

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
DEPARTAMENTO DE ESTATÍSTICA

**Estudo e comparação das técnicas de Validação  
Cruzada desenvolvidas para Séries Temporais**

**Daniel Simionato**

**Trabalho de Conclusão de Curso**



UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
DEPARTAMENTO DE ESTATÍSTICA

Estudo e comparação das técnicas de Validação Cruzada  
desenvolvidas para Séries Temporais

**Daniel Simionato**

**Orientadora: Maria Sílvia de Assis Moura**

Trabalho de Conclusão de Curso apresentado ao Departamento de Estatística da Universidade Federal de São Carlos - DEs-UFSCar, como parte dos requisitos para obtenção do título de Bacharel em Estatística.

**São Carlos**  
**Abril de 2022**



FEDERAL UNIVERSITY OF SÃO CARLOS  
EXACT AND TECHNOLOGY SCIENCES CENTER  
DEPARTMENT OF STATISTICS

Study and comparison of Cross-Validation techniques developed  
for Time Series

**Daniel Simionato**

**Advisor: Maria Sílvia de Assis Moura**

Bachelors dissertation submitted to the Department of Statistics, Federal University of São Carlos - DEs-UFSCar, in partial fulfillment of the requirements for the degree of Bachelor in Statistics.

**São Carlos**

**April 2022**



Daniel Simionato

Estudo e comparação das técnicas de Validação Cruzada  
desenvolvidas para Séries Temporais

Este exemplar corresponde à redação final do trabalho de conclusão de curso devidamente corrigido e defendido por Daniel Simionato e aprovado pela banca examinadora.

Aprovado em 18 de abril de 2022

Banca Examinadora:

- Profa. Dra. Maria Sílvia de Assis Moura (Orientadora)
- Prof. Dr. Luis Aparecido Milan
- Prof. Dr. Renato Jacob Gava





*Dedico este trabalho aos meus pais, Juliana Pedroso Simionato e Osmair Donizeti  
Simionato por todo suporte*



# Agradecimentos

Agradeço aos meus pais e meu irmão, que sempre me apoiaram e incentivaram nos estudos.

Ao meu namorado Renato Nakahara, que jamais me negou apoio, carinho e incentivo. Obrigado por todo o companheirismo ao longo deste percurso.

A professora Dra. Maria Sílvia de Assis Moura, por ter sido minha orientadora e ter desempenhado tal função com dedicação e amizade.

A banca examinadora e todo corpo docente do curso de bacharelado de estatística da UFSCar, por todos os conselhos, pela ajuda e pela paciência com a qual guiaram o meu aprendizado.



# Resumo

Testar a capacidade de generalização de um algoritmo obtido é crucial para qualquer metodologia de predição, para tal foram desenvolvidos os métodos de validação-cruzada. No entanto, quando estamos tratando com dados que tenham dependência entre as observações, como o caso de séries temporais, as metodologias usuais de validação-cruzada não são apropriadas. Atualmente não há uma maneira única e usual de se testar a capacidade de generalização de um modelo preditivo para séries temporais. À vista disso, nesse trabalho vamos estudar e comparar quatro diferentes variações de métodos para validação-cruzada, isso será realizado por meio simulações de séries temporais diversas.

**Palavras-chave:** *predição, séries temporais, validação-cruzada.*



# Abstract

Testing the generalization capacity of an algorithm obtained is crucial for any prediction methodology, for which cross-validation methods were developed. However, when dealing with data that have dependency among observations, as in the case of time series, the usual cross-validation methodologies are not appropriate. Currently, there is no single and usual way to test the generalizability of a predictive model for time series. In this work we will study and compare four different variations of methods for cross-validation, this will be done through simulations of different time series.

