

Modelo Auto-regressivo Integrado de Médias Móveis para a temperatura média anual nos anos de 1869-2019 do Central Park

Ana Zucon;
Vinicius Riffel

UFPR

Mar. 15, 2021

- 1 Introdução
- 2 Materiais e métodos
- 3 Aplicação em dados reais
- 4 Conclusão
- 5 Referências

- 1 Introdução
- 2 Materiais e métodos
- 3 Aplicação em dados reais
- 4 Conclusão
- 5 Referências

Introdução

- Os modelos para séries temporais são úteis em situações que temos dependência temporal na variável resposta.

Introdução

- Os modelos para séries temporais são úteis em situações que temos dependência temporal na variável resposta.
- A dependência pode ser por elemento intrínseco à variável resposta ou problema na coleta de amostras.

Introdução

- Os modelos para séries temporais são úteis em situações que temos dependência temporal na variável resposta.
- A dependência pode ser por elemento intrínseco à variável resposta ou problema na coleta de amostras.
- Em qualquer dessas situações temos *erros autocorrelacionados*.

Introdução

- Os modelos para séries temporais são úteis em situações que temos dependência temporal na variável resposta.
- A dependência pode ser por elemento intrínseco à variável resposta ou problema na coleta de amostras.
- Em qualquer dessas situações temos *erros autocorrelacionados*.
- Nessas situações, devemos considerar um modelo que seja capaz de incluir essa autocorrelação.

Modelos para séries temporais

- Auto-regressivos (*AR*).
- Médias móveis (*MA*).
- Auto-regressivos de médias móveis (*ARMA*).
- Auto-regressivos integrados de médias móveis (*ARIMA*).

- 1 Introdução
- 2 Materiais e métodos**
- 3 Aplicação em dados reais
- 4 Conclusão
- 5 Referências

Modelos AR

- O modelo AR de ordem p , denotado por $AR(p)$, é definido por:

$$\hat{Y}_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t \quad t = p + 1, p + 2, \dots, n \quad (1)$$

em que Y_t é um processo estocástico estacionário, ε_t é um termo de erro, c e ϕ_i são os parâmetros do modelo.

- A função de autocovariância do modelo AR(1) é dada por:

$$K_y(t, t + \tau) = \text{Cov}(Y_t, Y_{t + \tau}) = \frac{\sigma_\varepsilon^2}{1 - \phi^2} \phi^{|\tau|}$$

onde σ_ε^2 é a variância do termo de erro (constante).

Modelos MA

- A equação do modelo $MA(q)$ é dada por:

$$\hat{Y}_t = \mu + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t \quad t = q + 1, q + 2, \dots, n \quad (2)$$

em que ϵ_t é o erro no tempo t , ϵ_t é um termo de erro, μ e θ_i são os parâmetros do modelo.

Modelos *ARMA*

Combinando as equações 1 e 2 temos o modelo *ARMA*(p, q):

$$\hat{Y}_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t$$
$$t = \min(p, q) + 1, \min(p, q) + 2, \dots, n.$$

Operador de defasagem (LAG)

- Indica quantidade de tempos anteriores em relação ao tempo t :

$$L^n y_t = y_{t-n}, \quad \text{em que } t > n.$$

- Diferenciando a série uma vez:

$$y'_t = y_t - y_{t-1} = y_t - Ly_t = (1 - L)y_t.$$

- Generalizando: $(1 - L)^n y_t = y_t - \sum_{i=1}^n y_{t-i}$.

Modelos *ARIMA*

- Usado quando o processo Y_t é não estacionário.
- E equação do modelo *ARIMA*(p, d, q) é dada por:

$$(1 - L)^d \hat{Y}_t = c + \sum_{i=1}^p \phi_i (1 - L)^d Y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t,$$

$$t < d, d \leq p \text{ e } d \leq q.$$

- p , d e q são a *ordem* do modelo.
- Os parâmetros são c , ϕ_i e θ_i .

Caso especiais de *ARIMA*

- $ARIMA(0, 0, 0)$: Ruído branco (assumindo que $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$).
- $ARIMA(0, 0, q)$: $MA(q)$.
- $ARIMA(p, 0, 0)$: $AR(p)$.
- $ARIMA(p, 0, q)$: $ARMA(p, q)$.

