





Uma Introdução à Análise de Séries Temporais com R

Dr. Everaldo Freitas Guedes

Salvador, 20 de novembro de 2019



Referências



Objetivos

- ✓ Introduzir os conceitos da análise de séries temporais;
- ✓ Apresentar de modelos clássicos de predição de séries temporais;
- ✓ Utilizar do software R para o ajuste e simulação de alguns modelos de séries temporais.

1. Introdução

1.1 O que é análise de séries temporais?

A análise de séries temporais é um ramo da ciência estatística dedicada ao tratamento analítico de uma série de instâncias ou observações dependentes.

1. Introdução

1.2 Noções

Uma série temporal é definida como qualquer conjunto de observações ordenadas no tempo. Entretanto, pode ser substituída por uma outra, a exemplo de espaço e profundidade.

Matematicamente, uma série temporal é definida pelos valores Y_1, \dots, Y_N de uma variável Y , nos tempos t_1, \dots, t_N .
Portanto, Y é uma função simbolizada $Y = f(t)$.

1. Introdução

1.3 Classificação

- ✓ **Discreta**: quando T (conjunto de índices) é um conjunto finito de pontos, $t = 1, 2, \dots, n$.
- ✓ **Contínua**: quando T é um intervalo finito $T = [t: t_1 < t < t_2]$. Por exemplo, o registro da maré no Porto de Salvador durante 1 ano $T = [0, 23]$ se a unidade de tempo é a hora.

1. Introdução

1.3 Classificação

- ✓ **Determinística:** quando uma função matemática pode ser utilizada para estabelecer exatamente os valores futuros da série.
- ✓ **Estocástica:** quando os valores futuros da série somente podem ser estabelecidos em termos probabilísticos, pois o modelo compõe-se também de um termo aleatório.

1. Introdução

1.4 Aplicações de séries temporais

Economia -> preços diários de ações; taxa mensal de desemprego.

Medicina -> eletrocardiograma, eletroencefalograma.


Epidemiologia -> número mensal de novos casos de dengue.

Meteorologia -> precipitação pluviométrica.

Climatologia -> humidade relativa do ar, temperatura.

1. Introdução


Exemplos:



Bahia: Evolução mensal das exportações e importações (Jan/1989 a Dez/2013).
Fonte: MDIC. Nota: Elaborado pelo autor.

1. Introdução



Exemplos:



**Índice de Fechamento do Dow Jones.
Nota: Elaborado pelo autor.**

1. Introdução


Exemplos:



**Retorno dos mercados Dow Jones e Nasdaq.
Nota: Elaborado pelo autor.**

1. Introdução

Exemplos:



Sinais Mioelétricos do movimento de abrir e fechar a mão.
Nota: Elaborado pelo autor.

1. Introdução

1.5 Objetivos

- ✓ Em linhas gerais, pode-se dizer que o objetivo global do estudo de séries temporais é sumarizar as propriedades da série e caracterizar seu comportamento, identificando ou sugerindo um modelo adequado.

1. Introdução

1.5 Objetivos

- ✓ **Explicação**: usar a variação de uma série para explicar a variação de outra série.
- ✓ **Predição**: prever valores futuros com base em valores passados. Esta poderá ser de curto prazo (1 a 3 meses), médio prazo (3 a 24 meses) ou longo prazo (acima de 24 meses).

1. Introdução

1.5 Objetivos

- ✓ **Controle de processos:** controle estatístico de qualidade. Controlar a qualidade de uma série temporal é importante por permitir ajustar o modelo à série de dados, possibilitando tomar medidas corretivas nas séries para evitar que a qualidade se afaste de um nível estabelecido.
- ✓ **Descrição:** propriedades da série, a exemplo de tendência, sazonalidade, *outliers*, alterações estruturais e etc.

1. Introdução

1.6 Componentes

- ✓ Os movimentos característicos das séries de tempo podem ser classificados em três tipos principais, frequentemente denominados componentes.

$$Y_t = T_t + S_t + A_t \text{ ou } Y_t = T_t * S_t * A_t$$


1. Introdução

1.6 Componentes

- ✓ **Tendência**: Representa a componente macro de uma série; é a indicadora da direção global dos dados (ou o movimento geral da variável). Esse movimento pode ser de crescimento/decréscimo linear ou não-linear.


1. Introdução

Exemplo:



1. Introdução

Exemplo:




1. Introdução

1.6 Componentes

- ✓ **Sazonal**: Representa padrões idênticos, ou quase, que uma série temporal parece obedecer durante uma determinada época do ano. Esse movimento refere-se aos ciclos de curto prazo em torno da tendência.
- ✓ Ex.: Refere-se a eventos ligados às estações do ano, vinculados ao calendário e repetidos a cada doze meses, relacionado às causas climáticas, ciclos vegetativos, usos e costumes, festas sociais e religiosas.

