



# Análise e Previsão de Séries Temporais

Aula – 1: Introdução às séries temporais

**Eraylson Galdino**

**[egs@cin.ufpe.br](mailto:egs@cin.ufpe.br)**

## Agenda

- Séries Temporais:
  - Definições
  - Exemplos
- Modelos simples com média zero:
  - Ruído I.I.D
  - Processo Binário
  - Random Walk
- Modelos com tendência e sazonalidade:
  - Tendência
  - Sazonalidade
- Modelos Estacionários:
  - Estacionariedade
  - Função de Autocorrelação
  - Correlograma

## Séries Temporais: Definição



George Box & Gwilym Jenkins

*Uma série temporal é um conjunto de **observações ordenadas**,  $x_t$ , cada uma observada em um instante de tempo.*



Peter J Brockwell

*Uma série temporal é um conjunto de observações,  $x_t$ , cada uma **registrada num tempo específico t**.*




Eraylson G. Silva

*Uma série temporal é um conjunto de observações ordenadas,  $x_t$ , cada uma registrada num tempo específico **t**, resultante de um comportamento que pode ser representado por um **modelo matemático**.*

## Séries Temporais: Definição


- **Séries temporais discretas:** são séries em que o **intervalo de observações (t)** pertence a um **conjunto discreto**. Ou seja, as observações são feitas em **intervalos de tempo fixos**;
- **Séries temporais contínuas:** são séries em que as **observações são obtidas continuamente** através de algum **intervalo no tempo**, por exemplo, quando  $T = [0, 1]$ ;

## Séries Temporais: Definição



Exemplo de uma série temporal **discreta**

## Séries Temporais: Definição



Exemplo de uma série temporal **contínua**

## Análise de Séries Temporais

- Objetivos:
  - Compreender as **características** de tal **fenômeno** temporal;
  - **Selecionar** e **estimar** um **modelo estocástico** que possivelmente tenha **gerado** o conjunto de dados;
- Aplicações:
  - Entendimento de um comportamento temporal;
  - Classificar um comportamento temporal;
  - Detecção de anomalias;
  - Previsão;

## Análise de Séries Temporais

- Campos de Aplicação:
  - Mercado Financeiro;
  - Meteorologia;
  - Medicina;
  - Controle de Qualidade e Processos;
  - Governo;
  - Epidemiologia;
  - Transporte;



## Análise de Séries Temporais

- No geral, Análise de Séries Temporais consiste em:
  - Analisar um conjunto de dados (ao longo do tempo);
  - **Selecionar e estimar** um **modelo** matemático que possivelmente tenha **gerado** o conjunto de dados;

## Modelos de Séries Temporais



*Todos os modelos estão errados,  
mas alguns são úteis.*

## Modelos Simples de Séries Temporais

- Selecionar um **modelo probabilístico** adequado para os dados é uma das partes mais **importantes** da **análise** de séries temporais.
- Geralmente, é **suposto** que cada **observação**  $x$  seja um valor **resultante** de uma determinada **variável aleatória**  $X$ ;
- Um **modelo** de série temporal para um determinado **dado observado**  $x_t$  é a **especificação** da **composição de distribuições** da sequência da variável aleatória  $X_t$  em que  $x_t$  é uma observação;

## Modelos Simples de Séries Temporais

- Modelos com média zero:
  - Ruído i.i.d. (independente e identicamente distribuído);
  - Processo binário;
  - *Random Walk* (Passeio Aleatório);
- Modelos com tendência e sazonalidade

## Modelos Simples com média zero: Ruído i.i.d


- Modelo mais simples;
- Sem os componentes de **tendência** e **sazonalidade**;
- As **observações** são resultados de **variáveis aleatórias** i.i.d. com média zero;
- Uma sequência de variáveis aleatórias  $X_1, X_2, \dots$ , são ruídos i.i.d;

$$P[X_1 \leq x_1, \dots, X_n \leq x_n] = P[X_1 \leq x_1] \cdots P[X_n \leq x_n] = F(x_1) \cdots F(x_n)$$