Materiais e métodos

Estimação dos modelos

- Os estimadores de mínimos quadrados podem ser obtidos por:

$$\underset{\hat{\mathbf{Y}} \in \Theta}{\operatorname{argmin}} S(\hat{\mathbf{Y}}) = \sum_{t \in T} \varepsilon_t^2 \quad (3)$$

Ou assumindo que $\varepsilon_t \sim NID(0; \sigma_\varepsilon^2)$:

$$\underset{\hat{\mathbf{Y}} \in \Theta}{\operatorname{argmax}} L(\hat{\mathbf{Y}}) = (2\pi)^{-n/2} (\sigma_\varepsilon)^{-n} \exp \left(- \sum_{t \in T} \frac{\varepsilon_t^2}{2\sigma_\varepsilon^2} \right) \quad (4)$$

em que $\hat{\mathbf{Y}}$ é o vetor de parâmetros do modelo.

- Os estimadores são obtidos minimizando a função 3 ou maximizando a função 4.
- Os estimadores de máxima verossimilhança e mínimos quadrados são idênticos.

IC e TH

- Pode ser provado que:

$$\sqrt{n}(\hat{\Upsilon} - \Upsilon) \xrightarrow{D} N(\mathbf{0}_{r \times 1}; \mathbf{I}_F^{-1})$$

em que r é o rank da matriz do modelo e \mathbf{I}_F é a matriz de informação de Fisher.

Materiais e métodos

IC e TH

- IC com $(1 - \alpha)\%$ de confiança para algum parâmetro v do modelo é dado por:

$$\hat{v} \pm t_\alpha \sqrt{\hat{Var}(\hat{v})}$$

em que t_α é o quantil da distribuição T que fornece $(1 - \alpha)\%$ de confiança. Caso σ_ε^2 seja conhecida, o quantil utilizado será da distribuição Normal.

- Da mesma forma, pode-se obter o IC para predição ou para os valores ajustados:

$$\hat{y}_t \pm t_\alpha \sqrt{\hat{Var}(\hat{y}_t)}$$

Seleção de modelos

- Como selecionar um dentre os diferentes modelos?
- Podemos utilizar o Akaike Information Criteria (*AIC*):

$$AIC = -2l(\hat{\mathbf{Y}}; \mathbf{y}) + 2p$$

onde p é o número de parâmetros do modelo e $l(\hat{\mathbf{Y}}; \mathbf{y})$ é a moda da função log-verossimilhança.

- Na prática, ajustamos vários modelos *ARIMA* de diferentes ordens e selecionamos aquele que tem o menor *AIC*.

- 1 Introdução
- 2 Materiais e métodos
- 3 Aplicação em dados reais**
- 4 Conclusão
- 5 Referências

Aplicação em dados reais

- Mudanças climáticas é assunto recorrente na comunidade científica.

Aplicação em dados reais

- Mudanças climáticas é assunto recorrente na comunidade científica.
- Vamos modelar as temperaturas médias anuais do Central Park (Nova York) utilizando um modelo ARIMA.

Aplicação em dados reais

- Mudanças climáticas é assunto recorrente na comunidade científica.
- Vamos modelar as temperaturas médias anuais do Central Park (Nova York) utilizando um modelo ARIMA.
- Os dados foram coletados de 1869 até 2019.

Aplicação em dados reais

- Mudanças climáticas é assunto recorrente na comunidade científica.
- Vamos modelar as temperaturas médias anuais do Central Park (Nova York) utilizando um modelo ARIMA.
- Os dados foram coletados de 1869 até 2019.
- As medidas estão em graus Fahrenheit.

Aplicação em dados reais

- Mudanças climáticas é assunto recorrente na comunidade científica.
- Vamos modelar as temperaturas médias anuais do Central Park (Nova York) utilizando um modelo ARIMA.
- Os dados foram coletados de 1869 até 2019.
- As medidas estão em graus Fahrenheit.
- A análise foi construída no software R, através do pacote `forecast`.