**Keywords:** *prediction, time series, cross validation.*





# Lista de Figuras

2.1	Técnica de validação fora da amostra . . . . .	26
3.1	Ranking Médio - Suavização Exponencial, série ARIMA(1,0,0) n = 50 . . .	32
3.2	Ranking Médio - Modelo ARIMA, série ARIMA(1,0,0) n = 50 . . . . .	32
3.3	Ranking Médio - Suavização Exponencial, série ARIMA(1,0,0) n = 100 . .	33
3.4	Ranking Médio - Modelo ARIMA, série ARIMA(1,0,0) n = 100 . . . . .	33
3.5	Ranking Médio - Suavização Exponencial, série ARIMA(1,0,0) n = 1000 .	34
3.6	Ranking Médio - Modelo ARIMA, série ARIMA(1,0,0) n = 1000 . . . . .	34
3.7	Ranking Médio - Suavização Exponencial, série ARIMA(2,0,0) n = 1000 .	35
3.8	Ranking Médio - Modelo ARIMA, série ARIMA(2,0,0) n = 1000 . . . . .	35
3.9	Ranking Médio - Suavização Exponencial, série ARIMA(1,0,1) n = 1000 .	36
3.10	Ranking Médio - Modelo ARIMA, série ARIMA(1,0,1) n = 1000 . . . . .	36
3.11	Ranking Médio - Suavização Exponencial, série ARIMA(1,1,0) n = 50 . . .	37
3.12	Ranking Médio - Modelo ARIMA, série ARIMA(1,1,0) n = 50 . . . . .	38
3.13	Ranking Médio - Suavização Exponencial, série ARIMA(1,1,0) n = 100 . .	38
3.14	Ranking Médio - Modelo ARIMA, série ARIMA(1,1,0) n = 100 . . . . .	39
3.15	Ranking Médio - Suavização Exponencial, série ARIMA(1,1,0) n = 1000 .	39
3.16	Ranking Médio - Modelo ARIMA, série ARIMA(1,1,0) n = 1000 . . . . .	40
3.17	Ranking Médio - Suavização Exponencial, série ARIMA(2,1,0) n = 1000 .	40
3.18	Ranking Médio - Modelo ARIMA, série ARIMA(2,1,0) n = 1000 . . . . .	41
3.19	Ranking Médio - Suavização Exponencial, série ARIMA(1,1,1) n = 1000 .	41
3.20	Ranking Médio - Modelo ARIMA, série ARIMA(1,1,1) n = 1000 . . . . .	42



# Lista de Tabelas

3.1	Valor ordinal do <i>ranking</i> médio para as Séries estacionárias . . . . .	37
3.2	Valor ordinal do <i>ranking</i> médio para as Séries não estacionárias . . . . .	42
4.1	Valores ordinais do <i>ranking</i> médio, resumo dos resultados obtidos . . . . .	43



# Sumário

<b>1</b>	<b>Introdução</b>	<b>21</b>
<b>2</b>	<b>Material e Métodos</b>	<b>23</b>
2.1	Séries temporais . . . . .	23
2.2	Algoritmos para predição de séries temporais . . . . .	23
2.3	Avaliação de performance de modelos preditivos . . . . .	24
2.4	Metodologias para Validação Cruzada . . . . .	25
2.4.1	Validação Cruzada <i>K-fold</i> (CV) . . . . .	25
2.4.2	<i>Out-Of-Sample Validation</i> (OOS) . . . . .	25
2.4.3	<i>Modified cross-validation</i> (ModCV) . . . . .	26
2.4.4	<i>Blocked cross-validation</i> (BCV) . . . . .	26
2.4.5	<i>HV-Blocked cross-validation</i> (hvBCV) . . . . .	27
2.4.6	<i>Markov cross-validation</i> (M-CV) . . . . .	27
<b>3</b>	<b>Aplicação</b>	<b>31</b>
3.1	Simulação de dados . . . . .	31
3.1.1	Séries Temporais Estacionárias . . . . .	31
3.1.2	Séries Temporais não Estacionárias . . . . .	37
<b>4</b>	<b>Conclusão</b>	<b>43</b>
	<b>Referências Bibliográficas</b>	<b>45</b>
<b>A</b>	<b>Códigos utilizados</b>	<b>47</b>



# Capítulo 1

## Introdução

Segundo [Izbicki e dos Santos \(2020\)](#), metodologias para predição surgiram há mais de dois séculos, possuindo na atualidade um papel central dentro da estatística. Na prática, é comum desenvolver diversos modelos a fim de buscar o que possui melhor poder preditivo, porém muitas vezes se corre o risco de realizar um sub-ajuste ou super-ajuste aos dados.