1. Introdução

Exemplo:




1. Introdução

1.6 Componentes

- ✓ **Aleatória**: Refere-se aos deslocamentos esporádicos das séries temporais, provocados por eventos casuais. A importância dessa componente vincula-se ao poder de alterar tanto a direção da tendência quanto a amplitude dos ciclos existentes.

1. Introdução

Exemplo:



1. Introdução

1.6 Componentes

- ✓ A análise de séries temporais consiste em uma modelagem dessas componentes. Nesse sentido, a maneira clássica de decomposição baseia-se nos seguintes modelos:

1. Introdução

Exercício 1

- 1) Realizar a estimação da tendência através das técnicas de regressão linear simples e de média móvel das seguintes séries:
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

1. Introdução

1.7 Decomposição de séries temporais

Muitas das propriedades observadas em uma série temporal Y_t podem ser captadas assumindo-se as seguintes formas de decomposição:

$$Y_t = T_t + S_t + A_t \text{ ou } Y_t = T_t * S_t * A_t$$

Tipos:

- ✓ Clássica;
- ✓ STL (Seasonal Trend Decomposition Loess)

1. Introdução

Exercício 2

1) Realizar a decomposição clássica das seguintes séries:

- a) AirPassengers
- b) co2
- c) Nile
- d) nottem
- e) ausbeer #library(fpp)
- f) visitors #library(fpp)
- g) JohnsonJohnson

O que é possível concluir?

Processos estocásticos

2. Processos estocásticos

2.1 Conceitos básicos



Definições:

“é uma família de variáveis aleatórias representando a evolução de um sistema de valores com o tempo”.

“é o conjunto de todas as possíveis trajetórias de um fenômeno ou uma coleção de realizações do processo físico”.

2. Processos estocásticos

Ilustração:



2. Processos estocásticos

2.1 Conceitos básicos

Usualmente, descreve-se um processo estocástico através de suas funções média, autocovariância e variância.

$$E[Y(t)] = \mu_t$$

$$\gamma_{(t_1,t_2)} = E[(Y(t_1) - \mu_{t_1})][(Y(t_2) - \mu_{t_2})]$$

$$\sigma^2 = E[Y^2(t) - \mu_{t^2}]$$

2. Processos estocásticos

2.2 Estacionários

- ✓ Quando é invariante no tempo (estrita ou fraca).
- ✓ Um P.E. é estritamente estacionário se a média e a variância forem constantes ao longo do tempo.
- ✓ Um P.E. será considerado fracamente estacionário se e somente se

$$E\{X(t)\} = \mu(t) = \mu, \text{ constante, para todo } t \in T;$$

$$E\{X^2(t)\} < \infty, \text{ para todo } t \in T;$$

$$\gamma(t_1, t_2) = \text{Cov}X(t_1), X(t_2) \text{ é uma função de } |t_1 - t_2|.$$

2. Processos estocásticos

2.2 Estacionários

- ✓ Quando é invariante no tempo. (estrita ou fraca)
- ✓ Um P.E. é estritamente estacionário se as distribuições unidimensionais são invariantes no tempo, ou seja, se a média e a variância forem constantes.
- ✓ Um P.E. será considerado fracamente estacionário se e somente se

$$E\{X(t)\} = \mu(t) = \mu, \text{ constante, para todo } t \in T;$$

$$E\{X^2(t)\} < \infty, \text{ para todo } t \in T;$$

$$\gamma(t_1, t_2) = \text{Cov}X(t_1), X(t_2) \text{ é uma função de } |t_1 - t_2|.$$


2. Processos estocásticos

2.2 Estacionários

Obs.: uma série poderá ser estacionaria durante períodos longos ou apenas em períodos breves, mudando de nível e/ou de inclinação.

2. Processos estocásticos

Ilustração:



2. Processos estocásticos

2.2 Estacionários

Obs.: Caso não seja, poderá se transformar em estacionária ao ser diferenciada em uma quantidade n finita de vezes.

$$\Delta X(t) = X(t) - X(t - 1),$$

$$\Delta^2 X(t) = \Delta[\Delta X(t)] = \Delta[X(t) - X(t - 1)],$$

$$\Delta^n X(t) = \Delta[\Delta^{n-1} X(t)].$$

2. Processos estocásticos

2.2 Estacionários

Obs.: No máximo duas diferenças são suficientes para tornar a série temporal estacionária. No entanto, quando as diferenças não são suficientes para alcançar tal suposição, costuma-se aplicar antes das diferenças, uma transformação não linear nos dados, como por exemplo, a transformação logarítmica.

