



## Autocorrelação

1

## Quem sou?



- Licenciado em matemática pelo IME-USP;
- Iniciação Científica sob orientação da Profª Drª Mônica Carneiro Sandoval;
- *Transformação de Box-Cox*;
- Mestre em estatística sob a orientação da Profª Drª Mônica Carneiro Sandoval e co-orientação da Profª Denise Aparecida Botter;
- *Incorporação do plano amostral na análise de regressão*;
- Atualmente, doutorando em estatística... sob a orientação do Profº Drº Heleneo Boffarinho e Co-orientação da Profª Drª Mônica Carneiro Sandoval;
- *Calibração linear em modelos com assimetria*;
- Interesse:
  - Análise de Regressão,
  - Inferência Bayesiana e
  - Calibração Linear.

2

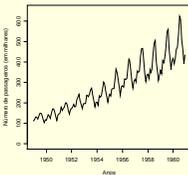
## Programa de Aperfeiçoamento de Ensino

Supervisora: Profª Clélia Maria de Castro Toloi

3

## Alguns exemplos do R - Passageiros

□ Figura 1. Totais mensais de passageiros em linhas aéreas internacionais nos EUA entre 1949 e 1960.



□ Existe uma clara tendência de crescimento bem como um padrão sazonal ao longo dos anos.

4

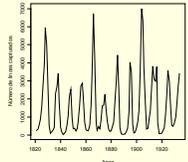
## Comandos

- `> data(AirPassengers)`
- `#` para obter informações sobre os dados `#`
- `> help(AirPassengers)`
  
- `> x = AirPassengers`
- `#` testa se um objeto é uma série temporal `#`
- `> is.ts(x)`
  
- `> plot(x,xlab='Anos',ylim=c(0,650),ylab='Número de passageiros (em milhares)')`

5

## Número de Lincas

□ Figura 2. Número anual de lincas capturados em armadilhas entre 1821 e 1934 no Canadá.



□ Observe o padrão um padrão cíclico em torno de 10 ou 11 anos.

6

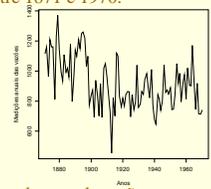
### Comandos

- ❑ > data(lynx)
- ❑ # para obter informações sobre os dados #
- ❑ > help(lynx)
  
- ❑ > lincex = lynx
- ❑ # testa se o objeto é uma série temporal #
- ❑ > is.ts(lincex)
  
- ❑ > plot(lincex,xlab='Anos', ylab='Número de lincex capturados')

7

### Vazões do Rio Nilo

- ❑ Figura 3. Medições anuais de vazões do Rio Nilo em Ashwan entre 1871 e 1970.



- ❑ Parece haver alguma alteração estrutural em torno do ano de 1900.

8

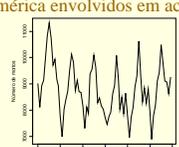
### Comandos

- ❑ > data(Nile)
- ❑ # para obter informações sobre os dados #
- ❑ > help(Nile)
  
- ❑ > Nile = Nile
- ❑ # testa se o objeto é uma série temporal #
- ❑ > is.ts(Nile)
  
- ❑ > plot(Nile,xlab='Anos', ylab='Medições Anuais das vazões')

9

### Total mensal de mortos em acidentes

- ❑ Figura 4. Mostra o total mensal de mortos nos Estados Unidos da América envolvidos em acidentes.



- ❑ Parece que o número de mortos é maior durante os verões e esse padrão é observado ano a ano. Além disso, o número de mortos não parece aumentar, mantendo-se estacionário.

10

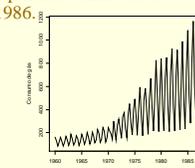
### Comandos

- ❑ > data(USAccDeaths)
- ❑ # para obter informações sobre os dados #
- ❑ > help(USAccDeaths)
  
- ❑ > mortes = USAccDeaths
- ❑ # testa se o objeto é uma série temporal #
- ❑ > is.ts(mortes)
  
- ❑ > plot(mortes,xlab='Anos', ylab='Número de mortos')

11

### Gás no Reino Unido

- ❑ Figura 5. Série trimestral do consumo de gás no Reino Unido entre o primeiro trimestre de 1960 e o quarto trimestre de 1980.



