIF}_k \left( \frac{\sigma^2}{S_k} \right) \quad \text{com} \quad S_k = \sum_{i=1}^n (X_{ki} - \bar{X}_k)^2$$

- ▶ Se  $X_k$  não está relacionada às outras variáveis  $X$ , tem-se  $\text{VIF}_k = 1$ .

- ▶ Podemos tomar algumas medidas para corrigir o problema de multicolinearidade.
- ▶ Coletar mais dados planejados para “quebrar” a relação entre as variáveis nos dados existentes.
- ▶ Considere que  $X_1$  e  $X_2$  são positivamente correlacionadas.
- ▶ Devemos coletar novos pares de observações  $(X_1, X_2)$  tais que:
  - ▶ sejam coletados valores baixos de  $X_1$  e altos de  $X_2$ , e vice-versa.
- ▶ Isso pode ser uma característica intrínseca das variáveis.
- ▶ Por exemplo, as variáveis sócio-econômicas renda da família e tamanho da casa.

- ▶ Podemos ainda redefinir as variáveis preditoras.
- ▶ Por exemplo, se  $X_1$ ,  $X_2$  e  $X_3$  são aproximadamente dependentes.
- ▶ É possível encontrar alguma função delas,

$$X = \frac{(X_1 + X_2)}{X_3} \quad X = X_1 X_2 X_3$$

que preserve a relação das preditoras, mas elimine a multicolinearidade.

- ▶ Uma outra solução é eliminar variáveis explicativas.
- ▶ Essa não é uma solução satisfatória,
  - ▶ pois as preditoras podem ter grande poder de explicação da resposta;
  - ▶ podemos estar descartando informação importante.

## Observações Atípicas

- ▶ **Outliers:** não se ajustam bem ao modelo (resíduo grande);
  - ▶ **Alavancas:** têm valor não usual da variável explicativa;
  - ▶ **Influente:** quando presentes, mudam o ajuste do modelo substancialmente.
- 
- ▶ Nem todo outlier é influente.
  - ▶ Assim como nem toda alavanca é influente.
  - ▶ Mas um ponto influente é um outlier e/ou uma alavanca.
  - ▶ Os resíduos exercem importante papel na análise de observações não usuais.

## A matriz H

- ▶ Lembre que no modelo de regressão

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

o estimador de mínimos quadrados é dado por

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

- ▶ Os valores estimados para  $\mathbf{Y}$  são dados por

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

- ▶ A matriz

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

é chamada de matriz **hat** (chapéu), pois liga  $\mathbf{Y}$  a  $\hat{\mathbf{Y}}$

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

## Outlier

## Outlier

- ▶ Observação com valor discrepante de  $Y$ .
- ▶ É um ponto que não se ajusta bem ao modelo.
- ▶ O valor ajustado  $\hat{Y}_i$  é muito distante de  $Y_i$ .
- ▶ O resíduo  $e_i$  é grande.
- ▶ Podem afetar o ajuste do modelo.

- ▶ Nem todo ponto que possui um valor alto de  $e_j$  é um *outlier*.
- ▶ Como identificar pontos que são de fato *outliers*?

- ▶ Nem todo ponto que possui um valor alto de  $e_i$  é um *outlier*.
- ▶ Como identificar pontos que são de fato *outliers*?
- ▶ Valores extremos de  $t_i$  na distribuição  $t_{n-p}$  indicam que a  $i$ -ésima observação é um *outlier*.
- ▶ Um *outlier* só deve ser excluído se um erro é identificado.
- ▶ Caso isso ocorra deve-se destacar essa exclusão nas conclusões finais do trabalho.

There should be strong non-statistical evidence before we discard any of the outliers. Otherwise, it can be dangerous as “deleting a desirable response” may give the user a false sense of precision in estimation or prediction.

## Observações alavanca

## Observações alavanca

- ▶ Observações extremas em  $X$ .
- ▶ Observações tais que o valor de  $X$  está muito afastado dos demais.
- ▶ Elas não necessariamente afetam a reta de regressão.
- ▶ Como detectamos esses pontos?