Aplicação em dados reais

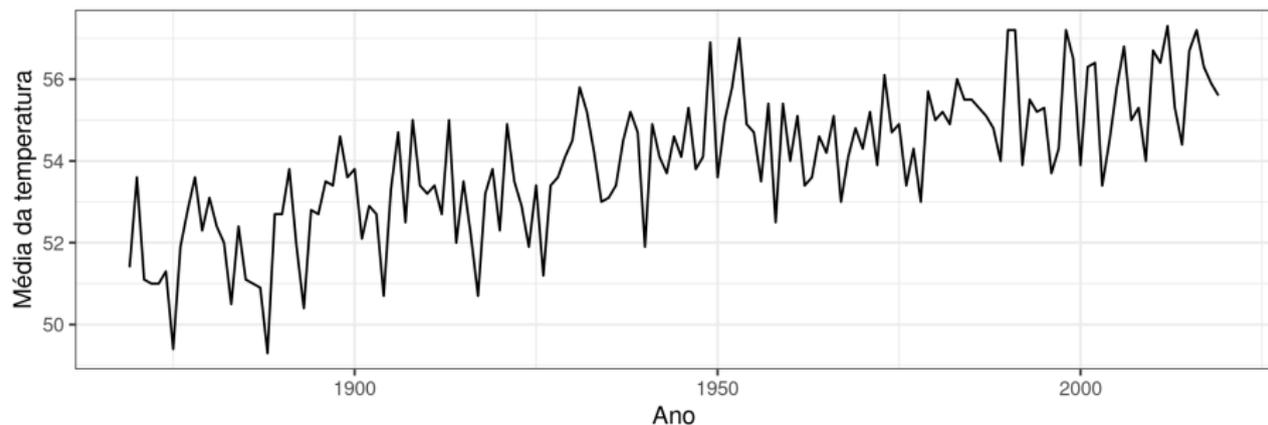


Figura 1: Gráfico da série com $LAG = 0$.

Aplicação em dados reais

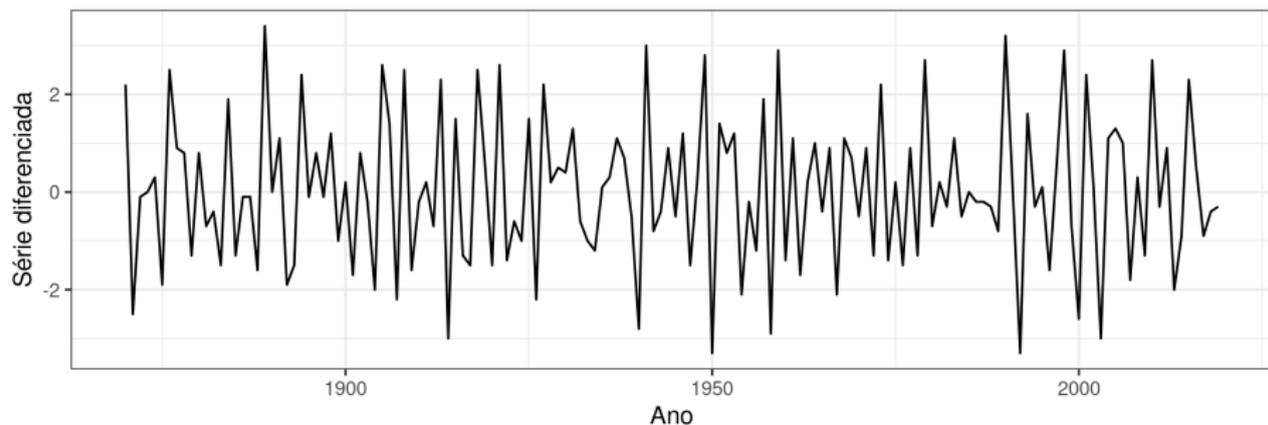


Figura 2: Gráfico da série com $LAG = 1$.