- ❑ Há uma tendência de crescimento porém a amplitude do padrão sazonal aumenta bastante a partir de 1971.

12

### Comandos

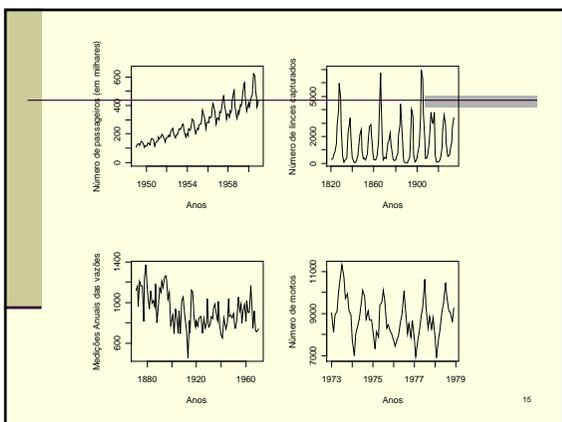
- ❑ > data(UKgas)
- ❑ # para obter informações sobre os dados #
- ❑ > help(UKgas)
  
- ❑ > gas = UKgas
- ❑ # testa se o objeto é uma série temporal #
- ❑ > is.ts(gas)
  
- ❑ > plot(gas,xlab='Tempo (em quadrimestres)', ylab='Consumo de gás')

13

### Colocando quatro deles lado a lado.

- ❑ > par(mfrow=c(2,2))
- ❑ > plot(x,xlab='Anos',ylim=c(0,650),ylab='Número de passageiros (em milhares)')
- ❑ > plot(linces,xlab='Anos', ylab='Número de linces capturados')
- ❑ > plot(Nilo,xlab='Anos', ylab='Medições Anuais das vazões')
- ❑ > plot(mortes,xlab='Anos', ylab='Número de mortos')

14



### Autocorrelação

- ❑ *Coefficientes de Autocorrelação:* Ferramenta para se identificar as propriedades de uma série temporal.
- ❑ *Coefficiente de correlação linear...*



$$r = \frac{S_{XY}}{S_X S_Y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

$(x_1, y_1), (x_2, y_2), (x_3, y_3), (x_4, y_4), (x_5, y_5), (x_6, y_6) \dots$

16

### Idéia de autocorrelação

- ❑ Queremos medir a correlação entre as observações de uma mesma variável em diferentes momentos de tempo.
- ❑ Seria ótimo se conseguíssemos entender a relação entre observações defasadas 1, 2, ..., períodos de tempo.

17

### $r_1$

- ❑ Será que há correlação entre uma e outra observação?

18

**r<sub>2</sub>**

❑ E entre a observação e a segunda vizinha?

19

**r<sub>3</sub>**

❑ E com a terceira vizinha?...

20

**A idéia é criar novos pares de variáveis!**

- ❑ Em r<sub>1</sub> os pares são (x<sub>1</sub>, x<sub>2</sub>), (x<sub>2</sub>, x<sub>3</sub>), ...
- ❑ Em r<sub>2</sub> os pares são (x<sub>1</sub>, x<sub>3</sub>), (x<sub>2</sub>, x<sub>4</sub>), ...
- ❑ Em r<sub>3</sub> os pares são (x<sub>1</sub>, x<sub>4</sub>), (x<sub>2</sub>, x<sub>5</sub>), ...

❑ E calcular as correlações dos novos pares de variáveis.