2. Processos estocásticos

Exercício 3

- 1) Realizar a 1ª e 2ª diferença das séries abaixo e plotar as séries originais:
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

2. Processos estocásticos

2.3 Função de autocorrelação

A FAC quantifica a interdependência de uma série temporal.

$$\rho(\hat{k}) = \frac{\gamma(\hat{k})}{\gamma(\hat{0})} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y}_t)(Y_{(t+k)} - \bar{Y}_t)}{\sum_{t=1}^n (Y_t - \bar{Y}_t)^2}$$

$\gamma(\hat{k})$ é a covariância na defasagem $k(k = 0, 1, 2, \dots)$; $\gamma(\hat{0})$ é a variância amostral,

2. Processos estocásticos

2.3 Função de autocorrelação

Como a covariância e a variância apresentam as mesmas unidades de medida, os valores de $\rho_{(k)}$ são adimensionais e variam entre -1 a 1, de modo que:

$0 < \hat{\rho}_{(k)} \leq 1$ a série possui autocorrelação positiva;


$\hat{\rho}_{(k)} = 0$ não existe autocorrelação na série; e,

$-1 \leq \hat{\rho}_{(k)} < 0$ a série possui autocorrelação negativa;


2. Processos estocásticos

Ilustração:

Series Nile



Series ausbeer



2. Processos estocásticos

2.3 Função de autocorrelação

A partir do correlograma é possível caracterizar uma série temporal em:

- a. Estacionária
- b. Não estacionária;
- c. Periódica;
- d. Ruído branco;

2. Processos estocásticos

Exercício 4

- 1) Realizar a 1ª e 2ª diferença das séries abaixo. Plotar as séries originais e as funções de autocorrelação.
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

O que é possível concluir?

2. Processos estocásticos

2.5 Tipos

um processo estocástico ε_t é especificado como **ruído branco** ou sequência aleatória se

$$E[\varepsilon_t] = 0, \text{ constante, para todo } t \in T;$$

$$\text{Var}[\varepsilon_t] = \sigma_\varepsilon^2, \text{ para todo } t \in T;$$


$$\gamma(\varepsilon_{t_1}, \varepsilon_{t_2}) = \text{Cov}[\varepsilon_{t_1}, \varepsilon_{t_2}] = 0, \text{ para todo } t_1 \neq t_2.$$

Obs.: o RB é homogêneo, estacionário e sem dependência temporal. Além disso, possui distribuição normal com média zero, variância e covariâncias nulas.


2. Processos estocásticos

Ilustração:

(a) white Noise (N=500)



(b) white Noise (N=1000)



2. Processos estocásticos

2.5 Tipos

Um processo estocástico é dito **passeio aleatório** se a primeira diferença deste resulta em um RB.

$$E[Y_t] = \sum_{j=1}^t E[\varepsilon_j] = t\mu;$$

$$\text{Var}[Y_t] = \sum_{j=1}^t \text{Var}[\varepsilon_j] = t\sigma_\varepsilon^2;$$


$$\text{Cov}(Y_t, Y_{t-k}) = \text{Cov}[\varepsilon_1 + \cdots + \varepsilon_{t-k} + \cdots + \varepsilon_t, \varepsilon_1 + \cdots + \varepsilon_{t-k}] = (t-k)\sigma_\varepsilon^2$$

Obs.: Apresenta tendência e, portanto, não é estacionário.


2. Processos estocásticos

Ilustração:

(a) Passeio Aleatório (N=500)



(b) Passeio Aleatório (N=1000)



2. Processos estocásticos

2.5 Tipos

Ruído Rosa é um processo estocástico intermediário entre o ruído branco e passeio aleatório.


Obs.: A família de processos aleatórios estatisticamente auto-semelhantes $1/f$.

Dica: <https://label2.tecnico.ulisboa.pt/vilela/Cursos/Beyond.pdf>


2. Processos estocásticos

Ilustração:

(a) Ruído Rosa (N=500)



(b) Ruído Rosa (N=1000)



2. Processos estocásticos

Exercício 5

- 1) Simular os processos estocásticos RB, PA e RR com os tamanhos 250, 500, 750, 1000.
- 2) Analisar a função de autocorrelação das séries simuladas. O que é possível concluir?

2. Processos estocásticos

2.5 Tipos

Um processo **AR** (p) é uma representação de um tipo de processo aleatório específica que a variável de saída depende linearmente de seus próprios valores anteriores e de um termo estocástico.

$$\phi(B)X_t = c + \varepsilon_t$$

em que, $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ representa o operador autorregressivo de ordem p .