Aplicação em dados reais

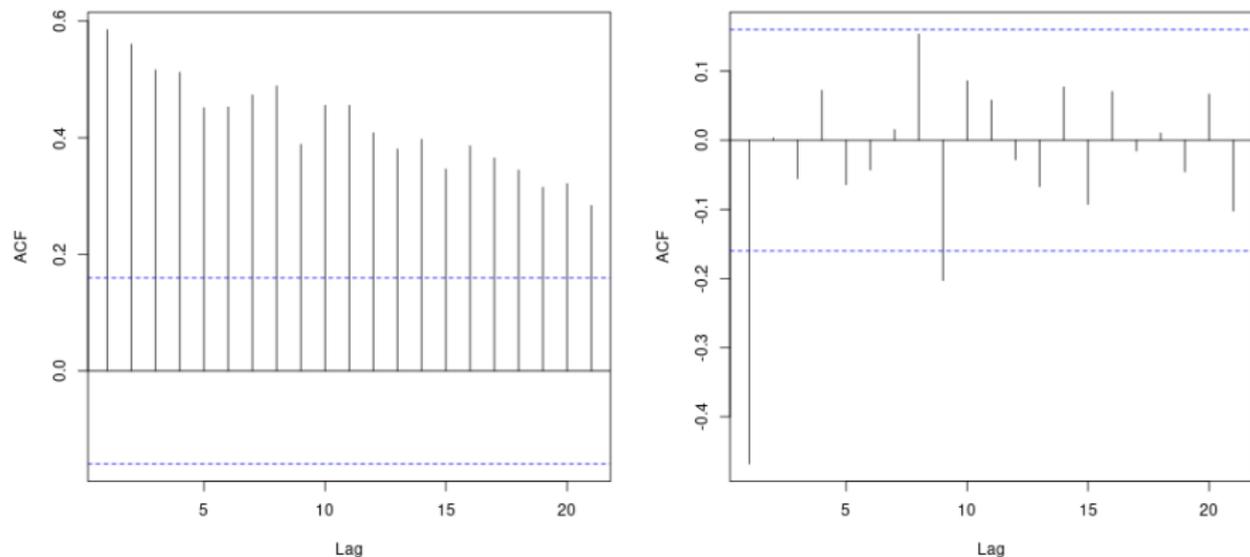


Figura 3: Gráfico das autocorrelações da série com $LAG = 0$ (esquerda) e $LAG = 1$ (direita).

Aplicação em dados reais

Modelo	AIC	\hat{c}	$\hat{\theta}$	$\hat{\phi}$
ARIMA(0,0,0)	590.84	53.97		
ARIMA(0,0,1)	556.85	53.96	0.39	
ARIMA(0,1,0)	553.88			
ARIMA(1,0,0)	528.15	53.96		0.59
ARIMA(0,1,1)	481.78		-0.86	
ARIMA(1,0,1)	489.63	53.87	-0.85	0.99
ARIMA(1,1,0)	518.51			-0.47
ARIMA(1,1,1)	483.28		-0.87	0.06

Aplicação em dados reais

```
(fit <- Arima(serie, order = c(0, 1, 1), method = "ML"))
```

```
## Series: serie
```

```
## ARIMA(0,1,1)
```

```
##
```

```
## Coefficients:
```

```
##          ma1
```

```
##        -0.8561
```

```
## s.e.    0.0406
```

```
##
```

```
## sigma^2 estimated as 1.412:  log likelihood=-238.89
```

```
## AIC=481.78   AICc=481.86   BIC=487.8
```

