

VI-100 - ANÁLISE COMPARATIVA ENTRE MODELOS DE SÉRIES TEMPORAIS PARA MODELAGEM DA TEMPERATURA MÉDIA MENSAL DO AR NO MUNICÍPIO DE SANTA TERESA - ES

Irinete Otto Pilger⁽¹⁾

Graduanda em Engenharia Ambiental e Sanitária na Faculdade da Região Serrana – FARESE.

Wanderson de Paula Pinto⁽²⁾

Graduado em Matemática pela Faculdade da Região Serrana - FARESE. Mestre em Engenharia Ambiental pela Universidade Federal do Espírito Santo (UFES). Doutorando em Engenharia Ambiental no Programa de Pós-Graduação em Engenharia Ambiental da Universidade Federal do Espírito Santo (PPGEA/UFES). Professor do Curso de Engenharia Ambiental da FARESE.

Gemael Barbosa Lima⁽³⁾

Engenheiro Ambiental pela FAESA - Faculdades Integradas Espírito-Santenses. Mestre em Engenharia Ambiental pela Universidade Federal do Espírito Santo (UFES). Professor do Curso de Engenharia Ambiental da FARESE e do Centro Universitário do Espírito Santo - UNESC.

Endereço⁽¹⁾: Rua Jequitibá, 121 - Centro - Santa Maria de Jetibá – ES – CEP: 29645-000 - Brasil - Tel: (27) 3263-2010 - e-mail: irinete_op@hotmail.com

RESUMO

Uma série temporal, também denominada série histórica, é uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico. O presente trabalho apresenta uma análise de séries temporais dos dados de temperaturas médias mensais do ar da cidade de Santa Teresa, ES, compreendendo o período de janeiro de 2007 a dezembro de 2015, totalizando uma série com 108 observações. O objetivo do trabalho foi extrair periodicidades e observações, descrever o comportamento da série e realizar previsões. A metodologia utilizada foi baseada na proposta de Box e Jenkins e o software utilizado foi o Software Livre R(R Development Core Team, 2015). Para escolha do modelo mais adequado foram analisados os critérios AIC, BIC, EQM e EAM. Para fins de comparação realizou a previsão de dois modelos: o modelo ARIMA (0,0,3) e o modelo SARIMA (0,0,3)X(2,1,0), onde o modelo SARIMA foi considerado o mais adequado para fazer previsão da temperatura.

PALAVRAS-CHAVE: Séries temporais, modelagem matemática, temperatura média, ARIMA, SARIMA.

INTRODUÇÃO

O clima é estabelecido através de conjunto de condições climáticas, sendo elas: temperatura, umidade, pressão, vento, chuva e altitude, as quais variam de acordo com as características de cada local. A partir de todos os dados das condições climáticas é possível prever fenômenos e condições meteorológicas. A habilidade de antecipar como o clima irá mudar de um ano para o outro, possibilita melhor gerenciamento da agricultura, recursos hídricos e atividade pesqueira, além da possibilidade de contribuição relevante nos campos dos transportes, abastecimento, turismo e lazer (SILVA; GUIMARÃES e TAVARES, 2008).

Segundo Ayoade (2006), a condição climática temperatura representa a intensidade do fluxo de calor que passa de um corpo ou massa de ar de maior temperatura para outro de menor temperatura. Esta possui papel fundamental no ciclo hídrico, onde, as altas temperaturas contribuem com que a água contida na superfície terrestre evapore e as baixas temperaturas permitem que o vapor de água se condense e retorne sobre a forma de chuva. A medição da temperatura atmosférica é realizada por dois tipos de termômetro: o de máximas e o de mínimas. A partir desses registros é possível calcular as temperaturas médias e amplitudes térmicas, podendo ser realizados para o intervalo de tempo de um dia, um mês ou um ano.

Para realizar uma previsão de temperatura pode-se usar como ferramenta a metodologia de séries temporais. Uma série temporal é caracterizada como uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico. Esta série temporal pode ser obtida através de observações periódicas do evento de interesse (LATORRE MARIA et al, 2001). A análise de séries temporais consiste em encontrar relações de dependências existentes temporalmente nos dados buscando identificar o mecanismo gerador da

série, com o objetivo de extrair periodicidades relevantes nas observações, descrever seu comportamento e fazer previsões (BAYER e SOUZA, 2010).