A fim de solucionar esse problema de sub ou super-ajuste de um modelo preditivo, foram desenvolvidas metodologias de validação-cruzada. Essas metodologias consistem basicamente em utilizar uma parte dos dados para treinar o modelo, enquanto o restante dos dados é utilizado para validar e testar a capacidade de generalização do modelo treinado. Contudo, quando o objetivo é realizar a predição de uma série temporal as metodologias padrões de validação-cruzada não podem ser aplicadas, uma vez que assumem que os dados são independentes e identicamente distribuídos.

Sendo assim, com o objetivo de conseguir comparar diversos modelos preditivos para séries temporais e testar a capacidade de generalização desses modelos, foram desenvolvidas algumas adaptações das metodologias de validação-cruzada. Neste trabalho, vamos estudar e comparar as metodologias *Modified cross-validation*, *Blocked cross-validation*, *HV-Blocked cross-validation* e *Markov cross-validation*, desenvolvidas por [McQuarrie e Tsai \(1998\)](#), [Snijders \(1988\)](#), [Racine \(2000\)](#) e [Jiang e Wang \(2017\)](#), respectivamente.

Para atender o objetivo de comparar as metodologias citadas, este trabalho está estruturado da seguinte maneira, no [Capítulo 2](#) é apresentado a definição de séries temporais, dois modelos usuais para realizar a predição desse tipo de dados, métricas para calcular a perda de um modelo preditivo e as metodologias de validação cruzada desenvolvidas para esse tipo de dado a fim de estimar a perda do modelo. No [Capítulo 3](#) utilizamos o método de Monte Carlo para realizar um comparativo das metodologias apresentadas

realizando diversas simulações de séries temporais diversas e ordenando os resultados por postos. Por fim, no Capítulo 4 apresentamos a conclusão desse trabalho.



# Capítulo 2

## Material e Métodos

### 2.1 Séries temporais

De acordo com [Morettin e Tolo \(2006\)](#), uma série temporal é um conjunto de observações, em que cada observação é coletada em um tempo específico  $t$ . Normalmente o parâmetro  $t$  representa o tempo em uma série temporal, porém pode ser qualquer parâmetro físico, como espaço, altura, volume, entre outros. Uma característica importante das séries temporais é que as observações adjacentes são dependentes. Neste trabalho, vamos denotar uma série temporal de tamanho  $n$  como  $Z = \{z_t\}, t = 1, \dots, n$ .

Se os valores de uma série temporal flutuam em torno de uma mesma média e possuem variância constante ao longo do período, ou seja, apresenta um equilíbrio estável, denominamos a série de estacionária. Caso contrário, dizemos que ela apresenta tendência. ([Morettin e Tolo \(2006\)](#))

Dizemos que uma série possui sazonalidade caso o comportamento que ocorre durante um tempo se repita a cada período idêntico de tempo, ou seja, dizemos que uma série possui comportamento sazonal com período  $s$ , caso ocorra similaridade a cada  $s$  observações.

### 2.2 Algoritmos para predição de séries temporais

Vamos utilizar nesse trabalho em suma dois modelos de predição para séries temporais, a suavização exponencial e o modelo ARIMA.

Conforme [Hyndman e Athanasopoulos \(2021\)](#), a suavização exponencial consiste em gerar as predições a partir de uma média ponderada das observações anteriores, no qual quanto mais recente for a observação maior será seu peso associado. Essa metodologia

tende a ser rápida e gera estimativas confiáveis para uma grande variedade de séries temporais, por isso é frequentemente utilizada.

Enquanto a metodologia de suavização exponencial é baseada na tendência e sazonalidade da série, o modelo ARIMA busca descrever as autocorrelações das observações. O modelo ARIMA é definido pelos parâmetros  $(p,d,q)$ , que correspondem a ordem da parte autoregressiva, grau de diferenciação necessária para tornar a série estacionária e a ordem da parte de média móvel, respectivamente.

## 2.3 Avaliação de performance de modelos preditivos

Um bom modelo de predição é aquele que realiza estimativas próximas do valor real da série, ou seja, com um erro pequeno. Conforme [Morettin e Tolo \(2006\)](#), podemos definir o erro de previsão  $h$  passos a frente no instante  $t$  como a diferença entre o valor real de série no instante  $t$  e a previsão deste valor feita  $h$  instantes antes disso.

$$\epsilon_h(t) = z_t - \hat{z}_{t-h}(h),$$

em que

- $\epsilon_h(t)$  é o erro de previsão  $h$  passos a frente no instante  $t$ ;
- $z_t$  corresponde ao valor real da série no instante  $t$ ;
- $\hat{z}_{t-h}(h)$  é a previsão do valor da série no instante  $t$  realizada  $h$  instantes antes disso.