2. Processos estocásticos

2.5 Tipos


Características:

- ✓ A fac teórica de um processo autorregressivo decai segundo exponenciais e/ou senóides amortecidas;
- ✓ As autocorrelações parciais ($facp$) nos primeiros lags são estatisticamente diferentes de zero;
- ✓ O processo AR, geralmente, não é estacionário;


2. Processos estocásticos

Ilustração:

AR = 0.8, n = 500



AR = 0.8, n = 1000



2. Processos estocásticos

Exercício 6

- 1) Simular os processos estocásticos AR com os tamanhos 250, 500, 750, 1000.
- 2) Analisar as funções de autocorrelação e autocorrelação parcial das séries simuladas. As séries são estacionárias?

2. Processos estocásticos

2.5 Tipos

Um processo **MA** (q) é um tipo de processo aleatório que especifica que a variável de saída depende linearmente de seus próprios valores anteriores e atuais mais um termo estocástico.

$$X_t = \mu + \theta(B)\varepsilon_t$$

em que, $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ representa o operador de médias móveis de ordem q .

2. Processos estocásticos

2.5 Tipos: MA


Características:

- ✓ O processo MA é estacionário;


2. Processos estocásticos

Ilustração:

AR = 0.8, n = 500



AR = 0.8, n = 1000



2. Processos estocásticos

Exercício 7

- 1) Simular os processos estocásticos MA com os tamanhos 250, 500, 750, 1000.
- 2) Analisar as funções de autocorrelação e autocorrelação parcial das séries simuladas. As séries são estacionárias?

2. Processos estocásticos

2.5 Tipos

Um processo **ARMA** (p, q) é um processo misto.

$$\phi(B)X_t = c + \theta(B)\varepsilon_t$$


em que,

- $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é o operador autorregressivo de ordem p ;
- $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ é o operador de médias móveis de ordem q .


2. Processos estocásticos

Ilustração:

(a) ARMA(2,2) N = 500



(b) ARMA(2,2) N = 1000



2. Processos estocásticos

Exercício 8

- 1) Simular os processos estocásticos ARMA com os tamanhos 250, 500, 750, 1000.
- 2) Analisar as funções de autocorrelação e autocorrelação parcial das séries simuladas. As séries são estacionárias?

2. Processos estocásticos

2.5 Tipos

Um processo **ARIMA** (p, d, q) é um processo misto.

$$\phi(B)[(1 - B)^d X_t - \mu] = c + \theta(B)\varepsilon_t$$


em que,

- $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é o operador autorregressivo de ordem p ;
- μ é a média da série com d diferenças;
- $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ é o operador de médias móveis de ordem q .


2. Processos estocásticos

Ilustração:

ARIMA (2,1,2), n = 500



ARIMA (2,1,2), n = 1000



2. Processos estocásticos

2.5 Tipos


Um processo *SARIMA* $(p, d, q)x(P, D, Q)$ é um processo ARIMA misto com parte sazonal.

$$\phi(B) \cdot \Phi_p(B^s) \left[(1-B)^d (1-B)_s^D - \mu \right] X_t = \theta(B) \cdot \Theta_Q(B^s) \cdot \zeta_t$$


2. Processos estocásticos

Ilustração:

ARIMA (2,1,2), n = 500



ARIMA (2,1,2), n = 1000



2. Processos estocásticos

Exercício 9

- 1) Simular os processos estocásticos ARIMA com os tamanhos 250, 500, 750, 1000.
- 2) Analisar as funções de autocorrelação e autocorrelação parcial das séries simuladas. As séries são estacionárias?
- 3) Repetir as simulações acima para os processos SARIMA.

Análise exploratória de Séries Temporais

3. Análise exploratória

3.1 – Imputação de valores ausentes

O objetivo aqui é preencher valores ausentes na série pela média ou pela mediana.

```
###código  
library(imputeTS)  
x <- ts(c(1, 2, 3, 4, 5, 6, 7, 8, NA, NA, 11, 12))  
na.mean(x)  
na.mean(x, option="median")
```

1. Introdução

Exercício 10

- 1) Na pasta “exercício 10”. Preencher, se possível, os valores da séries.

3. Análise exploratória

3.2 – Estatísticas descritivas

O objetivo aqui é caracterizar as séries temporais.