Aplicada a fatores climatológicos, a análise de séries temporais atrai especial interesse, pois é inegável que tais fatores exercem papel significativo no sucesso ou fracasso de muitos empreendimentos. Modelos estatísticos têm sido utilizados de maneira satisfatória nas áreas agrícolas. Hubbard (2007) destaca a importância das análises em climatologia agrícola sobre amplos aspectos da agricultura e pecuária. Segundo Ayoade (2006) o clima, devido a sua imprevisibilidade, é o fator de produção agrícola de mais difícil controle e de maior impacto quando se deseja a obtenção de máximas produtividades de uma determinada cultura. Logo, as adversidades climáticas podem ser a causa de um baixo rendimento na lavoura. Segundo Medeiros et al (2005) na área agrícola a temperatura do ar tem influência direta em muitos efeitos fisiológicos que ocorrem nas plantas e animais, tornando essencial o desenvolvimento de estudos desses fenômenos para a tomada de decisão.

A partir da análise de séries temporais agrícolas ou climatológicas é possível o ajuste de modelos estatísticos univariados de previsão (CHECHI e BAYER, 2012).

Silva, Guimarães e Tavares (2008) realizaram a previsão da temperatura média mensal de Uberlândia – MG, com modelos de séries temporais. O estudo teve como objetivo descrever o comportamento da série por meio do seu modelo de decomposição, verificando a existência dos componentes tendência e sazonalidade, e por fim identificar e estimar modelos de previsão e realizar previsões de temperatura para períodos subsequentes utilizando esses modelos. Os autores puderam identificar por meio de análise da série temporal, a presença de tendência e sazonalidade. Desta forma, os mesmos, ajustaram modelos do tipo SARIMA, onde por meio dos critérios AIC (Akaike Information Criterion), BIC (Bayesian Information Criterion) e MSE (Mean Square Error) selecionaram o modelo que melhor se ajustou à série em estudo: o modelo SARIMA (3,1,0)(0,1,1), para fins de previsão.

Amorim (2012) utilizou modelos de séries temporais da classe ARIMA para modelar dados da temperatura máxima da cidade de Campina Grande – PB referente ao período de 2002 a 2010. O objetivo do trabalho foi caracterizar a série temporal, escolher o modelo que melhor se aplica à série e a partir deste, prever valores de temperatura máxima. O autor identificou a presença de tendência e sazonalidade da série de temperatura, caracterizando o modelo como ARIMA sazonal. A escolha do melhor modelo se deu pelo critério BIC, onde obteve-se como resultado o modelo ARIMA (1,0,0)(2,0,0) como o mais adequado. A utilização de gráficos na análise estatística por parte do autor, permitiu uma maior compreensão do comportamento da temperatura máxima da cidade em estudo.

Chechi e Bayer (2012) utilizaram modelos univariados de séries temporais para previsão das temperaturas médias mensais de Erechim – RS, no período de janeiro de 2003 a março de 2011. Este estudo se deu por meio da comparação entre modelos da classe ARIMA (SARIMA) e modelos de alisamento exponencial (Holt-Winters aditivo). Os autores compararam modelos de previsão para diferentes horizontes de previsão, sendo que os modelos que se mostraram mais acurados foram os da classe ARIMA, mostrando-se adequados para traçar previsões das variáveis de temperatura do ar, e importantes ferramentas para a climatologia agrícola.

Teixeira-Gandra et al. (2014) realizaram a previsão das temperaturas para a cidade de Pelotas – RS, por modelos autorregressivos das séries de temperatura médias mínima, máxima e média anual, no período de 1931 a 2011. Os autores utilizaram os testes de Cox-Stuart, Wald-Wolfowitz, Spearman e Mann-Kendall, para caracterizar a série quanto a existência de tendência. Dentre os modelos ARIMA desenvolvidos, o mais adequado foi selecionado pelo teste de Porteau Monteau. O teste de Spearman foi considerado o mais robusto para detectar tendências em séries temporais, o que permitiu observar um acréscimo de 1,12°C nas temperaturas médias mínimas anuais da cidade em estudo. As temperaturas médias mínimas anuais da cidade de Pelotas podem ser previstas por modelos autorregressivos – AR, cuja inclusão de outro parâmetro regressivo não apresentou ganho de informação na previsão das mesmas.

Diante do exposto, este trabalho teve por objetivo caracterizar a série temporal em estudo e realizar a predição e a previsão de temperaturas médias mensais para a cidade de Santa Teresa, ES, utilizando modelos de séries temporais, bem como comparar os modelos ARIMA e SARIMA para verificar qual dos modelos apresenta maior acurácia na previsão de dados.