Para avaliar o quão boas foram as predições de um algoritmo iremos utilizar o acurácia do erro de predição absoluto. ([Bergmeir et al., 2018](#))

$$APAE_m = \left| \frac{\hat{g}^m - L^m}{L^m} 100 \right|,$$

em que

- $\hat{g}^m$  é a perda estimada a partir do conjunto de treinamento com um modelo preditivo  $m$  e a metodologia  $g$ ;
- $L^m$  é a perda calculada a partir do conjunto de teste com um modelo preditivo  $m$ .

Utilizamos como função de perda o erro quadrático médio, que é dado pela fórmula abaixo.

$$MSE = \frac{1}{n} \sum_{t=1}^n (\epsilon_h(t))^2$$

## 2.4 Metodologias para Validação Cruzada

Conforme [Izbicki e dos Santos \(2020\)](#), se as métricas apresentadas na seção 2.3 forem utilizadas para seleção de modelos podem levar a um super-ajuste, uma vez que o algoritmo é construído de modo a ajustar bem a amostra  $Z = \{z_t\}, t = 1, \dots, n$ .

Para solucionar esse problema, foram desenvolvidas metodologias de validação cruzada. Essas metodologias visam avaliar a capacidade de generalização de um modelo de predição, verificando se existe um sub-ajuste ou super-ajuste aos dados utilizados para treino do algoritmo.

Uma das metodologias mais conhecidas de validação cruzada é a *k-fold*. Essa técnica é adequada quando podemos assumir que as observações são independentes e identicamente distribuídas (i.i.d.), logo não é ideal a aplicação em séries temporais.

Nesse trabalho vamos estudar e comparar algumas variantes da técnica de validação cruzada adequadas para séries temporais.

### 2.4.1 Validação Cruzada *K-fold* (CV)

Segundo [Izbicki e dos Santos \(2020\)](#), a metodologia consiste em primeiramente separar o conjunto de dados em  $k$  subconjuntos de aproximadamente o mesmo tamanho, posteriormente cada bloco é escolhido iterativamente para o teste. O modelo é treinado nos  $k-1$  subconjuntos, enquanto o subconjunto restante é utilizado para estimar o erro.

### 2.4.2 *Out-Of-Sample Validation* (OOS)

Seja  $Z_1, \dots, Z_N$  uma série temporal, a validação fora da amostra (OOS) consiste em dividir a base em duas partes, o período inicial  $Z_1, \dots, Z_k$  será utilizado para treinar o algoritmo de predição enquanto o segundo período  $Z_{k+1}, \dots, Z_N$  será utilizado para testar e validar as métricas de performance.



Figura 2.1: Técnica de validação fora da amostra

Para este trabalho utilizamos a proporção de 70% dos dados para o conjunto de treino e 30% para o conjunto de teste.

### 2.4.3 *Modified cross-validation* (ModCV)

O método ModCV desenvolvido por [McQuarrie e Tsai \(1998\)](#), também denominado de *non-dependent cross-validation* por [Bergmeir e Benítez \(2012\)](#), consiste em inicialmente embaralhar suas observações aleatoriamente e dividir em  $k$ -folds (lotes) de aproximadamente o mesmo tamanho, procedimento similar a validação cruzada  $k$ -fold. Posteriormente, são removidas as observações da base de treinamento que estejam dentro de uma determinada distância de tempo  $t$  das observações da base de teste, esse procedimento garante independência entre as bases de treino e teste. Usualmente, utiliza-se a ordem de autocorrelação da série ( $p$ ) como a distância de tempo para remover as observações.

Um ponto de atenção para utilização desse método é que dependendo da quantidade de *lags* e do número de  $k$ -folds utilizados, a remoção das observações dependentes pode levar a uma perda significativa de dados, podendo ocasionar um sub-ajuste do modelo.

### 2.4.4 *Blocked cross-validation* (BCV)

O método BCV proposto por [Snijders \(1988\)](#) é semelhante a validação cruzada  $k$ -fold, com a diferença de não realizar o embaralhamento inicial das observações.