- Mínimo, máximo, amplitude;
- Média, variância, desvio padrão, coeficientes de variação, de assimetria e de curtose;
- Gráficos (boxplot, histograma);

1. Introdução

Exercício 11

- 1) Determinar e analisar as estatísticas descritivas das séries abaixo. Interprete.
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

3. Análise exploratória

3.3 – Verificar a hipótese de normalidade

- Teste Jarque-bera;
- Teste Shapiro-Wilk;

3. Análise exploratória

3.3.1 – Teste JB

O teste JB utiliza os coeficientes de assimetria e curtose para formar a seguintes estatística:

$$JB = n. \left[\frac{S^2}{6} + \frac{(K - 3)^2}{24} \right] \sim \chi_{(2)}^2$$

H_0 : X_t é normal

H_1 : X_t não é normal

3. Análise exploratória

3.3.1 – Teste SW

O teste SW é o mais utilizado na identificação de normalidade. Tal teste baseia-se na estatística W denotada por

$$W = \frac{(\sum_{i=1}^n a_i y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

sendo a_1, a_2, \dots, a_n constantes calculadas como a solução da equação

$H_0: X_t$ é normal

$H_1: X_t$ não é normal

1. Introdução

Exercício 12

- 1) Verificar se as séries abaixo são possuem distribuição normal.
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

3. Análise exploratória

3.4 – Verificar a hipótese de estacionariedade

- ✓ Teste Dickey-Fuller;
- ✓ Teste Dickey-Fuller Aumentado;

3. Análise exploratória

3.3.1 – Teste de Dickey-Fuller

O teste DF baseia-se numa regressão entre os valores de uma série temporal X_t e sua medição em um período imediatamente anterior $X_{(t-1)}$, ou seja, um modelo do tipo [AR(1)] representado por

$$\Delta X_t = \phi X_{t-1} + \varepsilon_t \quad \varepsilon_t \sim RB(0, \sigma_\varepsilon^2)$$

3. Análise exploratória

3.3.1 – Teste Dickey-Fuller

As hipóteses são:

i) $\Delta X_t = \pi X_{t-1} + \varepsilon_t$

Sem constante (α), sem tendência (α_t)

ii) $\Delta X_t = \alpha + \pi X_{t-1} + \varepsilon_t$

Com constante (α), sem tendência (α_t)

iii) $\Delta X_t = \alpha + \alpha_t + \pi X_{t-1} + \varepsilon_t$

Com constante (α) e tendência (α_t)

H_0 : X_t não é estacionária

H_1 : X_t é estacionária

3. Análise exploratória

3.3.2 – Teste Dickey-Fuller Aumentado

O teste ADF introduz um operador de defasagens no teste DF, para resolver o problema da autocorrelação serial tal como:

$$\Delta X_t = \phi X_{t-1} + \varepsilon_t$$

$$\Delta X_t = \alpha X_{(t-1)} + \sum_{k=1}^{\infty} \beta_k \Delta X_{(t-k)} + \varepsilon_t$$

$$\varepsilon_t \sim RB(0, \sigma_\varepsilon^2)$$

3. Análise exploratória

3.3.2 – Teste Dickey-Fuller Aumentado

As hipóteses são:

i) $\Delta X_t = \pi X_{(t-1)} + \sum_{k=1}^n \beta_k \Delta X_{(t-k)} + \varepsilon_t$
Sem constante (α), sem tendência (α_t)

ii) $\Delta X_t = \alpha + \pi X_{(t-1)} + \sum_{k=1}^n \beta_k \Delta X_{(t-k)} + \varepsilon_t$
Com constante (α), sem tendência (α_t)

iii) $\Delta X_t = \alpha + \alpha_t + \pi X_{(t-1)} + \sum_{k=1}^n \beta_k \Delta X_{(t-k)} + \varepsilon_t$
Com constante (α) e tendência (α_t)

H_0 : X_t não é estacionária

H_1 : X_t é estacionária

1. Introdução

Exercício 13

- 1) Executar o teste ADF nas séries listadas abaixo. O que é possível concluir?
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

1. Introdução

Exercício 13

2) Executar o teste ADF na duas primeiras diferenças das séries abaixo. O que é possível concluir?

- a) AirPassengers
- b) co2
- c) Nile
- d) nottem
- e) ausbeer #library(fpp)
- f) visitors #library(fpp)
- g) JohnsonJohnson

3. Análise exploratória

3.3.3 – Teste para memória

✓ Método DFA;

3. Análise exploratória

3.3.3 – DFA



O método DFA é um método computacional de análise de escala utilizado para estimar expoentes que caracterizam o decaimento lento da função de autocorrelação e possibilita a identificação de auto-afinidade em séries temporais não estacionárias.

