

# Modelos ARIMA, SARIMA e Método de Seleção de Variáveis do tipo LASSO para Séries Temporais

Gladys Choque Ulloa<sup>1</sup>

<sup>1</sup>Universidade Federal do Rio Grande do Sul.  
Instituto de Matemática e Estatística.

20 novembro 2022

# Conteúdo

- 1 Introdução
- 2 Metodología
- 3 Aplicação
- 4 Discussão
- 5 Referências

- 1 Introdução
- 2 Metodología
- 3 Aplicação
- 4 Discussão
- 5 Referências

- Uma série temporal é uma sucessão de dados medidos em determinados momentos e organizados cronologicamente.
- Os dados podem ser espaçados em intervalos iguais (como a temperatura em um observatório meteorológico em dias sucessivos ao meio-dia) ou desiguais (como o peso de uma pessoa em medições sucessivas no consultório médico, farmácia, etc.).
- Para a análise de séries temporais, são utilizados métodos que ajudam a interpretá-las e que permitem extrair informações representativas sobre as relações subjacentes entre os dados da série ou de diferentes séries e que permitem, em diferentes graus e com diferentes níveis de confiança, extrapolar ou interpolar os dados e assim prever o comportamento da série em tempos não observados, seja no futuro (extrapolação de previsão), no passado (extrapolação para trás) ou em tempos intermediários (interpolação).

- As séries temporais são estudadas em estatística, processamento de sinais, econometria e muitas outras áreas.
- Os modelos ARIMA e SARIMA são métodos usados para a análise de uma série temporal, onde cada um dos parâmetros dos modelos são usados para análise de dados.
- O método da seleção do melhor subconjunto de covariáveis se baseia em ajustar todos os modelos com  $k$  covariáveis e posteriormente escolher o melhor dentre eles com base em algum critério.

# Conteúdo

- 1 Introdução
- 2 Metodología**
- 3 Aplicação
- 4 Discussão
- 5 Referências

# Modelo ARMA ( $p, q$ )

- Os modelos Autorregressivos de Média Móvel, ou modelos ARMA (também chamados de modelos Box-Jenkins) são considerados modelos clássicos de séries temporais.

Uma série temporal é um modelo ARMA( $p, q$ ) se satisfizer;

$$X_t = \sum_{i=1}^p \phi_i X_{t-i} + \sum_{j=1}^q \theta_j a_{t-j} + a_t \quad (1)$$

onde  $\phi_1, \dots, \phi_p$  são os parâmetros da parte AR,  $\theta_1, \dots, \theta_q$  são os parâmetros da parte MA e  $a_t$  é um ruído branco.

O modelo ARMA é uma ferramenta para prever valores futuros da série, e esta composto de duas partes, uma parte autoregressiva (AR) e uma parte de média móvel (MA).

# Modelo ARIMA $(p, d, q)$

- Uma série temporal  $Y_t$  segue um modelo de autoregressiva de médias móveis integrada, se a  $d$ -ésima diferença  $W_t = \Delta^d Y_t$  é um processo ARMA estacionário. Se  $\{W_t\}$  segue um modelo ARMA  $(p, q)$ , dizemos que  $Y_t$  é um processo ARIMA  $(p, d, q)$ . Para fins práticos, geralmente podemos tomar  $d = 1$  ou no máximo 2. Suponha o seguinte modelo ARMA  $(p, q)$ :

$$\Theta_p(L)Y_t = \Theta_q(L)a_t \quad (2)$$

onde o polinômio AR pode ser fatorado em termos de suas  $p$  raízes  $L_1, \dots, L_p$

$$\Theta_p(L) = (1 - L_1^{-1}L)(1 - L_2^{-1}L) \cdots (1 - L_p^{-1}L) \quad (3)$$



## a) Identificação.

O primeiro passo desta fase é a análise gráfica dos dados com intuito de identificar e eliminar possíveis sazonalidades, presença de tendência determinística ou estocástica.