21

**O coeficiente pode ser simplificado!**

❑ Considerando x<sub>1</sub>, ..., x<sub>n-1</sub> e x<sub>2</sub>, ..., x<sub>n</sub> como duas variáveis o coeficiente de correlação entre x<sub>t</sub> e x<sub>t+1</sub>, por exemplo, é dado por:

$$r_1 = \frac{\sum_{t=1}^{n-1} (x_t - \bar{x}_1)(x_{t+1} - \bar{x}_2)}{\sqrt{\sum_{t=1}^{n-1} (x_t - \bar{x}_1)^2 \sum_{t=1}^{n-1} (x_{t+1} - \bar{x}_2)^2}}$$

22

**Mais simplificações!**

❑ Onde as médias amostrais são

$$\bar{x}_1 = \sum_{t=1}^{n-1} x_t / (n-1) \quad \text{e} \quad \bar{x}_2 = \sum_{t=2}^n x_t / (n-1).$$

❑ Se utilizarmos a média amostral total  $\bar{x}$  e considerarmos que as duas médias acima são aproximadamente as mesmas.

23

❑ A versão simplificada do coeficiente de correlação fica:

$$r_1 = \frac{\sum_{t=1}^{n-1} (x_t - \bar{x})(x_{t+1} - \bar{x})}{(n-1) \sum_{t=1}^n (x_t - \bar{x})^2 / n}$$

❑ Além disso, podemos excluir o fator n/(n-1) já que está próximo de 1 e temos um estimador bem mais simples!

24

### Um estimador da autocorrelação

- ❑ A expressão anterior pode ser generalizada para calcular a correlação entre observações defasadas em k períodos de tempo.

$$r_k = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2}$$

25

### Observações

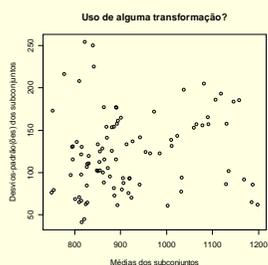
- ❑ Assim como o coeficiente de correlação usual, as autocorrelações são adimensionais e  $-1 < r_k < 1$ .
- ❑ Na prática é mais usual calcular primeiro os coeficientes de autocovariância  $\{c_k\}$ , definidos por analogia com a fórmula usual de covariância

$$c_k = \sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})/n.$$

- ❑ Os coeficientes de autocorrelação são então obtidos como  $r_k = c_k/c_0$ .

26

### Estudo da série de vazões do Nilo



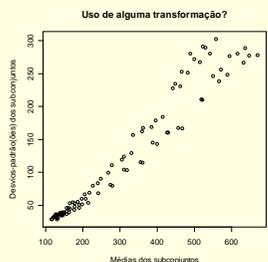
27

### Verificação da necessidade do uso de alguma transformação

- ❑ `j<-floor(n/20) # para garantir L = 20 #`
- ❑ `abscissa<- NULL`
- ❑ `ordenada<- NULL`
- ❑ `for (i in 1:(n-j)){`
- ❑ `abscissa[i]<-mean(Nilo[i:(i+j)])`
- ❑ `ordenada[i]<-sd(Nilo[i:(i+j)])`
- ❑ `}`
- ❑ `plot(x=abscissa,y=ordenada, xlab='Médias dos subconjuntos', ylab='Desvios-padrão(ões) dos subconjuntos', main='Uso de alguma transformação?')`

28

### Gás no Reino Unido – Log<sub>e</sub>?



29

### Estudo das autocorrelações

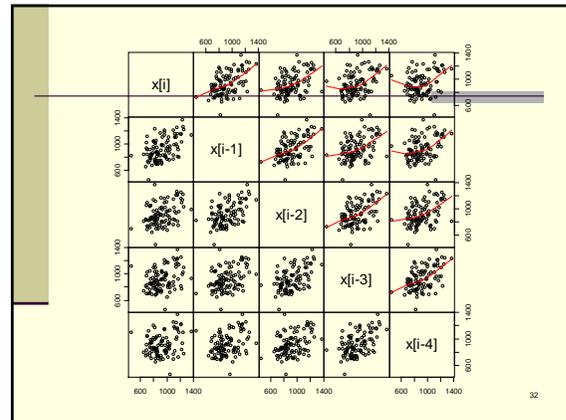
- ❑ Como exemplo do cálculo das autocorrelações vamos utilizar os dados das medições das vazões do Nilo disponível no R.
- ❑ Vamos montar uma matriz de correlogramas de valores defasados de 1, 2, 3 e 4 períodos.