## Observações alavanca

- ▶ Observações extremas em  $X$ .
- ▶ Observações tais que o valor de  $X$  está muito afastado dos demais.
- ▶ Elas não necessariamente afetam a reta de regressão.
- ▶ Como detectamos esses pontos?

- ▶ A matriz  $\mathbf{H}$  depende apenas dos valores  $\mathbf{X}$ .
- ▶ Então  $h_{ij}$  é alto por causa de um valor atípico de  $X$  e não de  $Y$ .
- ▶ Já vimos que

$$\sum_{i=1}^n h_{ij} = p$$

onde  $p$  é a dimensão do vetor de coeficientes  $\beta$ .

- ▶ Se nenhum ponto “força” o ajuste, devemos ter
  - ▶ todos  $h_{ij}$  aproximadamente iguais, nenhum “puxa” mais;

$$h_{ij} \approx \frac{p}{n}.$$

- ▶ Uma regra empírica é olhar com mais atenção pontos tais que

$$h_{ij} > \frac{2p}{n}.$$

## Ponto Influyente

## Ponto Influyente

- ▶ É aquele cuja remoção do banco de dados causa grande mudança no ajuste.
- ▶ Pode ou não ser um *outlier*.
- ▶ Pode ou não ser uma *alavanca*.
- ▶ Tende a ter pelo menos um dessas duas propriedades.
- ▶ A medida mais usada para detectar pontos influentes é

## Ponto Influyente

- ▶ É aquele cuja remoção do banco de dados causa grande mudança no ajuste.
- ▶ Pode ou não ser um *outlier*.
- ▶ Pode ou não ser uma *alavanca*.
- ▶ Tende a ter pelo menos um dessas duas propriedades.
- ▶ A medida mais usada para detectar pontos influentes é a **Distância de Cook**.

- ▶ Vejamos como é definida a **Distância de Cook**.
- ▶ Sejam  $\hat{\beta}$  e  $\hat{Y}$  os estimadores de  $\beta$  e  $Y$ .
- ▶ Esses estimadores são calculados usando as  $n$  observações.
- ▶ Retiramos a  $i$ -ésima observação do banco de dados.
- ▶ Recalculamos os estimadores.
- ▶ Vamos denotá-los por  $\hat{\beta}_i$  e  $\hat{Y}_i$ .

- ▶ A Distância de Cook mensura:
  - ▶ o quanto muda as estimativas dos coeficientes de regressão com a retirada da observação  $i$

$$\hat{\beta}_{(i)} - \beta_{(i)} .$$

- ▶ A distância Cook da  $i$ -ésima observação é dada por:

$$D_i = \frac{(\hat{\mathbf{Y}} - \hat{\mathbf{Y}}_{(i)})'(\hat{\mathbf{Y}} - \hat{\mathbf{Y}}_{(i)})}{p\hat{\sigma}^2} = \frac{r_i h_{ii}}{p(1 - h_{ii})}$$

onde

- ▶  $\hat{\sigma}^2$  é a estimativa de  $\sigma^2$  (baseada no modelo com as  $n$  observações);
- ▶  $p$  é a dimensão do vetor  $\beta$ ;
- ▶  $r_i$  é o resíduo padronizado;
- ▶  $h_{ii}$  é a alavanca.

- ▶ Um valor alto de  $D_i$  (em relação às demais)
  - ▶ indica que a observação  $i$  é influente, os valores estimados com e sem a observação são bem próximos.
- ▶ A influência pode ser consequência de:
  - ▶ um valor extremo do resíduo padronizado (o ponto é *outlier*);
  - ▶ um valor alto (próximo de 1) de  $h_{ii}$  (o ponto é uma alavanca).