Aplicação em dados reais

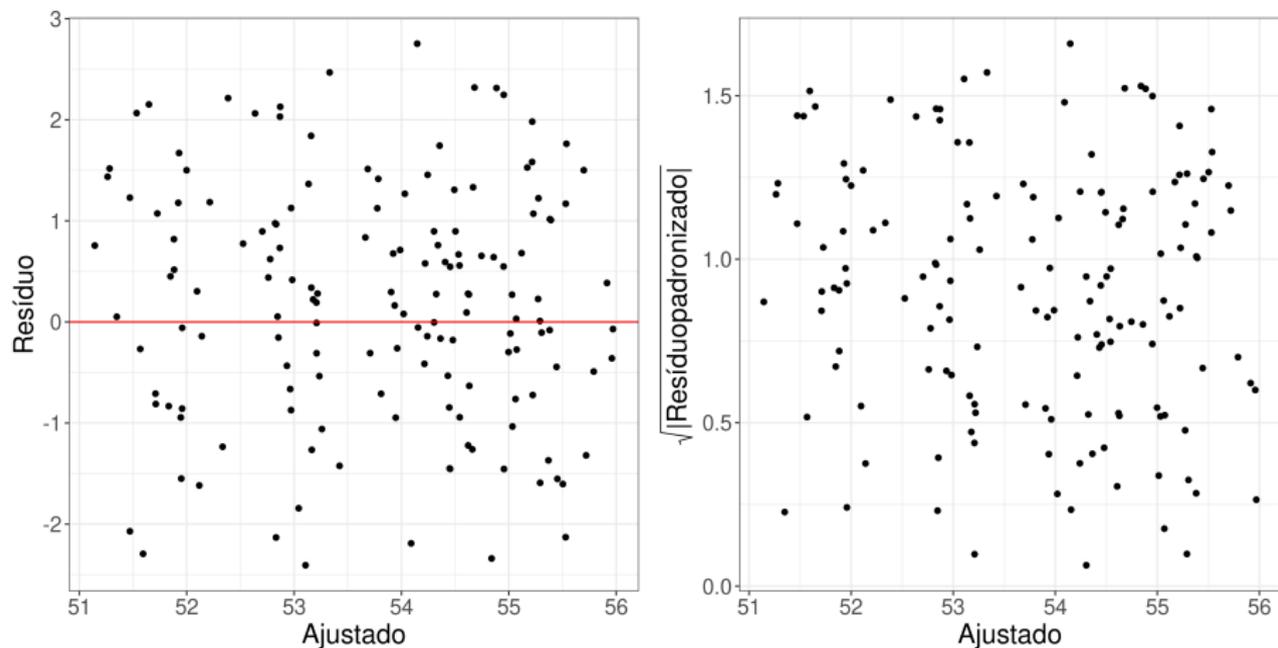


Figura 4: Resíduos ordinários (esquerda) e raiz quadrada do valor absoluto dos resíduos padronizados (direita) para cada valor ajustado.

Aplicação em dados reais

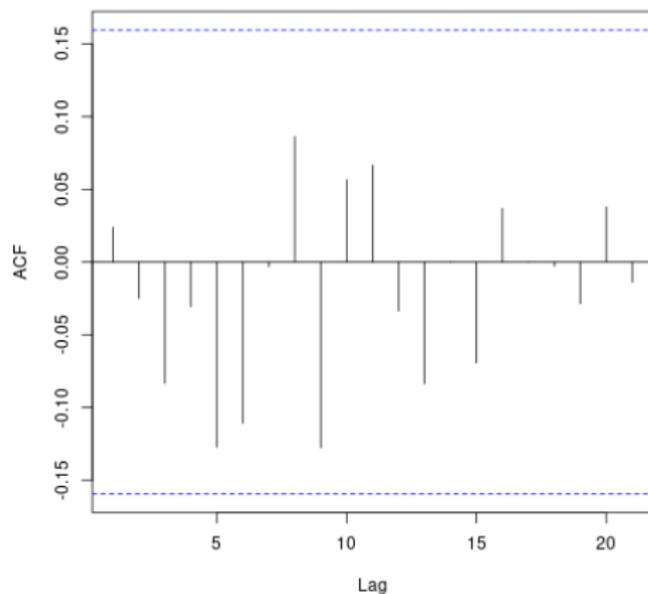


Figura 5: Gráfico ACF dos resíduos.

Aplicação em dados reais

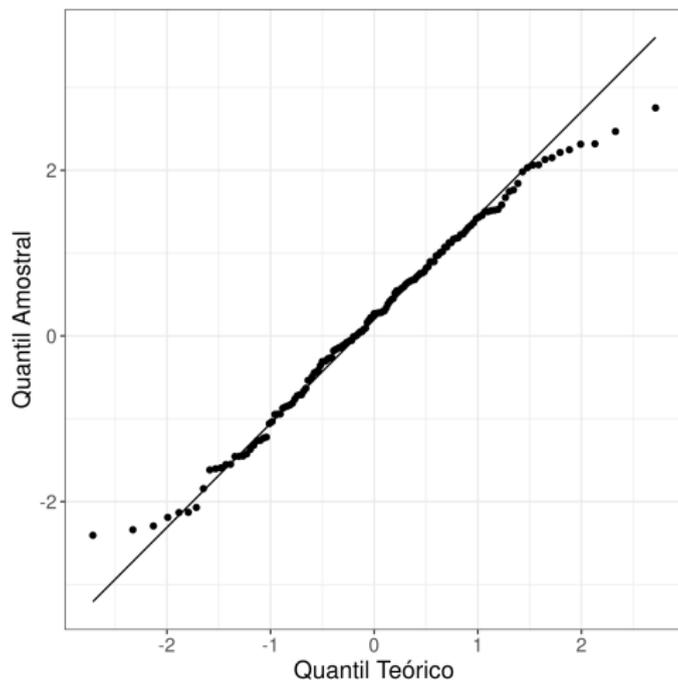


Figura 6: Gráfico quantil-quantil dos resíduos.