Logo, a metodologia consiste em primeiramente separar o conjunto de dados em  $k$  subconjuntos de mesmo tamanho, posteriormente cada bloco é escolhido iterativamente para o teste. O modelo é treinado nos  $k-1$  subconjuntos, enquanto o subconjunto restante é utilizado para estimar o erro. [Bergmeir e Benítez \(2012\)](#) recomendam utilizar essa metodologia quando a série temporal que se deseja realizar a predição é estacionária.

### 2.4.5 *HV-Blocked cross-validation* (hvBCV)

O método hvBCV proposto por [Racine \(2000\)](#) é uma modificação do BCV apresentando na Seção 2.4.4, a fim de aumentar a independência entre as bases de treino e teste.

O procedimento também é similar à validação cruzada  $k$ -fold, não havendo o embaralhamento das observações, além disso são removidas as observações adjacentes entre as bases de treino e teste a fim de aumentar a independência entre as observações. Conforme [Cerqueira et al. \(2021\)](#), para cada interação deve-se retirar as  $p$  observações adjacentes entre as bases de treino e teste, onde  $p$  corresponde a ordem de autocorrelação da série temporal em estudo.

[Racine \(2000\)](#) demonstra que a partir do hvBCV a chance de selecionar o modelo com a melhor capacidade preditiva converge para 1 conforme o número total de observações se aproxima do infinito, ou seja, a metodologia é mais apropriada para séries temporais com grande número de observações.

### 2.4.6 *Markov cross-validation* (M-CV)

Segundo [Jiang e Wang \(2017\)](#), as adaptações da metodologia usual de validação cruzada apresentadas nas Seções 2.4.3, 2.4.4 e 2.4.5 não conseguem resolver os problemas de periodicidade, sobreposição e autocorrelação ao mesmo tempo. Visando atender a esses três critérios foi proposto o método M-CV, o procedimento consiste em primeiramente repartir a base de dados em alguns subconjuntos que representem a série original, posteriormente é aplicado a validação cruzada  $k$ -fold, com  $k$  igual a 2, em cada subconjunto.

Mais especificamente, dada um série temporal  $Z = \{z_t\}, t = 1, \dots, n$  com autocorrelação de ordem  $p$ , iremos primeiramente repartir os dados em dois subconjuntos ( $Z^+$  e  $Z^-$ ) a partir do algoritmo 1.

---

**Algoritmo 1** Interação de Markov
 

---

**Pré:** Série temporal  $Z = \{z_t\}, t = 1, \dots, n$ , com autocorrelação  $p$

**Pós:** O estado ( $d$ ) é iniciado aleatoriamente com algum dos casos:

$$d_1 = +1, d_2 = +1;$$

$$d_1 = +1, d_2 = -1;$$

$$d_1 = -1, d_2 = +1;$$

$$d_1 = -1, d_2 = -1;$$

**para**  $t = 3, \dots, n$  **faça**

**se**  $(d_{t-1} < 0) \& (d_{t-2} < 0)$  **então**

$$d_t = +1$$

**senão se**  $(d_{t-1} > 0) \& (d_{t-2} > 0)$  **então**

$$d_t = -1$$

**senão se**  $u > 0,5$  **então**

$$d_t = -1$$

**senão**

$$d_t = +1$$

**fim se**

**fim para**

---

Logo, podemos separar os dados nos dois subconjuntos seguindo a regra dada por

$$z_t \in \begin{cases} Z^+, & \text{se } d_t > 0 \\ Z^-, & \text{se } d_t < 0 \end{cases}$$

Posteriormente, cada subconjunto deve ser dividido em mais  $m$  subconjuntos, com  $m$  definido como

$$m = \begin{cases} 2p/3, & \text{se } p\%3 = 0 \\ 2\lfloor p/3 \rfloor + 2 & \text{caso contrário} \end{cases}$$

onde  $\%$  é a operação módulo e  $\lfloor \cdot \rfloor$  é a função piso. Essa segunda divisão em  $2m$  subgrupos é realizada a partir do seguinte critério:

$$Id_t = t\%m + 1 + I(d_t > 0)m, I(\cdot) \text{ é a função indicadora;}$$

$$Z_u = \{z_t | Id_t = u\}, u = 1, \dots, 2m.$$

Por último, devemos dividir cada subconjunto  $Z_u$  em mais dois grupos  $Z_{up}$  e  $Z_{ui}$  de

acordo com se a posição (número ordinal) da amostra for par ou ímpar, respectivamente. Completamos então o método M-CV aplicando a validação cruzada *2-fold* e cada  $2m$  subconjuntos, utilizando a separação definida de  $Z_{up}$  e  $Z_{ui}$ .





