

Modelos de Regressão Múltipla - Parte VII

Erica Castilho Rodrigues

26 de Janeiro de 2016

Regressão Polinomial

Multicolinearidade

Regressão Polinomial

- ▶ Vimos como ajustar um modelo não linear fazendo transformações das variáveis, como, por exemplo


$$Y = \exp\{\beta_0 + \beta_1 x + \epsilon\} .$$

- ▶ Existem casos em que a relação entre as variáveis é polinomial.
- ▶ Por exemplo, parábolas aparecem frequentemente em problemas de engenharia.
- ▶ Polinômios podem ajustar uma grande variedade de curvas.

- ▶ 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

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



- ▶ Começamos primeiro com uma reta, ou polinômio de grau um.
- ▶ Vamos incluindo graus maiores e testando a significância.
- ▶ Para fazer essa inclusão, basta acrescentar na matriz \mathbf{X} , uma coluna com os valores de X^2 ou X^3 .
- ▶ Quando chegamos em um grau que não é mais significativo interrompemos o processo.
- ▶ Todos os termos de grau menor são incluídos no modelo.
- ▶ Por exemplo, se X^3 é significativo:
 - ▶ vamos incluir X e X^2 no modelo.

- ▶ Não devemos colocar muito termos no modelo.
- ▶ Se tivermos n observações:
 - ▶ um polinômio de grau $n - 1$ se ajusta perfeitamente aos dados.
- ▶ Esse modelo é bom?

- ▶ Não devemos colocar muito termos no modelo.
- ▶ Se tivermos n observações:
 - ▶ um polinômio de grau $n - 1$ se ajusta perfeitamente aos dados.
- ▶ Esse modelo é bom?
- ▶ Esse modelo não é bom, pois está ajustando ruído, variação aleatória.
- ▶ O grau do polinômio não deve ser maior do que $1/3$ do número de observações.
- ▶ Se temos uma amostra de tamanho 12:
 - ▶ não devemos ajustar um polinômio de grau maior que 4.

- ▶ Todas suposições do modelo de regressão simples devem valer para o modelo polinomial:


- ▶ Todas suposições do modelo de regressão simples devem valer para o modelo polinomial:

- ▶ Todas suposições do modelo de regressão simples devem valer para o modelo polinomial:
 - ▶ normalidade,

- ▶ Todas suposições do modelo de regressão simples devem valer para o modelo polinomial:
 - ▶ normalidade, independência e

- ▶ Todas suposições do modelo de regressão simples devem valer para o modelo polinomial:
 - ▶ normalidade, independência e variância constante dos erros.
- ▶ Os polinômios não podem ser usados para fazer previsões fora do intervalo dos dados.
- ▶ Pontos de inflexão:
 - ▶ permitem que a relação mude o sentido, de crescente, vire decrescente.
- ▶ A cada grau que aumentamos do polinômio, permitimos que essa mudança ocorra mais uma vez.

- ▶ Extrapolações são inúteis a não ser que estejamos ajustando uma parábola:
 - ▶ a curva não tem uma tendência bem comportada fora do intervalo dos dados.



- ▶ Se aumentarmos o grau do polinômio ele pode representar qualquer curva.
- ▶ Porém, devemos usar apenas se não pudermos encontrar nenhuma função mais simples.
- ▶ Se uma função exponencial se ajusta bem aos dados, devemos usá-la ao invés do polinômio.
- ▶ Os parâmetros da exponencial tem interpretação direta.
- ▶ Qual interpretação do termo β_2 em

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \epsilon ?$$


- ▶ Se aumentarmos o grau do polinômio ele pode representar qualquer curva.
- ▶ Porém, devemos usar apenas se não pudermos encontrar nenhuma função mais simples.
- ▶ Se uma função exponencial se ajusta bem aos dados, devemos usá-la ao invés do polinômio.
- ▶ Os parâmetros da exponencial tem interpretação direta.
- ▶ Qual interpretação do termo β_2 em

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \epsilon ?$$

- ▶ Não tem interpretação.
- ▶ Portanto, só devemos usar polinômios se não encontramos nenhuma função mais simples.

Exemplo:

- ▶ Estamos analisando a produção de milho em uma fazenda.
- ▶ Queremos verificar como ela varia com a quantidade de chuva.



Exemplo: (continuação)

- ▶ A relação entre as variáveis parece linear?

Exemplo: (continuação)

- ▶ A relação entre as variáveis parece linear? Não.
- ▶ Qual tipo de curva parece se ajustar bem nesse caso?

Exemplo: (continuação)

- ▶ A relação entre as variáveis parece linear? Não.
- ▶ Qual tipo de curva parece se ajustar bem nesse caso? Uma parábola.
- ▶ Vamos então ajustar um polinômio de grau 2.

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \epsilon_i \quad \epsilon_i \sim^{iid} N(0, \sigma^2).$$

- ▶ Comandos em R para ajustar o modelo

```
results = lm(Yield ~ Rain + I(Rain^2))  
summary(results)
```

Exemplo: (continuação)

- ▶ Os resultados obtidos através do ajuste do modelo são mostrados a seguir.