30

### Comandos

- ❑ Nile <- Nile
- ❑ n <- length(Nilo)
- ❑ k <- 5
- ❑ m = NULL
- ❑ for (i in 1:k) m=cbind(m,lag(Nilo,k=i-1))
- ❑ m=as.data.frame(m)
- ❑ colnames(m) <- c("Nilo[i]", "Nilo[i-1]", "Nilo[i-2]", "Nilo[i-3]", "Nilo[i-4]")
- ❑ pairs(m, gap = 0, upper.panel = panel.smooth)

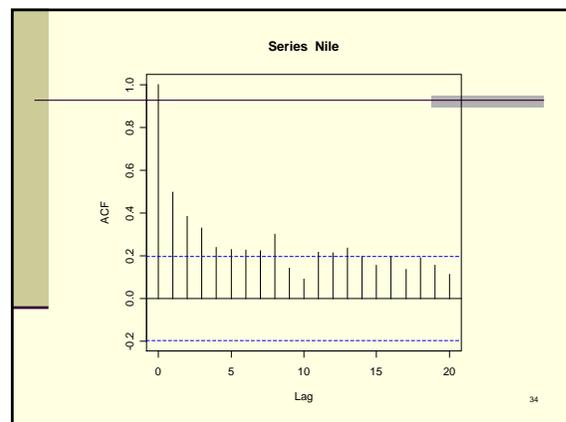
31



### A função de autocorrelação - acf

- ❑ Para calcularmos todas as possíveis autocorrelações existe uma função chamada acf.
- ❑ No exemplo anterior, se tivéssemos digitado o comando:
- ❑ acf( Nile )
- ❑ Teríamos o correlograma de toda a série.

33



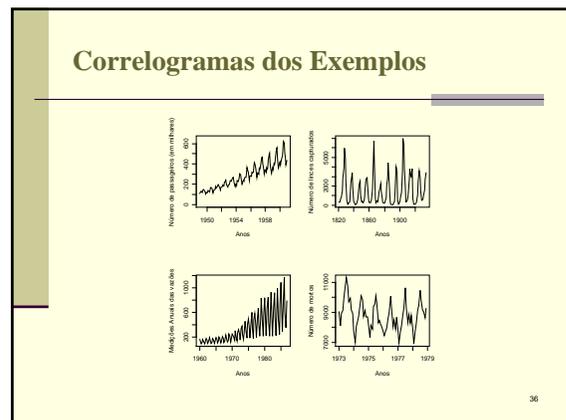
### Limites de confiança

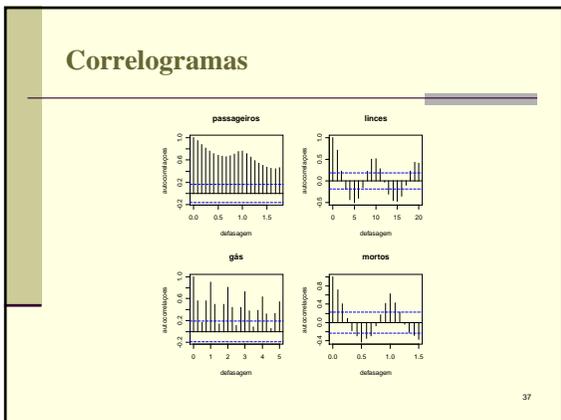
- ❑ Numa série aleatória esperamos que os valores defasados sejam não correlacionados e espera-se que  $r_k = 0$ .
- ❑ Podemos mostrar que  $r_k$  tem distribuição assintótica

$$r_k \sim N(-1/n ; 1/n).$$

- ❑ Assim, os limites de confiança aproximados de 95% são dados por  $-1/n \pm 1, 96/\sqrt{n}$ , que são frequentemente ainda mais aproximados para  $\pm 1, 96/\sqrt{n}$ .