# Capítulo 3

## Aplicação

### 3.1 Simulação de dados

Neste capítulo realizamos primeiramente a simulação séries temporais diversas, esses dados serviram para um melhor entendimento e avaliação das metodologias apresentadas no Capítulo 2. Cada série temporal foi simulada com o intuito de assumir características diferentes das demais, alternando no tamanho amostral, tendência e/ou composição. Aplicamos as metodologias predição para séries temporais apresentadas na Seção 2.2 para cada uma das metodologias de Validação Cruzadas estudadas.

Utilizamos o método de Monte Carlo a fim de comparar as metodologias de validação cruzada, simulando um conjunto de mil séries para cada combinação de características diferentes. Para cada combinação de modelo preditivo e série temporal foram ordenadas de menor para maior (ranking) as metodologias de validação cruzada conforme a métrica APAE. Calculamos então o ranking médio e o desvio padrão para cada metodologia, obtendo um indicativo de qual metodologia é o melhor estimador da perda naquela representação.

#### 3.1.1 Séries Temporais Estacionárias

Séries simuladas:

- ARIMA( $p=0.7, d=0, q=0$ ), tamanho amostral  $n=50$  (100AR50);
- ARIMA( $p=0.7, d=0, q=0$ ), tamanho amostral  $n=100$  (100AR100);
- ARIMA( $p=0.7, d=0, q=0$ ), tamanho amostral  $n=1000$  (100AR1000);

- ARIMA( $p=0.7, d=0, q=0.7$ ), tamanho amostral  $n=1000$  (101AR1000);
- ARIMA( $p=[0.7, -0.7], d=0, q=0$ ), tamanho amostral  $n=1000$  (200AR1000);




Figura 3.1: Ranking Médio - Suavização Exponencial, série ARIMA(1,0,0)  $n = 50$




Figura 3.2: Ranking Médio - Modelo ARIMA, série ARIMA(1,0,0)  $n = 50$

Para ambos os modelos as metodologias BCV, CV, hvBCV e ModCV ficaram entre o melhor estimador do erro, enquanto o M-CV ficou como o pior e OOT como o segundo pior. Em geral com essas configurações de dados podemos dizer que o CV se saiu melhor.




Figura 3.3: Ranking Médio - Suavização Exponencial, série ARIMA(1,0,0)  $n = 100$




Figura 3.4: Ranking Médio - Modelo ARIMA, série ARIMA(1,0,0)  $n = 100$

Novamente, para ambos os modelos as metodologias BCV, CV, hvBCV e ModCV ficaram entre o melhor estimador do erro, porém alterou a ordem do pior e segundo pior. Em geral com essas configurações de dados podemos dizer que o CV empatou com BCV.




Figura 3.5: Ranking Médio - Suavização Exponencial, série ARIMA(1,0,0)  $n = 1000$




Figura 3.6: Ranking Médio - Modelo ARIMA, série ARIMA(1,0,0)  $n = 1000$

Para essa simulação as metodologias M-CV e OOT novamente ficaram novamente entre as piores, porém quando foi utilizado o modelo preditivo de Suavização Exponencial é possível observar que as metodologias ModCV e CV ficaram mais próximas ao M-CV e OOT do que BCV e hvBCV.




Figura 3.7: Ranking Médio - Suavização Exponencial, série ARIMA(2,0,0)  $n = 1000$




Figura 3.8: Ranking Médio - Modelo ARIMA, série ARIMA(2,0,0)  $n = 1000$

Nesse caso, simulando séries temporais com autocorrelação de ordem 2 e tamanho 1000, obtivemos resultados similares a simulação de séries temporais com autocorrelação ordem 1 e tamanho 100. As metodologias BCV, CV, hvBCV e ModCV ficaram entre o melhor estimador do erro, enquanto OOT e M-CV entre as piores.