3. Análise exploratória

Passos do DFA:


1º – Obter a série integrada $y(k)$

$$y(k) = \sum_{i=1}^n (X_i - \langle X \rangle),$$



3. Análise exploratória

2º – A série integrada $y_{(k)}$ é dividida em intervalos (*box*) de tamanhos iguais n , que não se interceptam. Em seguida, ajusta-se um polinômio de grau ≥ 1 a $y_{(k)}$ para cada *box* de tamanho n . O polinômio é do tipo $(y_n(k) = a + bx)$.



3. Análise exploratória

3º – A série integrada $y_{(k)}$ é subtraída de $y_n(k)$ em cada intervalo de tamanho n . Assim, é calculada a raiz quadrática média $F_{(n)}$ para cada amplitude de tamanho n , isto é,


$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]^2},$$

Nota: O cálculo descrito anteriormente deve ser repetido sistematicamente para diferentes *boxes* de tamanho n ($4 \leq n \leq n/4$).

3. Análise exploratória

3º – Por último, determina-se o comportamento de escala da flutuação $F_{(n)}$ através da relação linear entre $\log F_{(n)}$ em função de $\log(n)$.

$$F_{(n)} \sim n^\alpha$$



3. Análise exploratória

Tabela 1.3: Tipos de comportamento considerados na análise do DFA

DFA	Tipos de comportamentos
$\alpha_{DFA} < 0,5$	Antipersistente
$\alpha_{DFA} \simeq 0,5$	Não correlacionado (Ruído Branco)
$\alpha_{DFA} > 0,5$	Persistente
$\alpha_{DFA} \simeq 1,0$	Ruído $1/f$
$\alpha_{DFA} > 1,0$	Não estacionário (Passeio Aleatório)
$\alpha_{DFA} \simeq 1,5$	Ruído Browniano

3. Análise exploratória

Exercício 14

- 1) Testar a memória das séries abaixo. O que é possível concluir?
 - a) AirPassengers
 - b) co2
 - c) Nile
 - d) nottem
 - e) ausbeer #library(fpp)
 - f) visitors #library(fpp)
 - g) JohnsonJohnson

3. Análise exploratória

Exercício 14

- 2) Simule séries do tipo RB, RR, PA, AR, MA, ARMA, ARIMA com tamanho 1000. Para cada série simulada pede-se
 - a. Plote a função de autocorrelação.
 - b. Aplique o DFA e classifique as séries com base no α .

Métodos Preditivos

4. Métodos Preditivos

O que é previsão?

Etimologicamente (*prae e videre*), a palavra [previsão](#) sugere que se quer ver uma coisa antes que ela exista.

Alguns autores sugerem a palavra [predição](#), para indicar algo que deverá existir no futuro. Outros autores, preferem o termo [projeção](#).

Obs.: Salienta-se que a projeção é apenas um meio de fornecer informações para uma tomada de decisão.

4. Métodos Preditivos

Abordagens

- ✓ Econométrico
- ✓ De Séries Temporais

4. Métodos Preditivos

Métodos de Séries Temporais

- ✓ Média;
- ✓ Naive;
- ✓ SES;
- ✓ SEH;
- ✓ SEHW;
- ✓ ETS
- ✓ TBATS
- ✓ ARIMA;
- ✓ SSA;

4. Métodos Preditivos

4.1 – Indicadores de acurácia

- ✓ É difícil encontrar modelos que vinculem plenamente o mundo real aos dados observados.
- ✓ Vários indicadores de performance foram desenvolvidos para avaliar o desempenho preditivo (acurácia) de modelos.

4. Métodos Preditivos

4.1 – Indicadores de acurácia

$$ME = \frac{\sum_{t=1}^n (X_t - \hat{X}_t)}{n}$$

$$MAE = \frac{\sum_{t=1}^n |X_t - \hat{X}_t|}{n}$$

$$MSE = \frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{n}$$

$$MAPE = \left[\frac{1}{n} \sum_{t=1}^n \frac{|X_t - \hat{X}_t|}{X_t} \right] * 100$$

4. Métodos Preditivos

4.2 – Média

As previsões de todos os valores futuros são iguais à média dos dados históricos.

$$\hat{Y}_{T+h} = (Y_1, \dots, Y_N)/T$$

```
Ex.: plot(AirPassengers)
      library(forecast)
      model <- meanf(AirPassengers)
      lines(model$mean, col="red")
      summary(model)
```

1. Métodos Preditivos

Exercício 15

- 1) Realize a modelagem das séries abaixo com o método de médias e estime a valor futuro considerando-se $h = 5$. Os valores são iguais? Por que?
 - a) co2
 - b) Nile
 - c) ausbeer #library(fpp)
 - d) visitors #library(fpp)

4. Métodos Preditivos

4.3 – Naive

As previsões são definidas como o valor da última observação Y_t .