## b) Estimação.

Após a escolha de um candidato, passamos para a estimativa dos parâmetros do modelo, isto é,  $(\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q)$ .

## c) Análise residual.

Nesta etapa utilizamos vários testes e gráficos para diagnosticar o ajuste do modelo proposto aos dados.

## d) Predição.

Uma vez que concluímos que o modelo proposto se ajusta de forma adequada aos dados satisfazendo os pressupostos teóricos esperados, podemos obter previsões dentro e fora da amostra para o problema estudado.

- O modelo SARIMA  $(p, d, q) \times (P, D, Q)$  é definido como;

$$\Phi_p(B^s)\phi_p(B)\nabla_s^D\nabla^d X_t = \Theta_Q(B^s)\theta_q(B)\epsilon_t \quad (4)$$

Onde;

- Generaliza todos os modelos da família ARIMA
- Permite modelar séries estacionárias, bem como séries sazonais e não estacionárias, bem com séries sazonais e não sazonais.

Em um modelo ARIMA, os termos estão incluídos autoregressivos ( $p$ ), diferenciação da variável ( $d$ ) e termos de média móvel ( $q$ ). No entanto, o modelo SARIMA inclui termos sazonais autorregressivos ( $P$ ), diferenciação sazonal ( $D$ ) e média móvel sazonal ( $Q$ ), ou seja, o SARIMA contém fatores sazonais e não sazonais em um modelo multiplicativo (Dritsaki, 2016:137).

- O estimador via LASSO no contexto da regressão linear é dado pela resolução do problema

$$\hat{\beta}_L = \operatorname{argmin} \left\{ \sum_{i=1}^n (Y_i - X_i \beta)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}, \quad \lambda \geq 0, \quad (5)$$

em que  $\lambda$  é um valor que deve ser escolhido previamente. Note que, se  $\lambda = 0$ , então o estimador via LASSO será igual ao estimador via mínimos quadrados, isto é, o estimador de mínimos quadrados de  $\beta$  pode ser visto como um caso particular do estimador via LASSO.

# Conteúdo

- 1 Introdução
- 2 Metodología
- 3 Aplicação**
- 4 Discussão
- 5 Referências

- Para parte aplicativa foi usado o banco de dados do Instituto Nacional de Meteorologia do Ministério da Agricultura, Pecuária e Abastecimento, do estado do Rio Grande do Sul, Brasil, no período de 2018-2021. Primeiramente faremos um ajuste dos modelos ARIMA e SARIMA e depois aplicaremos um método de seleção de variáveis com o LASSO.

# Ajuste do Modelo ARIMA

- Neste caso seguiremos os passos para modelagem de um Modelo ARIMA, esta metodologia é conhecida também como Box Jenkins. Vamos começar fazendo o análise exploratório de nossos dados, temos ás variáveis "Precipitação", "Pressão", "Temporvalho", "MaxTemp", "MeanTemp", "MinTemp", "UMIDADE", "UmidadeMin", "MaxVento" e "MeanVento".




Figura: Séries Temporais das Variáveis de estudo.




Figura: Séries Temporais das Variáveis de estudo.

- O gráfico apresenta o quão bem o modelo se ajusta aos dados. Nota-se por meio da figura que os resíduos apresentam uma distribuição aleatória sem apresentar tendência. Portanto, os resíduos são ruído branco, verificado através do teste de  $Ljung - Box = 0.346$  e com  $AIC = 6088.59$ , na análise gráfica que os resíduos se distribuem de forma homogênea.




Figura: Gráfica de Previsão com o modelo Sarima.



# Ajuste de uma Regressão com o LASSO

O processo para realizar um ajuste de Lasso e identificar o melhor valor lambda e o procedimento é equivalente ao caso Ridge. Para fazer esse ajuste usaremos a função `glmnet()` onde `alfa=1`.

Para a análise, primeiro precisamos de dois arquivos "Train" e "Teste1" do nosso banco de dados, onde suas dimensões devem ser iguais.

Na saída do R a quantidade dos Modelos gerados com o LASSO são 69 com 10 variáveis.