- $F(\cdot)$  é uma função de distribuição cumulativa;
- **Não existe dependência** entre as observações;
- Através do valor  $x_n$  **não é possível prever** o valor de  $x_{n+h}$ ;
- Apesar de **não ser interessante para predição**, é um modelo **importante** para **construção** e **entendimento** de modelos mais complexos;

## Modelos Simples com média zero: Ruído i.i.d


- Um ruído i.i.d com distribuição normal com média zero e variância  $\sigma^2$  é também chamado de **ruído branco** gaussiano;



## Modelos Simples com média zero: Processo binário

- As observações só podem assumir dois valores possíveis;

$$P[X_t = 1] = p, \quad P[X_t = -1] = 1 - p,$$



## Modelos Simples com média zero: *Random Walk*


- Ideia remete a “**caminhada do bêbado**”. Tomada de vários **passos consecutivos**, cada qual em uma **direção aleatória**;
- É **obtido** através da **soma cumulativa** de variáveis i.i.d aleatórias:

$$S_t = X_1 + X_2 + \dots + X_t, \quad \text{for } t = 1, 2, \dots,$$

- é um ruído i.i.d;
- Se  $X_t$  é resultado de um processo binário, então é chamado de *Random Walk* simétrico simples;
  - Caso de *Random Walk* aplicado em jogo de baseball




## Modelos Simples com média zero: *Random Walk*




## Modelos Simples com média zero: *Random Walk*

- Problema na previsão de um *Random Walk*: *Série Nasdaq*



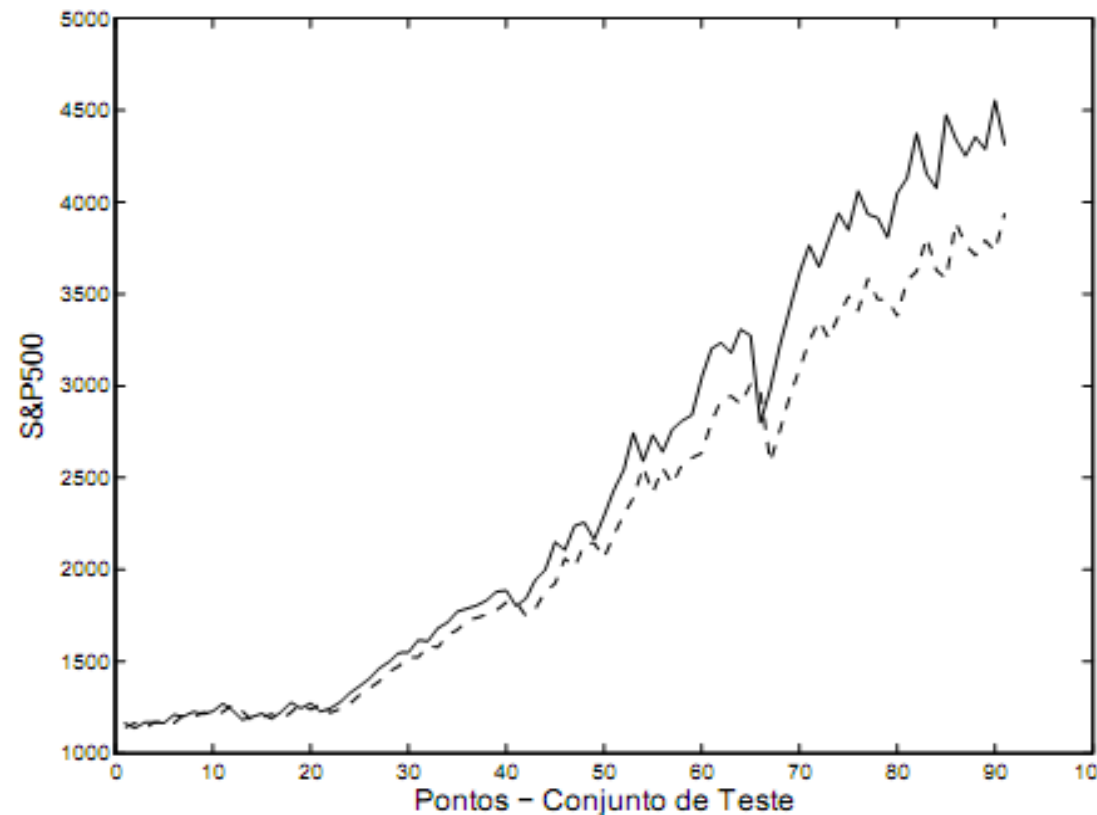
## Modelos Simples com média zero: *Random Walk*