- ✓ Simples
- ✓ Drift
- ✓ Sazonal

4. Métodos Preditivos

4.2.1 – Naive Simples

As previsões são definidas como o valor da última observação Y_t .

$$\hat{Y}_{T+h|T} = Y_T$$

```
Ex.: plot(AirPassengers)
      library(forecast)
      model1 <- naive(AirPassengers, h = 3)
      summary(model1)
      plot(model1)
```

4. Métodos Preditivos

4.2.2 – Naive drift

Uma variação do método Naive que permite que as previsões aumentem ou diminuam com o tempo Y_t .

$$\hat{Y}_{T+h|T} = Y_T + \frac{h}{T-1}(Y_T - Y_1)$$

```
Ex.: plot(AirPassengers)
      library(forecast)
      model2 <- rwf(AirPassengers, h = 3, drift=TRUE)
      summary(model2)
      plot(model2)
```

4. Métodos Preditivos

4.2.3 – Naive seasonal

É útil para dados altamente sazonais. Neste caso, cada previsão é igual ao último valor observado da mesma estação do ano.

$$\hat{Y}_{T+h|T} = Y_{T+h-km}, \quad k = \left[\frac{h-1}{m} \right] + 1$$

```
Ex.: plot(AirPassengers)
      library(forecast)
      model3 <- snaive(AirPassengers, h = 3)
      summary(model3)    plot(model3)
```

1. Métodos Preditivos

Exercício 16

- 1) Realize a modelagem das séries abaixo usando os métodos Naive simples, Naive drift e Naive Seasonal. Qual deles apresenta a melhor acurácia?
 - a) co2
 - b) Nile
 - c) ausbeer #library(fpp)
 - d) visitors #library(fpp)

4. Métodos Preditivos

4.4 – SES

É adequado para prever dados sem tendência ou padrão sazonal.

$$\hat{Y}_{t+1} = \alpha Y_t + (1 - \alpha) \hat{Y}_t \quad 0 \leq \alpha \leq 1 \quad \hat{Y}_0 = Y_t$$

$$\hat{Y}_{T+h|T} = N_t$$

Obs.: Explicar Utilizando o excel

1. Métodos Preditivos

Exercício 17

- 1) Realize a modelagem das séries abaixo usando o método SES. Qual foi o erro obtido?
 - a) Nile
 - b) nottem

4. Métodos Preditivos

4.5 – SEH

É adequado para prever dados com tendência.

$$N_{t+1} = \alpha R_t + (1 - \alpha)(N_{t-1} + T_{t-1}) \quad 0 \leq \alpha \leq 1$$

$$T_{t+1} = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1} \quad 0 \leq \beta \leq 1$$

$$N_0 = Y_t$$

$$T_0 = Y_{t+1} - Y_t$$

$$\hat{Y}_{T+h|T} = N_t + hT_t$$

Obs.: Explicar Utilizando o excel

1. Métodos Preditivos

Exercício 18

- 1) Realize a modelagem das séries abaixo usando o método SEH. Qual foi o erro obtido?
 - a) Co2
 - b) AirPassengers
 - c) JohnsonJohnson

4. Métodos Preditivos

4.7 – SEHW

É adequado para prever dados com tendência e sazonalidade.

Aditivo	Multiplicativo	
$N_t = \alpha(Y_t - S_{t-m}) + (1 - \alpha)(N_{t-1} + T_{t-1})$	$N_t = \alpha\left(\frac{Y_t}{S_{t-m}}\right) + (1 - \alpha)(N_{t-1} + T_{t-1})$	$0 \leq \alpha \leq 1$
$T_t = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1}$	$T_t = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1}$	$0 \leq \beta \leq 1$
$S_t = \gamma(Y_t - N_{t-1} - T_{t-1}) + (1 - \gamma)S_{t-m}$	$S_t = \gamma\left(\frac{Y_t}{N_{t-1} + T_{t-1}}\right) + (1 - \gamma)S_{t-m}$	$0 \leq \gamma \leq 1$
$\hat{Y}_{T+h T} = N_t + hT_t + S_{t-m}$	$\hat{Y}_{T+h T} = (N_t + hT_t) S_{t-m}$	

1. Métodos Preditivos

Exercício 19

1) Realize a modelagem das séries abaixo usando o método SEHW. Qual foi o erro obtido?

- a) Co2
- b) AirPassengers
- c) JohnsonJohnson

Dica: Verifiquem se a sazonalidade é aditiva ou multiplicativa antes de modelar.