Figura: Gráfico dos valores de  $\lambda$ .




Figura: Gráfico do valor de  $\lambda$ .

Vemos no gráfico acima que o valor de melhor  $\lambda = -4.836514$  está entre esse intervalo das linhas pontilhadas.

Após de fazer a previsão com o melhor  $\lambda$  e obter os coeficientes do modelo, podemos observar que as variáveis que mais contribuem para o modelo são Precip, Pressao, TempOrvalho, MaxTemp, MinTemp, Umidade, MaxVento e o Intercept.

Obtivemos um  $RMSE = 0.2739275$ , o que indica que é o melhor ajuste para nosso modelo.

# Conteúdo

- 1 Introdução
- 2 Metodología
- 3 Aplicação
- 4 Discussão**
- 5 Referências

- Os modelos ARIMA e SARIMA são uma classe de modelos de Séries Temporais, que são geralmente usados para a análise de previsão.
- O modelo ARIMA é um método estatístico "clássico" para análise de séries temporais: detecção, previsão e previsão de anomalias. Para diversificar a sua utilização (por exemplo, trabalhar em tempo real) pode ser combinada com outras técnicas.
- Verificou-se que supera métodos mais complexos (ML) na previsão de dados univariados. Portanto, recomenda-se usá-lo como linha de base para demonstrar que a complexidade agregada por esses métodos agrega valor.

# Conteúdo

- 1 Introdução
- 2 Metodología
- 3 Aplicação
- 4 Discussão
- 5 Referências**

- Rodrigues, K. A. (2018). LASSO Clássico e Bayesiano. Instituto de Matemática e Estatística, Universidade de São Paulo, Brasil.
- LUCAS, J. L. (2013). Modelos de Series Temporais para Previsão da Demanda. Faculdade de Economia, Administração, Atúaria, Contabilidade e Secretariado Executivo, Brasil.
- Miranda, C. d. (2001). Modelação Linear de Séries Temporais na presença de . Departamento de Matemática Aplicada, Faculdade de Ciências da Universidade do Porto, Brasil.
- Konzen, E. (2014). Penalizações Tipo Lasso na Seleção de Covariáveis em Séries Temporais. Departamento de Economia, Universidade Federal do Rio Grande do Sul, Brasil.
- Freitas, A. A. (2007). Previsão de Séries Temporais via Seleção de Variáveis, Reconstrução Dinâmica, ARMA-GARCH e Redes Neurais Artificiais. Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Brasil.
- Valipour, M. (2015). Long-term runoff study using SARIMA and ARIMA models in the United States. Meteorological Applications, 22(3), 592-598.

- Tseng, F. M., Yu, H. C., & Tzeng, G. H. (2002). Combining neural network model with seasonal time series ARIMA model. *Technological forecasting and social change*, 69(1), 71-87.
- Otu, O. A., Osuji, G. A., Opara, J., Mbachu, H. I., & Iheagwara, A. I. (2014). Application of Sarima models in modelling and forecasting Nigeria's inflation rates. *American Journal of Applied Mathematics and Statistics*, 2(1), 16-28.
- Kajuru, J. Y., Abdulkarim, K., & Muhammed, M. M. (2019). Forecasting Performance of ARIMA and Sarima Models on Monthly Average Temperature of Zaria, Nigeria. *ATBU Journal of Science, Technology and Education*, 7(3), 205-212.
- Sun, K., Huang, S. H., Wong, D. S. H., & Jang, S. S. (2016). Design and application of a variable selection method for multilayer perceptron neural network with LASSO. *IEEE transactions on neural networks and learning systems*, 28(6), 1386-1396.
- Yan, Z., & Yao, Y. (2015). Variable selection method for fault isolation using least absolute shrinkage and selection operator (LASSO). *Chemometrics and Intelligent Laboratory Systems*, 146, 136-146.
- Ranstam, J., & Cook, J. A. (2018). LASSO regression. *Journal of British Surgery*, 105(10), 1348-1348.