Figura 3.9: Ranking Médio - Suavização Exponencial, série ARIMA(1,0,1)  $n = 1000$




Figura 3.10: Ranking Médio - Modelo ARIMA, série ARIMA(1,0,1)  $n = 1000$

Adicionando um componente de médias móveis nas séries temporais simuladas obtivemos resultados similares aos obtidos com as séries com tamanho 1000 e ordem de autocorrelação igual a 1, com as metodologias hvBCV e BCV se destacando com o modelo de Suavização Exponencial.

Agrupando os resultados pela média e ordenando as metodologias pelo *ranking*, é possível obter os seguintes resultados para as séries temporais estacionárias apresentados na Tabela 3.1.

Tabela 3.1: Valor ordinal do *ranking* médio para as Séries estacionárias

Dados	OOT	CV	ModCV	BCV	hvBCV	M-CV
Séries Estacionárias	6	4	3	1	2	5

### 3.1.2 Séries Temporais não Estacionárias

Séries simuladas:

- ARIMA( $p=0.7,d=1,q=0$ ), tamanho amostral  $n=50$  (110AR50);
- ARIMA( $p=0.7,d=1,q=0$ ), tamanho amostral  $n=100$  (110AR100);
- ARIMA( $p=0.7,d=1,q=0$ ), tamanho amostral  $n=1000$  (110AR1000);
- ARIMA( $p=0.7,d=1,q=0.7$ ), tamanho amostral  $n=1000$  (111AR1000);
- ARIMA( $p=[0.7,-0.7],d=1,q=0$ ), tamanho amostral  $n=1000$  (210AR1000);




Figura 3.11: Ranking Médio - Suavização Exponencial, série ARIMA(1,1,0)  $n = 50$




Figura 3.12: Ranking Médio - Modelo ARIMA, série ARIMA(1,1,0)  $n = 50$

Neste caso a metodologia BVC apresenta os melhores resultados, mesmo comparando com as metodologias CV, hvBCV e ModCV, as quais apresentaram valores próximos. As metodologias OOT e M-CV apresentaram os piores resultados entre as comparações, com a metodologia M-CV foi a última entre as comparações de ranking.




Figura 3.13: Ranking Médio - Suavização Exponencial, série ARIMA(1,1,0)  $n = 100$






Figura 3.14: Ranking Médio - Modelo ARIMA, série ARIMA(1,1,0)  $n = 100$

Analisando a Figura 3.13 e a Figura 3.14 é notório que obtivemos resultados semelhantes as simulações da série também de tamanho 100 e ordem de autocorrelação 1, porém sem tendência. Com as metodologias BCV, hvBCV, ModCV e Cv ficando próximas entre as melhores.




Figura 3.15: Ranking Médio - Suavização Exponencial, série ARIMA(1,1,0)  $n = 1000$




Figura 3.16: Ranking Médio - Modelo ARIMA, série ARIMA(1,1,0)  $n = 1000$

Similar com o que ocorreu nas Figuras 3.5 e 3.6, quando analisamos a estimação do risco com modelo preditivo de Suavização Exponencial é possível observar que as metodologias ModCV e CV ficaram mais próximas ao M-CV e OOT entre as piores do que as BCV e hvBCV.




Figura 3.17: Ranking Médio - Suavização Exponencial, série ARIMA(2,1,0)  $n = 1000$




Figura 3.18: Ranking Médio - Modelo ARIMA, série ARIMA(2,1,0)  $n = 1000$

Para ambos os modelos as metodologias BCV, CV, hvBCV e ModCV ficaram entre as melhores para estimador do erro preditivo, enquanto o OOT ficou como o pior e M-CV como o segundo pior.




Figura 3.19: Ranking Médio - Suavização Exponencial, série ARIMA(1,1,1)  $n = 1000$




Figura 3.20: Ranking Médio - Modelo ARIMA, série ARIMA(1,1,1)  $n = 1000$

Por último, simulando séries temporais ARIMA(1,1,1), obtivemos resultados similares a simulação de séries ARIMA(1,0,1), as metodologias hvBCV e BCV se destacando com o modelo de Suavização Exponencial. No geral para esse caso podemos dizer que a metodologia BCV se saiu melhor.