- Problema na previsão de um *Random Walk*: *Série DJIA*




## Modelos Simples com média zero: *Random Walk*

- Problema na previsão de um *Random Walk*: *Série S&P 500*



## Modelos Simples com média zero: *Random Walk*

- Problema na previsão de um *Random Walk*: *Série Petrobras*



## Modelos Simples com média zero: *Random Walk*

- Problema na previsão de um *Random Walk*: *Série S&P 500*


| Real     | Previsão |
|----------|----------|
| 0,685264 | 0,69427  |
| 0,690659 | 0,688232 |
| 0,681649 | 0,69365  |
| 0,685226 | 0,684601 |
| 0,691443 | 0,688193 |
| 0,700727 | 0,694438 |
| 0,707789 | 0,703763 |

## Modelos com tendência e sazonalidade

- Algumas séries é perceptível que **não podem ser modeladas** por **modelos simples** de média zero;
- São **geradas** com **componentes** de **tendência** e **sazonalidade**;
- **Tendência**: mudança sistemática na série temporal que não aparenta ser periódico;
- **Sazonalidade**: comportamento que se repete durante um período de tempo;

## Modelos com tendência e sazonalidade

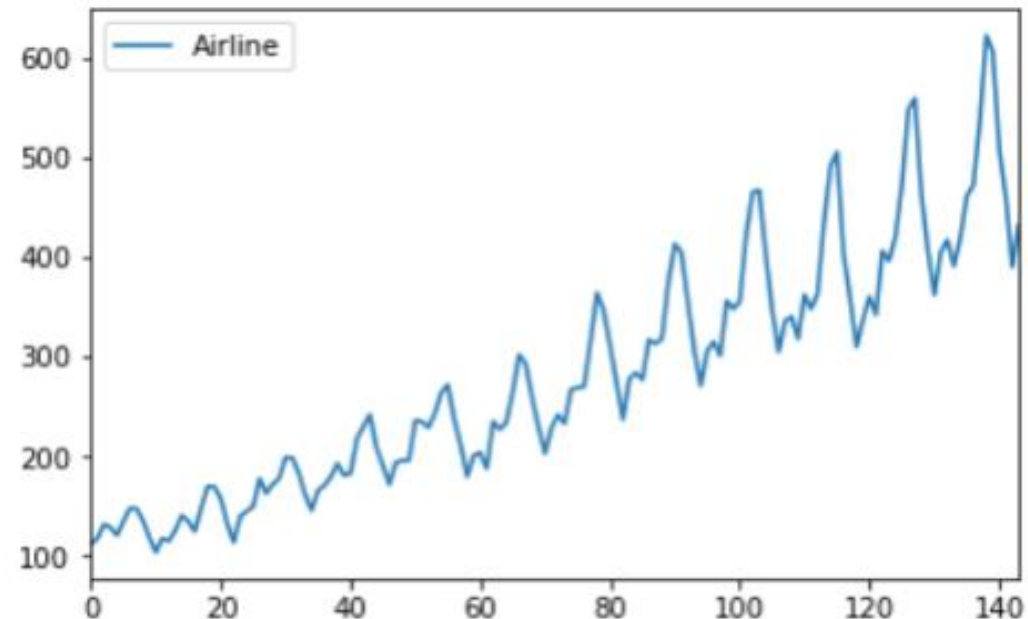
- Série com tendência: Vendas de Shampoo