## Métodos de Seleção de Variáveis

- ▶ Devemos incluir no modelo todas as variáveis explicativas disponíveis?
- ▶ Ou devemos escolher apenas um subconjunto delas?
- ▶ Podemos usar procedimentos automáticos para auxiliar na escolha desse subconjunto.
- ▶ Alguns métodos que podem ser usados:

## Métodos de Seleção de Variáveis

- ▶ Devemos incluir no modelo todas as variáveis explicativas disponíveis?
- ▶ Ou devemos escolher apenas um subconjunto delas?
- ▶ Podemos usar procedimentos automáticos para auxiliar na escolha desse subconjunto.
- ▶ Alguns métodos que podem ser usados:
  - ▶ Todas as Regressões Possíveis (*All Regressions*)
  - ▶ Inclusão Passo a Frente (*Forward*)
  - ▶ Eliminação Passo Atrás (*Backward*)
  - ▶ Seleção Passo-a-Passo (*Stepwise*)

## Critérios de Seleção da melhor Regressão

- ▶ Modelo “cheio”: modelo com todas variáveis explicativas disponíveis.
- ▶ Precisamos escolher uma variável a ser descartada.
- ▶ Podemos escolher com base em alguma das medidas:
  - ▶ menor valor de  $S^2$  (estimativa de  $\sigma^2$ );
  - ▶ maior valor de  $R^2_{ajustado}$

$$R^2_{ajustado} = 1 - (1 - R^2) \left( \frac{n-1}{n-p} \right);$$

- ▶ Estatística  $C_p$  de Mallows

$$C_p = \frac{SQE}{S^2} - (n - 2p)$$

quanto mais próxima essa estatística estiver de  $p$ , melhor é o modelo.

## Todas as Regressões Possíveis (*All Regressions*)

## Todas as Regressões Possíveis (*All Regressions*)

- ▶ Testa de maneira iterativa todos os subconjuntos possíveis de variáveis explicativas.
- ▶ Se temos  $k$  variáveis, qual o número total de subconjuntos possíveis?

## Todas as Regressões Possíveis (*All Regressions*)

- ▶ Testa de maneira iterativa todos os subconjuntos possíveis de variáveis explicativas.
- ▶ Se temos  $k$  variáveis, qual o número total de subconjuntos possíveis?

## Todas as Regressões Possíveis (*All Regressions*)

- ▶ Testa de maneira iterativa todos os subconjuntos possíveis de variáveis explicativas.
- ▶ Se temos  $k$  variáveis, qual o número total de subconjuntos possíveis?

$2^k - 1$  pois não contamos o modelo se nenhuma variável.

- ▶ Por exemplo, se  $k = 10$ , temos  $2^{10} - 1 = 1023$  possibilidades.
- ▶ Escolhemos algum dos modelos com base nos critérios.
- ▶ Se o número de variáveis é grande, o método é computacionalmente inviável.

## Inclusão Passo a Frente (Forward)

## Inclusão Passo a Frente (Forward)

- ▶ Começamos com o modelo só com intercepto.
- ▶ Vamos incluindo as variáveis mais significativas.
- ▶ O algoritmo para quando uma variável não significativa é encontrada.
- ▶ Uma vez que a variável entra no modelo, ela não sai mais.
- ▶ Mesmo que sua contribuição deixe de ser significativa quando uma outra variável entrar.

## Eliminação Passo Atrás (*Backward*)

## Eliminação Passo Atrás (*Backward*)

- ▶ Começamos com o modelo com todas variáveis.
- ▶ Vamos excluindo as variáveis menos significativas.
- ▶ Quando encontramos uma variável significativa o algoritmo para.
- ▶ Uma vez que a variável sai no modelo, ela não entra mais.
- ▶ Mesmo que sua contribuição passe a ser significativa quando uma outra variável entrar.

## Seleção Passo a Passo (*Stepwise*)

## Seleção Passo a Passo (*Stepwise*)

- ▶ É uma mistura de *Forward* e *Backward*.
- ▶ A variável que entra em um passo pode sair nos próximos.
- ▶ A variável que sai em um passo pode entrar nos próximos.

## Etapas para Análise de Regressão

- ▶ Inicie o procedimento realizando uma análise exploratória dos dados;
- ▶ Ajuste o modelo e realize um teste sobre a validade do mesmo;
- ▶ Caso necessário, faça uma transformação na variável resposta ( $y$ ) para estabilizar a variância;
- ▶ Faça uma análise dos resíduos para justificar a aleatoriedade e normalidade dos mesmos e para detectar possíveis outliers;
- ▶ Caso seja identificado algum outlier, procure por evidências que justifiquem a ocorrência do mesmo antes que seja retirado das observações.