Agrupando as resultados pela média e ordenando as metodologias pelo *ranking*, é possível obter os seguintes resultados para as séries temporais não estacionárias apresentados na Tabela 3.2.

Tabela 3.2: Valor ordinal do *ranking* médio para as Séries não estacionárias

Dados	OOT	CV	ModCV	BCV	hvBCV	M-CV
Séries não Estacionárias	6	4	2	1	3	5

# Capítulo 4

## Conclusão

Nesse trabalho estudamos e comparamos diferentes metodologias de validação cruzada desenvolvidas para dados onde não é verdadeira a suposição de independência das observações. Analisamos em específico como essas metodologias se comportam em diferentes séries temporais e a habilidade de estimar a perda dado um modelo preditivo usual para esse tipo de dados (ARIMA e Suavização Exponencial).

Agrupando as análises apresentadas no Capítulo 3 pela média e ordenando as metodologias pelo *ranking*, é possível obter os seguintes resultados apresentados na Tabela 4.1.

Tabela 4.1: Valores ordinais do *ranking* médio, resumo dos resultados obtidos

Dados	OOT	CV	ModCV	BCV	hvBCV	M-CV
Séries Estacionárias	6	4	3	1	2	5
Séries não Estacionárias	6	4	2	1	3	5
Total	6	4	2	1	3	5

Analisando a Tabela 4.1, é possível observar que a metodologia *Blocked cross-validation* foi a melhor para estimar a perda dado um modelo preditivo usual nas condições testadas no estudo, tanto para séries estacionárias quanto não estacionárias. A segunda melhor metodologia foi a *Modified cross-validation*, demonstrando que para esses casos de estudos apresentados metodologias menos complexas se saíram melhor que as demais, sendo elas simples modificações do método de validação cruzada *k-fold* comumente usando com modelos de aprendizado de máquina. No geral as metodologias desenvolvidas especificamente para séries temporais realmente se saíram melhores que metodologia de validação cruzada usual.

A metodologia apresentada por [Jiang e Wang \(2017\)](#) acabou tendo resultados parecidos da validação fora da amostra (OOS) também comumente utilizada, seria interessante realizar simulações de mais séries alterando seus devidos comportamentos a fim de testar mais essa metodologia.

Para estudos futuros, seria interessante realizar mais comparações com diferentes tipos de séries temporais, alterando mais o tamanho amostral dos dados e a ordem de autocorrelação da série. Além disso, pode-se testar o comportamento dessas metodologias em diferentes tipos de modelos preditivos, como por exemplo modelos de aprendizado de máquina.

# Referências Bibliográficas

- Bergmeir, C. e Benítez, J. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, **191**, 192–213.
- Bergmeir, C. e Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, **191**, 192–213. Data Mining for Software Trustworthiness.
- Bergmeir, C., Hyndman, R. J. e Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics Data Analysis*, **120**, 70–83.
- Cerqueira, V., Torgo, L. e Soares, C. (2021). Model selection for time series forecasting: Empirical analysis of different estimators.
- Hyndman, R. J. e Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*, volume 3rd edition. OTexts: Melbourne, Australia.
- Izbicki, R. e dos Santos, T. M. (2020). *Aprendizado de máquina: uma abordagem estatística*. ISBN 978-65-00-02410-4.
- Jiang, G. e Wang, W. (2017). Markov cross-validation for time series model evaluations. *Information Sciences*, **375**, 219–233.
- McQuarrie, A. D. R. e Tsai, C.-L. (1998). *Regression and time series model selection*. World Scientific.
- Morettin, P. A. e Toloi, C. M. (2006). *Análise de Series Temporais*. ABE- Projeto Fisher e Editora Blucher.
- Racine, J. (2000). Consistent cross-validators model-selection for dependent data: hv-block cross-validation. *Journal of Econometrics* 99 (2000) 39-61.

Snijders, T. A. B. (1988). On cross-validation for predictor evaluation in time series. Em T. K. Dijkstra, editor, *On Model Uncertainty and its Statistical Implications*, páginas 56–69, Berlin, Heidelberg. Springer Berlin Heidelberg. ISBN 978-3-642-61564-1.



# Apêndice A

## Códigos utilizados

Os códigos utilizados nesse trabalho estão disponíveis em

<https://github.com/DanielSimionato/tcc>