## Modelos com tendência e sazonalidade

- Série com sazonalidade: Vendas de Passagens aéreas



## Modelos com tendência e sazonalidade

- Modelo com tendência:

$$X_t = m_t + Y_t.$$

- $m_t$  é o **componente de tendência** e pode ser **estimado** através do método de **mínimo quadrado**:

$$m_t = a_0 + a_1t + a_2t^2.$$

- Valores de **a** são ajustados para minimizar a função:

$$\sum_{t=1}^n (x_t - m_t)^2$$

## Modelos com tendência e sazonalidade

- Modelo com Sazonalidade:

$$X_t = s_t + Y_t$$

- $s_t$  é o **componente de sazonalidade**, resultado de uma **função periódica** que pode ser obtida através da **soma de ondas senoidais**:

$$s_t = \alpha_0 + \sum_{j=1}^k (a_j \cos(\lambda_j t) + b_j \sin(\lambda_j t))$$

- **a** e **b** são parâmetros desconhecidos e lambda  $\lambda$  são as frequências

## Uma Abordagem Geral para Modelagem de Séries Temporais

- A abordagem consiste em **plotar a série** e analisar alguns aspectos:
  - Tendência
  - Sazonalidade
  - Alterações acentuadas no comportamento
  - Observações discrepantes com os dados
- **Remover tendências** e componentes **sazonais** para obter resíduos estacionários;
- **Escolher** um modelo para ajustar aos resíduos. Utilizando várias estatísticas amostrais como função de autocorrelação
- Alcançar **a previsão original** da série através da **previsão dos resíduos** junto com os valores estimados da **tendência** e **sazonalidade**;

## Processo Estacionário

- É um processo que se **mantém em equilíbrio estatístico** com propriedades probabilísticas que **não se alteram no tempo**;
  - $X_t$  uma série temporal com  $E(x_t^2) < \infty$
  - A Média pode ser representada por:  $\mu_x(t) = \bar{E}(X_t)$
  - A covariância pode ser representada por:  $\gamma_x(r, s) = Cov(X_r, X_s) = E[(X_r - \mu_x(r))(X_s - \mu_x(s))]$
- O processo é considerado **fracamente estacionário** se:
  - As características de  $x_t$  são iguais para todo  $t$ ;
  - Média e variância constantes;
  - $\mu_x(t)$  é independente de  $t$  e  $\gamma_x(t+h, t)$  é independente de  $t$  para cada  $h$ ;

## Modelos Estacionários: Função de Autocorrelação

- Seja  $X_t$  uma série estacionária, a Função de Autocovariância do lag  $h$  é:

$$\gamma_x = Cov(X_{t+h}, X_t)$$

- A Função de Autocorrelação de  $X_t$  do lag  $h$  é definida como:

$$\rho_x(h) \equiv \frac{\gamma_x(h)}{\gamma_x(0)} = Cor(X_{t+h}, X_t)$$

- A autocorrelação é a correlação entre uma série e ela mesma defasada;

## Analisando Estacionariedade: Exemplos

- Ruído i.i.d.:
  - Se  $X_t$  é um ruído i.i.d e  $E(X_t^2) = \sigma^2 < \infty$  e  $E(X_t) = 0$  para todo  $t$ , então a primeira condição para ser um modelo estacionário é satisfeita.
  - Assumindo a independência dos dados temos:

$$\gamma_X(t+h, t) = \begin{cases} \sigma^2, & \text{if } h = 0, \\ 0, & \text{if } h \neq 0, \end{cases} \quad \text{Não dependente de } t$$

- $\{X_t\} \sim \text{IID}(0, \sigma^2)$  é um modelo estacionário.