4. Métodos Preditivos

4.6 – ARIMA

Um processo **ARIMA** (p, d, q) é um processo misto. É adequado para prever séries com tendência.

$$\phi(B)[(1 - B)^d X_t - \mu] = c + \theta(B)\varepsilon_t$$

em que,

- $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é o operador autorregressivo de ordem p ;
- μ é a média da série com d diferenças;
- $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ é o operador de médias móveis de ordem q .

4. Métodos Preditivos

4.6 – SARIMA

Um processo *SARIMA* $(p, d, q)x(P, D, Q)$ é um processo misto. É adequado para prever séries com tendência e sazonalidade.

$$\phi(B).\Phi_p(B^s)\left[(1-B)^d(1-B)_s^D - \mu\right]X_t = \theta(B).\Theta_Q(B^s).\xi_t$$

4. Métodos Preditivos

4.6 – Formas

a) Forma de Equação de Diferenças

Representado em termos de valores prévios de Y_t e do valor atual. É bastante utilizado para calcular previsões.

$$Y_t = \xi_1 Y_{t-1} + \dots + \xi_{p+d} Y_{t-p-d} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q}$$

b) Forma de Choques Aleatórios

Representado em termos do valor atual e prévio de u_t . É uma forma conveniente para se calcular a variância dos erros de previsão.

$$Y_t = u_t + \psi_1 u_{t-1} + \psi_2 u_{t-2} + \dots = \psi(B)u_t$$


c) Forma Invertida

Representada em termos dos valores prévios de Y_t e do valor atual de u_t .

$$\pi(B)Y_t = Y_t - \pi_1 Y_{t-1} - \pi_2 Y_{t-2} - \dots = u_t$$

4. Métodos Preditivos

4.6 – ARIMA/SARIMA



1 - Uma classe geral de modelos é considerada para a análise. A estimação é realizada considerando-se as ferramentas: FAC, FACP e critérios de informação (AIC, BIC e etc).

2 – Os parâmetros do modelo identificado são estimados com base nos dados (máxima verossimilhança ou mínimos quadrados).

3 – Avaliação residual. Espera-se que os resíduos não apresentem correlação serial (RB).

4. Métodos Preditivos

4.6 – ARIMA/SARIMA

Tabela 2.1 - Comportamento teórico da AC e PACF para alguns modelos







Modelo	ACF	PACF
MA(1)	1 pico no lag 1	Decrescimento exponencial
AR(1)	Decrescimento exponencial	1 pico no lag 1
MA(2)	1 pico no lag 1 e 1 pico no lag 2	Mistura de exponenciais ou ondas senóides amortecidas
AR(2)	Mistura de exponenciais ou ondas senóides amortecidas	1 pico no lag 1 e 1 pico no lag 2

$$AIC = -2\ln(L) + 2(p + q)$$

$$BIC = -2\ln(L) + (p + q)\ln(N)$$


L a verossimilhança maximizada.

```
library(forecast)
model <- auto.arima(AirPassengers)
summary(model)
```



4. Métodos Preditivos

4.6 – ARIMA/SARIMA



`tsdiag(model)`

$$H_0: \hat{\rho}(1) = \hat{\rho}(2) = \dots = \hat{\rho}(k) = 0$$
$$\hat{\rho}(1) \neq \hat{\rho}(2) \neq \dots \neq \hat{\rho}(k) \neq 0.$$


1. Métodos Preditivos

Exercício 20

- 1) Realize a modelagem das séries abaixo usando o método ARIMA/SARIMA.
 - a) Co2
 - b) AirPassengers
 - c) JohnsonJohnson
 - d) nottem

4. Métodos Preditivos

4.7 – Singular Spectrum Analysis (SSA)




$$\begin{bmatrix} Y_1 & Y_2 & \cdots & Y_k \\ Y_2 & Y_3 & \cdots & Y_{k+1} \\ \vdots & \vdots & \ddots & \vdots \\ Y_L & Y_{L+1} & \cdots & Y_N \end{bmatrix}$$

$$K = N - L + 1$$

4. Métodos Preditivos

4.7 – Singular Spectrum Analysis (SSA)



Obs.: Demonstrar SSA no R

1. Métodos Preditivos

Exercício 21

1) Aplique o método SSA nas séries abaixo.

- a) Co2
- b) JohnsonJohnson
- d) nottem

4. Métodos Preditivos

4.8 – Tópico especial

Importante! Antes de aplicar um método preditivo é necessário realizar o *data partition*. Pode ser:

- ❑ *train set, predict set* [70%, 30%];
- ❑ [80%, 20%];
- ❑ [90%, 10%];

Obs.: Rodar o script nº21.

Obrigado!

Everaldo Guedes
efgestatistico@gmail.com