35





### Comandos

```

par(mfrow=c(2,2))
plot(x,xlab='Anos',ylim=c(0,650),ylab='Número de passageiros (em milhares)')
plot(lincas,xlab='Anos', ylab='Número de lincas capturados')
plot(gas,xlab='Anos', ylab='Medições Anuais das vazões')
plot(mortes,xlab='Anos', ylab='Número de mortos')

par(mfrow=c(2,2))
acf(x, main='passageiros',xlab='defasagem',ylab='autocorrelações')
acf(lincas, main='lincas',xlab='defasagem',ylab='autocorrelações')
acf(gas, main='gás',xlab='defasagem',ylab='autocorrelações')
acf(mortes, main='mortos',xlab='defasagem',ylab='autocorrelações')

```

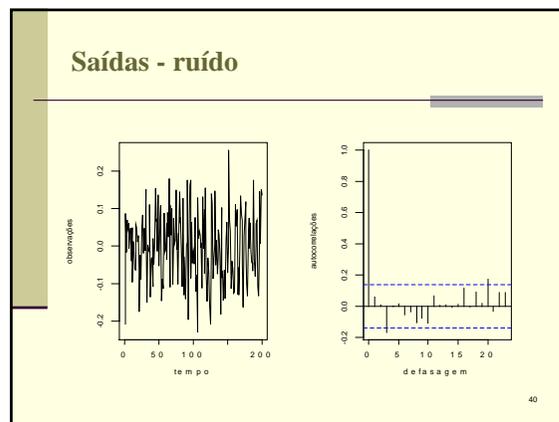
### Gerando séries temporais artificiais

1. Série aleatória, observações iid da distribuição  $N(0,1)$

```

x = rnorm(200,0,0.1)
par(mfrow=c(1,2))
plot.ts(x,xlab='tempo',ylab='observações')
acf(x,main='',xlab='defasagem',ylab='autocorrelações')

```



### Gerando séries temporais artificiais

2. Série com tendência,

$$x_t = x_{t-1} + N(0,0.01)$$

```

e = rnorm(100,0,0.1)
x = cumsum(e)
par(mfrow=c(1,2))
plot.ts(x,xlab='tempo',ylab='observações')
acf(x,main='',xlab='defasagem',ylab='autocorrelações')

```



### A função diff(...)

É interessante notar que a primeira diferença de um passeio aleatório é estacionária!

```
z<-diff(x)
par(mfrow=c(1,2))
plot.ts(z,xlab='tempo',ylab='observações')
acf(z,main='',xlab='defasagem',ylab='autocorrelações')
```

43

### Agora é estacionária!

44

### Vamos usar diff(...) - Passageiros

45

```
z<-diff(x,lag=12)
par(mfrow=c(1,2))
plot.ts(z,xlab='tempo',ylab='observações')
acf(z,main='',xlab='defasagem',ylab='autocorrelações')
```

46

### Gerando séries temporais artificiais

3. Série com correlação de curto-prazo

$$x_t = 0,7x_{t-1} + e_t$$

```
Curto<-arima.sim(n = 400, list(ar = 0.7))
par(mfrow=c(1,2))
plot.ts(Curto,xlab='tempo',ylab='observações')
acf(Curto,main='',xlab='defasagem',ylab='autocorrelações')
```

47

### Saída – memória de curto prazo

48

## Gerando séries temporais artificiais

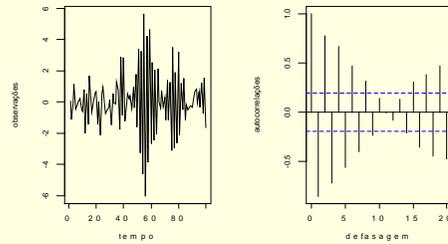
### 4. Série com correlação negativa

$$x_t = -0,8x_{t-1} + e_t$$

```
negativo<-arima.sim(n = 100, list(ar = -0.8))  
par(mfrow=c(1,2))  
plot.ts(negativo,xlab='tempo',ylab='observações')  
acf(negativo,main='',xlab='defasagem',ylab='autocorrelações')
```

49

## Saída – correlações negativas



50

This document was created with Win2PDF available at <http://www.daneprairie.com>.  
The unregistered version of Win2PDF is for evaluation or non-commercial use only.