MATERIAIS E MÉTODOS

Dados e caracterização da área de estudo

Os dados de temperatura média mensal analisados integram o banco de dados do Instituto Capixaba de Pesquisa, Assistência Técnica e Extensão Rural (INCAPER), localizado no município de Santa Teresa. O período de estudo corresponde de janeiro de 2007 a dezembro de 2015, totalizando uma série temporal de 108 observações.

A cidade de Santa Teresa está localizada na região Serrana do Estado do Espírito Santo, coordenadas geográficas 19° 56' 09" S e 40° 36' 00" O, com distância de 78 km da capital Vitória. Situado na meso-região Central Espírito-Santense – Estado do Espírito Santo, o município de Santa Teresa apresenta limites ao norte com o município de São Roque do Canaã, a oeste com Itaguaçu e Itarana, a leste com João Neiva, Ibirapuçu e Fundão, e ao sul com Santa Leopoldina e Santa Maria de Jetibá.

A 675 m de altitude apresenta clima tropical de altitude, identificado do tipo Cwb, de acordo com a classificação de Köppen, caracterizado por ser encontrado em regiões tropicais de áreas montanhosas, com inverno seco e verão ameno. A pluviosidade média anual da cidade fica em torno de 1345mm, sendo novembro o mês mais chuvoso e junho e julho os meses mais secos. A temperatura média mensal se encontra em torno de 20°C.

Modelos

Os modelos utilizados foram o da classe ARIMA, seja Z_t ($t=1,2,3,\dots$) sendo este um processo que satisfaz a equação 1:

$$\phi_p(B)Z_t = \theta_q(B)\epsilon_t, \quad (1)$$

em que ϵ_t é ruído branco (RB), definido como uma variável aleatória não correlacionada com média zero e variância constante ao longo do tempo (WEI, 2006), isto é., $\epsilon_t \sim RB(0, \sigma_\epsilon^2)$, $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$, $\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ e B é o operador da defasagem definido como $B^k Z_t = Z_{t-k}$. O processo Z_t definido anteriormente é chamado de processo autorregressivo e de médias móveis de ordens (p,q) , abreviado por $ARMA(p,q)$.

Este processo é estacionário e invertível se as raízes de $\phi_p(B)$ e $\theta_q(B)$ não são comuns e encontram-se fora do círculo unitário. Para maiores detalhes consultar em Pinto, Lima e Zanetti (2015), Wei (2006), entre outros.

Em séries não estacionárias é necessário aplicar o procedimento de diferenciação da série. Se a série torna-se estacionária após d diferenças a série é dita ser integrada de ordem d . Sendo assim, o modelo $ARMA$ integrado passa a ser denominado de modelo $ARIMA$. Uma série temporal Z_t é dita um processo $ARIMA(p,d,q)$ se,

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)\epsilon_t, \quad \epsilon_t \sim RB(0, \sigma_\epsilon^2) \quad (2)$$

Portanto, Z_t é processo não estacionário que depois de diferenciado $\nabla^d Z_t$ ($d \geq 1$) se transforma em processo estacionário invertível $ARMA(p,d)$.

As séries que apresentam a característica de sazonalidade, utilizam para estudo o modelo $SARIMA(p,d,q) \times (P,D,Q)_s$. Seja $Z_t = \{Z_t; t \in \mathbb{Z}\}$ com representação dada por:

$$\Phi(B^s)\phi(B)\nabla^d Z_t = \Theta(B^s)\theta(B)\epsilon_t, \quad (3)$$

em que s é chamado de período sazonal do processo. O operador, ∇^d em que $\mathbf{d} = (d,D)$ e d,D são números inteiros não negativos e representam o número de diferenças simples e sazonais, respectivamente, aplicadas sobre o processo Z_t , é definido por:

$$\nabla^d = (1-B)^d (1-B^s)^D \quad (4)$$

Temos que $\Phi(z^s) = 1 - \sum_{i=1}^P \Phi_i z^{is}$, $\phi(z) = 1 - \sum_{j=1}^p \phi_j z^j$, $\Theta(z^s) = 1 - \sum_{k=1}^Q \Theta_k z^{ks}$ e $\theta(z) = 1 - \sum_{l=1}^q \theta_l z^l$ são polinômios de ordem P , p , Q , $q \in \mathbb{N}$, respectivamente, com $z \in \mathbb{C}$, em que, \mathbb{C} representa o conjunto dos números complexos e $\{\Phi_i\}, \{\phi_j\}, \{\Theta_k\}, \{\theta_l\}$ são sequências de números reais. Para detalhes ver, Pinto, Lima e Zanetti (2015), Wei (2006), entre outros.