Aplicação em dados reais

- A equação do modelo ajustado é dada por:

$$\hat{Y}_t = Y_{t-1} - 0.8561(\hat{Y}_{t-1} - Y_{t-1}) \quad \text{com } t = 2, 3, \dots, 151.$$

- Para esse modelo, a variância de $\hat{\theta}$ é estimada por:

$$\hat{Var}(\hat{\theta}) \approx \frac{1 - (-0.8561)^2}{150} \approx 0.0016$$

- Para $\alpha = 0.05$, o intervalo de confiança/predição é dado por:

$$\hat{y}_t \pm t_{0.05} \sqrt{1.412(1 + \tau(1 - 0.8561)^2)}$$

em que τ é a quantidade de tempos adiante de t que iremos prever.

Aplicação em dados reais

- Para testar se o coeficiente é significativo, fazemos:

$$t_{obs} = \frac{-0.8561}{0.04} \approx -21.$$

- O intervalo com 95% intervalo de confiança para θ pode ser obtido a partir da função `confint`.

```
confint(fit)
```

```
##           2.5 %       97.5 %  
## ma1 -0.9356608 -0.7766035
```

Aplicação em dados reais

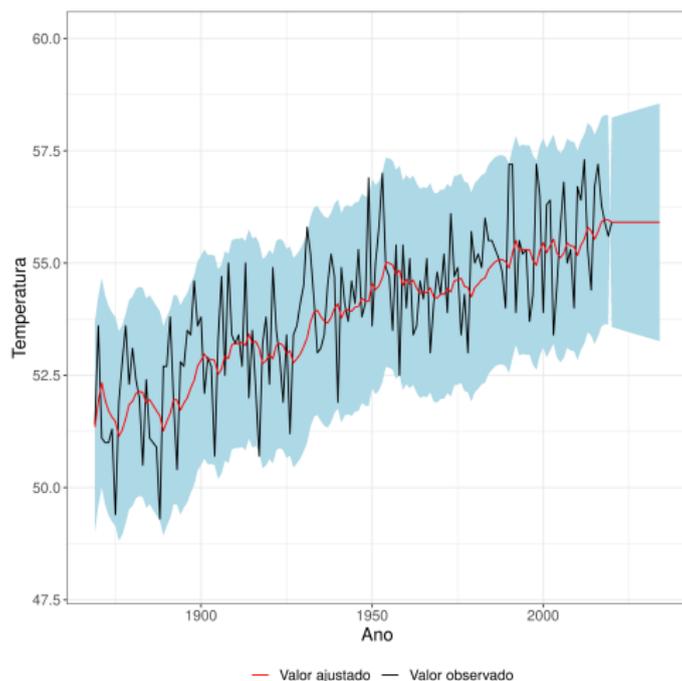


Figura 7: Gráfico com intervalo de confiança dos valores ajustados e um intervalo de previsão até 2024.

- 1 Introdução
- 2 Materiais e métodos
- 3 Aplicação em dados reais
- 4 Conclusão**
- 5 Referências

Conclusão

- Séries temporais são técnicas estatísticas que podem ser utilizadas nas mais diferentes áreas de pesquisa.

Conclusão

- Séries temporais são técnicas estatísticas que podem ser utilizadas nas mais diferentes áreas de pesquisa.
- Apresentamos diversos modelos para dados com dependência temporal.

Conclusão

- Séries temporais são técnicas estatísticas que podem ser utilizadas nas mais diferentes áreas de pesquisa.
- Apresentamos diversos modelos para dados com dependência temporal.
- Outro tipos de modelos para séries temporais lidam com sazonalidade e situações em que nossos dados são vetores (modelos multivariadas).

- 1 Introdução
- 2 Materiais e métodos
- 3 Aplicação em dados reais
- 4 Conclusão
- 5 Referências

Referências

J. Hamilton. **Time Series Analysis**. Princeton University Press, 1994.

R. Hyndman, G. Athanasopoulos, C. Bergmeir, G. Caceres, L. Chhay, M. O'Hara-Wild, F. Petropoulos, S. Razbash, E. Wang, and F. Yasmeeen. **forecast: Forecasting functions for time series and linear models**, 2020. R package version 8.13.

R. J. Hyndman and Y. Khandakar. **Automatic time series forecasting: the forecast package for R**. Journal of Statistical Software, 26(3):1–22, 2008.

R Core Team. **R: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing, Vienna, Austria, 2020.