Call:

```
lm(formula = Yield ~ Rain + I(Rain^2))
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) -5.01467 11.44158 -0.438 0.66387
Rain 6.00428 2.03895 2.945 0.00571 **
I(Rain^2) -0.22936 0.08864 -2.588 0.01397 *
```

Residual standard error: 3.763 on 35 degrees of freedom

Multiple R-squared: 0.2967,

Adjusted R-squared: 0.2565

F-statistic: 7.382 on 2 and 35 DF,

p-value: 0.002115

Exemplo: (continuação)

- ▶ Quais as conclusões podemos tirar?

Exemplo: (continuação)

- ▶ Quais as conclusões podemos tirar?
- ▶ A quantidade de chuva é significativa para explicar a produção de milho.

Exemplo: (continuação)

- ▶ Quais as conclusões podemos tirar?
- ▶ A quantidade de chuva é significativa para explicar a produção de milho.
- ▶ O termo quadrático é significativo.
- ▶ O modelo ajustado é dado por

$$\hat{Y} =$$

Exemplo: (continuação)

- ▶ Quais as conclusões podemos tirar?
- ▶ A quantidade de chuva é significativa para explicar a produção de milho.
- ▶ O termo quadrático é significativo.
- ▶ O modelo ajustado é dado por


$$\hat{Y} = -5.01 + 6X - 0.23X^2.$$

- ▶ Podemos usar os seguintes comandos para plotar a curva sobre o grafo de dispersão

```
plot(Rain, Yield)
x = seq(6, 17, by=0.1)
lines(x, beta[1]+beta[2]*x +
      beta[3]*x^2, col='red')
```

Exemplo: (continuação)

- ▶ A figura ao lado mostra o gráfico com a curva.
- ▶ O modelo quadrático parece representar bem a relação entre as variáveis.
- ▶ Não parece necessário testar polinômios de ordem mais alta.



- ▶ Podemos usar regressão polinomial quando temos mais de uma variável explicativa.
- ▶ Por exemplo, considere o caso em que temos duas variáveis.
- ▶ Além dos termos, quadráticos, cúbicos, etc, podemos incluir interação.
- ▶ Um modelo possível seria

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{1i}^2 + \beta_3 X_{2i} + \beta_4 X_{2i}^2 + \beta_5 X_{1i} X_{2i} + \epsilon_i$$

- ▶ Qual figura geométrica essa equação representa?

- ▶ Podemos usar regressão polinomial quando temos mais de uma variável explicativa.
- ▶ Por exemplo, considere o caso em que temos duas variáveis.
- ▶ Além dos termos, quadráticos, cúbicos, etc, podemos incluir interação.
- ▶ Um modelo possível seria

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{1i}^2 + \beta_3 X_{2i} + \beta_4 X_{2i}^2 + \beta_5 X_{1i} X_{2i} + \epsilon_i$$

- ▶ Qual figura geométrica essa equação representa? Uma superfície.
- ▶ De acordo com os valores dos parâmetros a superfície assume formatos distintos.

- ▶ Considere o caso em que temos

$$\beta_2 > 0 \quad \beta_4 > 0$$

- ▶ Duas dimensões convexas.
- ▶ Considere ainda que

$$\beta_5 = 0$$

- ▶ Isso significa que


- ▶ Considere o caso em que temos

$$\beta_2 > 0 \quad \beta_4 > 0$$

- ▶ Duas dimensões convexas.
- ▶ Considere ainda que

$$\beta_5 = 0$$

- ▶ Isso significa que não há interação.
- ▶ A relação entre X_1 e Y não muda com os valores de X_2 .



- ▶ Considere o caso em que temos

$$\beta_2 > 0 \quad \beta_4 > 0$$

- ▶ Duas dimensões convexas.
- ▶ Considere ainda que

$$\beta_5 \neq 0$$

- ▶ Isso significa que


- ▶ Considere o caso em que temos

$$\beta_2 > 0 \quad \beta_4 > 0$$

- ▶ Duas dimensões convexas.
- ▶ Considere ainda que

$$\beta_5 \neq 0$$

- ▶ Isso significa que há interação.
- ▶ A relação entre X_1 e Y muda com os valores de X_2 .



- ▶ Considere o caso em que temos

$$\beta_2 > 0 \quad \beta_4 < 0$$

- ▶ Uma dimensão é côncava e outra convexa.
- ▶ Considere ainda que

$$\beta_5 \neq 0$$

- ▶ Isso significa que


- ▶ Considere o caso em que temos

$$\beta_2 > 0 \quad \beta_4 < 0$$

- ▶ Uma dimensão é côncava e outra convexa.
- ▶ Considere ainda que

$$\beta_5 \neq 0$$

- ▶ Isso significa que há interação.
- ▶ A relação entre X_1 e Y muda com os valores de X_2 .