Metodologia de modelagem

A metodologia utilizada foi a de Box e Jenkins, a qual consiste nas seguintes etapas: (i) identificação do modelo; (ii) estimação dos parâmetros, (iii) diagnóstico do modelo ajustado, e, (iv) previsão.

Para identificar o modelo mais adequado dentre vários modelos descritos é analisado o comportamento das funções de autocorrelações (ACF) e das funções de autocorrelações parciais (PACF). A estimação dos parâmetros do modelo proposto é realizado pelo cálculo dos parâmetros ϕ e Φ do componente auto-regressivo, θ e Θ do componente de médias móveis e a variância de ε_t . Para verificar se o modelo estimado é adequado para descrever o comportamento dos dados realiza-se uma análise dos resíduos e estima-se os critérios AIC (Akaike Information Criterion), BIC (Bayesian Information Criterion), EQM (Erro Quadrático Médio) e EAM (Erro Absoluto Médio).

Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. Quando se obtém um modelo satisfatório, passa-se para a última etapa da metodologia de Box-Jenkins, que constitui o objetivo principal da metodologia: realizar previsões.

A realização de previsões é o cálculo do valor esperado de uma observação condicionada às valores passados e ao valor presente da variável, dada pela função:

$$\hat{Z}_t(h) = E(Z_{(t+h)} | Z_t, Z_{(t-1)}, \dots) \quad (5)$$

em que $\hat{Z}_t(h)$ é o valor estimado da variável Z_t no horizonte h períodos de tempos futuros com base em t observações passadas. O valor de Z_{t+h} é calculado com o modelo que melhor se ajusta aos dados.

O desenvolvimento deste trabalho se deu através do emprego do Software Livre R (R Development Core Team, 2015). Este software é utilizado para cálculos estatísticos, análise de dados simulações e gráficos. O R é um ambiente disponibilizado sobre os termos da GNU (General Public License e sua página principal é [HTTP://www.r-project.org](http://www.r-project.org). (REISEN e SILVA, 2011).

RESULTADOS

A Tabela 1 apresenta uma análise descritiva dos dados, onde se verifica o comportamento das temperaturas médias mensais no decorrer de nove anos (Janeiro de 2007 a Dezembro de 2015). A temperatura média no período foi de 18,478104, com variância de 4,287673 e desvio padrão 2,070670. A assimetria e curtose apresentaram valores de, respectivamente, 0,068522 e -1,282336, indicando uma baixa assimetria à direita, e distribuição com caudas leves e pico mais achatado que a distribuição normal. Verifica-se que a menor temperatura mensal se encontra em torno de 14,60°C, enquanto que a maior temperatura mensal esta em torno de 22,30°C.

Tabela 1: Medidas descritivas da variável temperatura

Estatística	Resultado
Média	18,478704
Mediana	18,500000
Variância	4,287673
Desvio Padrão	2,070670
Assimetria	0,068522
Curtose	-1,282336
Mínimo	14,600000
Máximo	22,300000

Com a análise das Figuras 1 e 2, percebe-se visualmente o comportamento da série em estudo. A série temporal (Figura 1) demonstra um padrão de variabilidade, observado também na função de autocorrelação (ACF) e da função de autocorrelação parcial (PACF) (Figura 2), o que indica a característica de sazonalidade.

Tal propriedade foi confirmada pela Figura 3, indicando que o modelo a ser utilizado é da classe SARIMA. Percebe-se ainda que a série é estacionária na média. A estacionariedade na média foi confirmada com o teste de Dickey-Fuller (ADF) (DICKEY e FULLER, 1981).

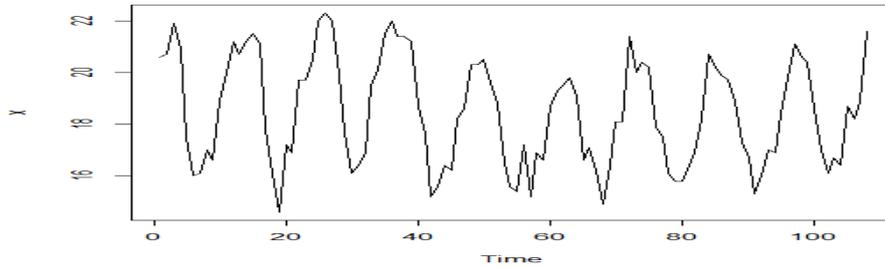


Figura 1: Gráfico da série de temperatura das médias mensais.

