

## Exemplos de Aplicação

## Case: *Air Pollution in US Cities*



### Exemplo



- Estudo de poluição do ar em 41 cidades dos EUA
  - ✓ Ano: 1970
- Dados: *Usairpollution{MVA}*

### Variáveis:



- ✓ SO2: conteúdo de dióxido de enxofre no ar, em  $\mu\text{g}/\text{m}^3$ .
- ✓ Temp: temperatura média anual ( $^{\circ}\text{F}$ )
- ✓ Indust: quantidade de empresas manufatureiras empregando pelo menos 20 empregados.
- ✓ Pop: população (censo 1970), em milhares.
- ✓ Vento: velocidade média anual de vento, em milhas/h
- ✓ Precip: precipitação média anual, em polegadas
- ✓ Dias: número médio anual de dias com precipitação

## Ajf Variáveis

- ✓ ‘Resposta’: SO2
- ✓ Ambientais: Vento, Precip, Dias, Temp
- ✓ Demográficas: Indust, Pop



Análise Multivariada - 2020

167



## ✓ Matriz de correlações:

```
> # Descrição do conjunto de dados
>
> poluicao.corr <- cor(poluicao[,-1])
> poluicao.corr
      Indust       Pop      Vento     Precip      Dias    negtemp
Indust  1.0000000  0.95526935  0.23794683 -0.03241688  0.13182930  0.19004216
Pop   0.95526935  1.00000000  0.21264375 -0.02611873  0.04208319  0.06267813
Vento  0.23794683  0.21264375  1.00000000 -0.01299438  0.16410559  0.34973963
Precip -0.03241688 -0.02611873 -0.01299438  1.00000000  0.49609671 -0.38625342
Dias   0.13182930  0.04208319  0.16410559  0.49609671  1.00000000  0.43024212
negtemp 0.19004216  0.06267813  0.34973963 -0.38625342  0.43024212  1.00000000
```



## ✓ Comentário:

- Valores altos de correlação entre Indust e Pop

Análise Multivariada - 2020

169

## Ajf Comandos em R:

### ✓ Carregamento dos dados:

```
> library(MVA)
> library(HSAUR2, AlgOfTest) # carrega os pacotes
> data(USairpollution) # carrega o banco de dados
> poluicao <- USairpollution
> colunas<- c("SO2", "Temp", "Indust", "Pop",
+ "Vento", "Precip", "Dias")
> colnames(poluicao)<- colunas
>
> poluicao$negtemp <- poluicao$Temp * (-1)
> poluicao$Temp <- NULL
```



Análise Multivariada - 2020

168

### ✓ Comentários:

- Extrair componentes da matriz de correlações:
  - Variáveis estão em escalas muito distintas
- Ignora a variável SO2 (considera só as ‘explicativas’)
- Uso da temperatura negativa
  - As 6 variáveis têm valores altos, de maneira que representam um ambiente menos atrativo







## ✓ Matrix plot:

### – Comandos em R:

```
> panel.hist <- function(x, ...){
+ usr <- par("usr"); on.exit(par(usr))
+ par(usr = c(usr[1:2], 0, 1.5) )
+ h <- hist(x, plot = FALSE)
+ breaks <- h$breaks; nB <- length(breaks)
+ y <- h$counts; y <- y/max(y)
+ rect(breaks[-nB], 0, breaks[-1], y, col = "grey", ...)
+ }
>
> pairs(poluicao[,-1], pch = ".", cex = 1.5)
> pairs(poluicao[,-1], diag.panel = panel.hist, pch = ".", cex = 1.5)
```

Análise Multivariada - 2020

170




## Questão Interessante

- Quais dentre as variáveis climáticas e ambientais são as melhores preditoras do grau de poluição do ar (concentração de SO<sub>2</sub>)?
  - Esta questão é tratada com regressão linear múltipla
  - Potencial problema para aplicação dessa técnica:
    - Alta correlação entre Indust e Pop
  - Solução:
    - Retirar uma das variáveis
  - Alternativa:
    - Fazer regressão dos níveis de SO<sub>2</sub> com as componentes principais derivadas das 6 variáveis originais
    - Pode ser melhor regredir com todas as 6 componentes

Análise Multivariada - 2020

175

## ✓ SO<sub>2</sub> dependendo das componentes principais



Análise Multivariada - 2020

176



## ✓ Regressão com as 6 componentes principais:

```
> poluicao$reg <- lm(SO2 ~ poluicao.acpscores,
+ data = poluicao)
> summary(poluicao$reg)

Call:
lm(formula = SO2 ~ poluicao.acpscores, data = poluicao)

Residuals:
    Min      1Q  Median      3Q     Max 
-23.004 -8.542 -0.991  5.758 48.758 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 30.049    2.286 13.146 6.91e-15 ***
poluicao.acpscoresComp.1 -9.942    1.542 -6.446 2.28e-07 ***
poluicao.acpscoresComp.2  2.240    1.866  1.200 0.23845  
poluicao.acpscoresComp.3  0.375    1.935  0.194 0.84752  
poluicao.acpscoresComp.4  6.549    2.622  3.261 0.00253 *** 
poluicao.acpscoresComp.5 -15.176   6.753 -2.247 0.03122 *  
poluicao.acpscoresComp.6 -39.271   12.316 -3.189 0.00306 ** 
...
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 14.64 on 34 degrees of freedom
Multiple R-squared:  0.6695, Adjusted R-squared:  0.6112 
F-statistic: 11.48 on 6 and 34 DF,  p-value: 5.419e-07
```

- Escores da 1<sup>a</sup>. componente predizem mais a resposta
- Componentes com menor variância não têm necessariamente as menores correlações com a resposta

Análise Multivariada - 2020



## Fonte

- EVERITT, B.; HOTHORN, T. *An Introduction to Applied Multivariate Analysis with R*. Springer, 2011.

✓ Sec. 3.10.3: Air pollution in US cities, pg. 86.

Análise Multivariada - 2020

179