## Analisando Estacionariedade: Exemplos

- Ruído Branco:
  - Se  $X_t$  é uma sequência de **variáveis aleatórias descorrelacionadas**, onde  $X_t \sim \text{WN}(0, \sigma^2)$  então  $X_t$  é **estacionário com características semelhantes ao ruído i.i.d** (covariância);
  - Todo processo IID(0,  $\sigma^2$ ) é um WN(0,  $\sigma^2$ ), porém o inverso não é verdadeiro;
- Random Walk:
  - Se  $S_t$  é um random walk definida por:
    - $E(S_t) = 0$ ,  $E(S_t^2) = t\sigma^2 < \infty$  para todo  $t$ , e para  $h \geq 0$ ;
    - Será estacionária se  $\gamma_s(t+h, t)$  não depender de  $t$ . Pois caso contrario à medida que  $t$  aumenta, a variância cresce indefinidamente, violando uma das condições de estacionariedade;



## Função de Autocorrelação Amostral

- Utilizada para analisar o **grau de dependência** temporal na série;
- **Auxilia na seleção** de possíveis modelos de séries temporais estacionárias;
- Definição:
  - Seja  $x_t, \dots, x_n$  observações de uma série temporal. A média amostral é definida como:

$$\bar{x} = \frac{1}{n} \sum_{t=1}^n x_t$$

- A função de autocovariância amostral é definida como:

$$\hat{\gamma}(h) = n^{-1} \sum_{t=1}^{n-|h|} (x_{t+|h|} - \bar{x})(x_t - \bar{x}), \quad -n < h < n$$

- A função de autocorrelação amostral:


$$\hat{\rho}(h) = \frac{\hat{\gamma}(h)}{\hat{\gamma}(0)}, \quad -n < h < n.$$

## Função de Autocorrelação Parcial

- As autocorrelações para intervalos sucessivos são formalmente dependentes;
- A F.A.C parcial é utilizada para **obter uma informação** sobre autocorrelação na série **sem esta influência em cascata**;
- A autocorrelação parcial de atraso  $k$  corresponde a autocorrelação entre  $x_t$  e  $x_{t-k}$  que não é explicada pelos atrasos de 1 a  $k$ ;
- Correlação x Causalidade:
  - Correlação: Uma variável **A** tem um comportamento semelhante à **B**;
  - Causalidade: Uma variável **B** influencia o comportamento da variável **B**;
  - <http://www.tylervigen.com/spurious-correlations>

## Correlograma

- Forma gráfica de analisar a autocorrelação;
- O correlograma traça as autocorrelações em **diversas defasagens**;
- Através da análise utilizando o correlograma é possível **entender se a série é aleatória** ou possui alguma **tendência** ou **sazonalidade**;
- Frequentemente utilizado para **analisar os resíduos** de um modelo;



## Correlograma

- O Gráfico é **composto por valores** exibidos em pontos/barra que representam o **coeficiente de correlação** amostral  $r$ . Esse **coeficiente** é uma medida de direção e **grau** entre **duas variáveis** quantitativas que se **associam linearmente**;
- Representando as variáveis por  $(x,y)$ , o coeficiente é calculado através da seguinte fórmula:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \text{ onde } \bar{x} = \frac{\sum_{i=1}^n x_i}{n} \text{ e } \bar{y} = \frac{\sum_{i=1}^n y_i}{n}$$

- O coeficiente  $r$  para o par de variáveis  $(x,y)$  é o quociente entre a **covariância amostral** das variáveis  $x$  e  $y$  e o **produto dos respectivos desvios padrões**:



$$r = \frac{Cov(x,y)}{s_x s_y}$$

## Correlograma

- Para inferir se em um dado lag existe ou não correlação é utilizado intervalos de confiança;
- Para um intervalo de confiança de 95% os limites são  $\pm 1.96/\sqrt{n}$
- Os lag com coeficiente  $r$  fora do intervalo de confiança são considerados significantes.
- O coeficiente com valor 1 representa correlação máxima positiva;
- O coeficiente com valor -1 representa correlação máxima negativa;
- O coeficiente com valor 0 representa que não existe correlação;