Multicolinearidade

- ▶ Sabemos que, para ajustar o modelo

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

a solução de mínimos quadrados é dada por

$$\hat{\beta} =$$

- ▶ 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:

- ▶ 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?

- ▶ 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.

- ▶ Observe que as colunas de $\mathbf{X}'\mathbf{X}$ são combinações lineares das colunas de \mathbf{X} .
- ▶ Se as colunas de \mathbf{X} são linearmente dependentes,
 - ▶ combinações lineares dessas colunas também serão.
- ▶ Portanto as colunas de $\mathbf{X}'\mathbf{X}$ não serão linearmente independentes e a matriz não tem inversa.

- ▶ Dizemos que existe multicolinearidade entre as colunas de \mathbf{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.

Exemplo

- ▶ Estamos interessados em ajustar um modelo para o seguinte conjunto de dados

X	4	4	7	7	7.1	7.1
Y	19	20	37	39	36	38



Exemplo (continuação)

- ▶ Podemos tentar um modelo quadrático

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \epsilon.$$

- ▶ Obtemos as equações normais a seguir

$$\mathbf{X}'\mathbf{X}\hat{\beta} = \mathbf{X}'\mathbf{Y}$$

$$\begin{bmatrix} 6 & 36.2 & 230.82 \\ 36.2 & 230.82 & 1529.82 \\ 230.82 & 1529.82 & 10396.3362 \end{bmatrix} \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} 189 \\ 1213.4 \\ 8078.34 \end{bmatrix}$$

- ▶ Essa matriz é aproximadamente singular.

Exemplo (continuação)

- ▶ A reta estimada e os erros padrões dos estimadores são mostrados a seguir

$$\hat{Y} = -151 + 63.5X - 5.2X^2$$

$$EP(\hat{\beta}_0) = 113 \quad EP(\hat{\beta}_1) = 44 \quad EP(\hat{\beta}_2) = 4.0$$

- ▶ Os erros padrões são muito altos.
- ▶ Os valores estimados dos coeficientes não têm precisão.
- ▶ O modelo não é útil.
- ▶ Isso ocorre pois X e X^2 são altamente correlacionadas.
- ▶ Se ajustarmos um modelo de X^2 em função de X obtemos

$$X^2 = -28.217 + 11.053X \quad R^2 = 99.99\% .$$

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:

- ▶ 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 $\text{VIF}_k = 1$.

- ▶ Portanto

$$VIF_k = \text{Var}(\hat{\beta}_k) \left(\frac{S_k}{\sigma^2} \right)$$

- ▶ VIF_k é chamado fator de inflação de variância de β_k .
- ▶ Mede quanto a $\frac{\sigma^2}{S_k}$ é inflacionada pela:
 - ▶ relação da variável X_k com as demais.
- ▶ Se o VIF_k aumenta, $\text{Var}(\hat{\beta}_k)$ aumenta.
- ▶ O VIF também pode ser calculado como o elemento da diagonal da matriz \mathbf{C}^{-1} ;
 - ▶ onde \mathbf{C} é a matriz de correlações das variáveis explicativas.
- ▶ Pode-se mostrar ainda que

$$VIF_k = \frac{1}{(1 - R_k^2)}$$

onde R_k^2 é coeficiente de determinação da regressão de X_k (variável resposta) em função das outras variáveis explicativas.

Exemplo:

- ▶ Foi feito um estudo para avaliar a quantidade de gordura corporal (Y).
- ▶ Foram selecionadas as seguintes variáveis explicativas:
 - ▶ X_1 - medida de espessura da dobra do tríceps;
 - ▶ X_2 - circunferência da coxa;
 - ▶ X_3 - circunferência do antebraço.
- ▶ Os dados de 20 mulheres de 25 a 24 anos foram coletados.

Exemplo:

- ▶ Observou-se que:
 - ▶ X_1 e X_2 são altamente correlacionadas.
 - ▶ As estimativas e os erros padrão dos β 's mudam muito de um modelo para o outro.
 - ▶ Estimativas negativas dos β 's, contrariando o esperado.
 - ▶ No modelo com as três predictoras, o teste F é significativo (a 5%), mas todos os testes t individuais são não-significantes.
- ▶ Todos esses são indícios de multicolinearidade.
- ▶ Os valores dos VIF's são apresentados a seguir

$$VIF_1 = 708.84 \quad VIF_2 = 564.34 \quad VIF_3 = 104.61$$

- ▶ Valores altos indicam presença de multicolinearidade.

- ▶ 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.

- ▶ Uma outra possibilidade é usar métodos alternativos de estimação.
- ▶ Um dos procedimentos possíveis é a *Ridge Regression*.
- ▶ Consiste em somar uma matriz diagonal à matriz $\mathbf{X}'\mathbf{X}$.
- ▶ A estimativa dos coeficientes fica

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

onde $\kappa \geq 0$ é uma constante especificada pelo analista.