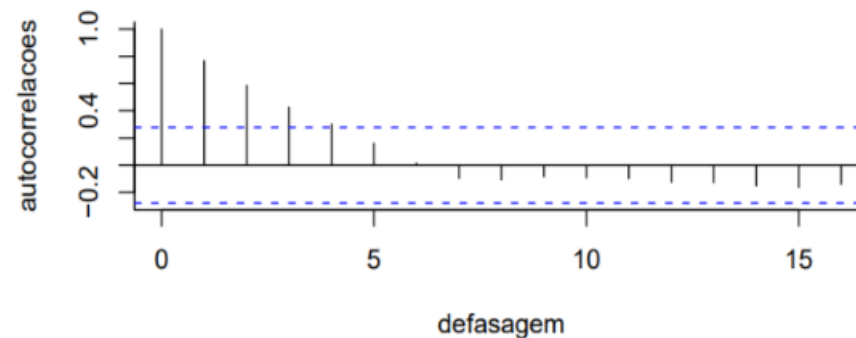

## Correlograma: Exemplo

- Série aleatória:
  - Através do correlograma é possível analisar se uma série é aleatória ou não;
  - Em uma série completamente aleatória os lags são não correlacionados, ou seja, espera-se que o coeficiente de autocorrelação amostral  $r_k$  seja próximo à zero,  $k = 1, 2, \dots$





## Correlograma: Exemplo

- Correlação de curto prazo:
  - É dita de curto prazo quando uma observação acima da média tende a ser seguida por uma ou mais observações acima da média. O mesmo ocorre para observações abaixo da média.
  - O correlograma desta série será composto por um valor relativamente grande para  $r_1$  seguido por valores que tendem a ficar sucessivamente menores;
  - A partir de uma certa defasagem  $k$  os valores de  $r_k$  tendem a ser aproximadamente zero.



## Correlograma: Exemplo



- Séries não estacionária:
  - Para uma série com tendência os valores do coeficiente  $r$  não decaem para zero a não ser em defasagens grandes. Isso ocorre pois uma observação de um lado da média tende a ser seguida por um grande número de observações da mesma média (mesmo lado) por conta da tendência;
  - Nesse caso, pouca ou nenhuma informação pode ser obtida do correlograma pois a tendência dominará outras características;





## Correlograma: Exemplo

- Correlação negativa:
  - Quando os valores das observações tendem a se alternar acima e abaixo de uma média, o coeficiente de correlação também tende a se alternar;
  - O valor de  $r_1$  será negativo enquanto o valor de  $r_2$  será positivo já que as observações defasadas de 2 períodos (lags) tendem a estar do mesmo lado da média;



## Resumo

- Conceitos:
  - Séries Temporais;
  - Modelos simples com média zero
    - Ruído I.I.D
    - Processo Binário
    - Random Walk
  - Modelos com tendência e sazonalidade
    - Tendência
    - Sazonalidade
  - Modelos Estacionários
    - Estacionariedade
    - Função de Autocorrelação
    - Correlograma

## Extras

- Repositórios de séries temporais:
  - <https://datamarket.com/data/list/?q=>
  - <https://research.cs.aalto.fi/aml/datasets.shtml>
  - <http://archive.ics.uci.edu/ml/index.php>
  - <https://www.kaggle.com/datasets>
- Aula com código em Python:
  - <https://github.com/EraylsonGaldino/timeseries/blob/master/TS%20-%20Aula%2001.ipynb>

## Referências

- BOX, G. E. P. and JENKINS, G. M. (2008). Time series analysis: forecasting and control, 4nd. ed., San Francisco: Holden-Day.
- Brockwell, Peter J. and Davis, Richard A. (2002). Introduction to Time Series and Forecasting, 2nd. ed., Springer-Verlag