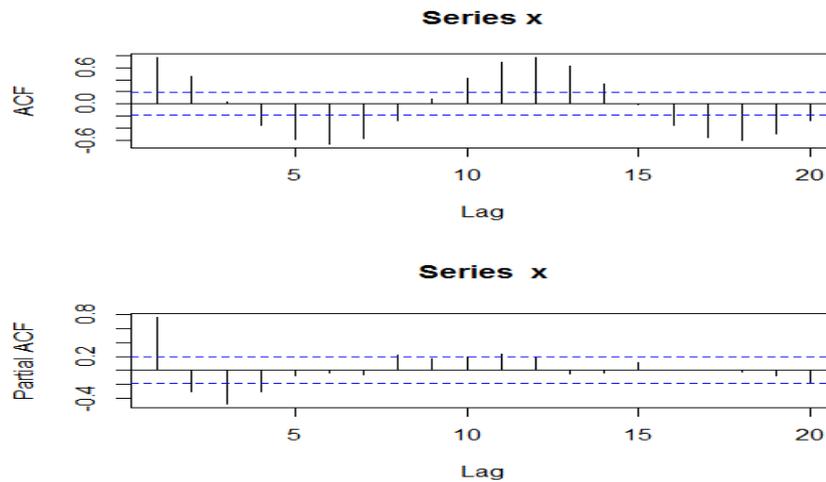


Figura 2: Funções amostrais de autocorrelação (ACF) e autocorrelação parcial (PACF)

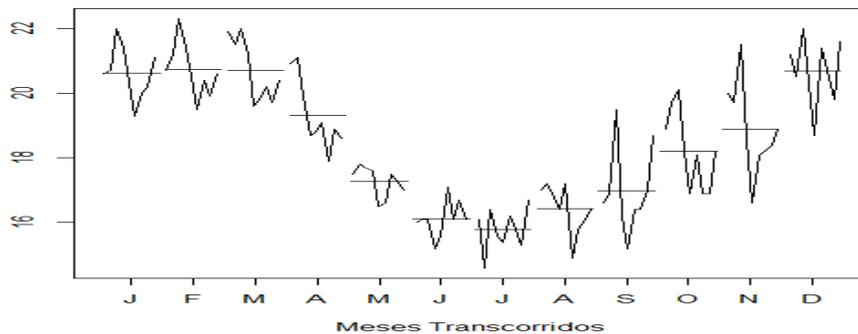


Figura 3: Análise gráfica da sazonalidade da série em estudo.

Após se caracterizar a série em estudo, foi realizada a etapa de identificação do modelo, a qual consiste em determinar os valores de $(p,d,q) \times (P,D,Q)$ (devido a sazonalidade da série). Como a série é estacionária atribuiu-se valor 0 ao d , já a sazonalidade valor 1 a D . Os valores de p,q,P,Q são obtidos através da análise de ACF e PACF (figura 2) e ACF e PACF da série diferenciada, considerando a quantidade de lags significativos.

Foram determinados cinco modelos, utilizando como critérios de escolha: Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), Erro quadrático médio (EQM) e Erro absoluto médio (EAM). Os resultados destes critérios se encontram na Tabela 2. O modelo mais adequado é o que apresenta menor valor para AIC, BIC, EQM e EAM, o que pode ser claramente visualizado no modelo 3 de ordem $(0,0,3)X(2,1,0)$.

Tabela 2: Modelos SARIMA ajustados e seus valores de AIC, BIC e das medidas de qualidade.

Parâmetros	$(1,0,1) \times (2,1,1)$	$(1,0,0) \times (2,1,2)$	$(0,0,3) \times (2,1,0)$	$(2,0,1) \times (3,1,1)$	$(2,0,0) \times (3,1,2)$
AIC	372,31	302,80	292,86	311,34	299,83
BIC	386,34	316,84	306,90	330,72	319,21
EQM	1,29	0,91	0,86	0,93	0,87
EAM	1,01	0,72	0,67	0,73	0,69

Para comprovar se o modelo é adequado, foi necessário realizar a análise residual, para comprovar a não autocorrelação e a normalidade dos resíduos. De acordo com os resultados dos testes de Shapiro-Wilk e Jarque-Bera os resíduos são normalmente distribuídos e não autocorrelacionados. Logo, o modelo é válido para modelar os dados e realizar previsões.

Para efeito de comparação, realizou-se a previsão de dois modelos: um do tipo SARIMA e outro do tipo ARIMA, a fim de demonstrar a importância de identificar a sazonalidade da série e as diferenças no modelo caso a mesma não seja levada em consideração. Para tal, foi ajustado um modelo ARIMA $(0,0,3)$, desconsiderando a sazonalidade. A figura 4 apresenta os dois modelos ajustados.

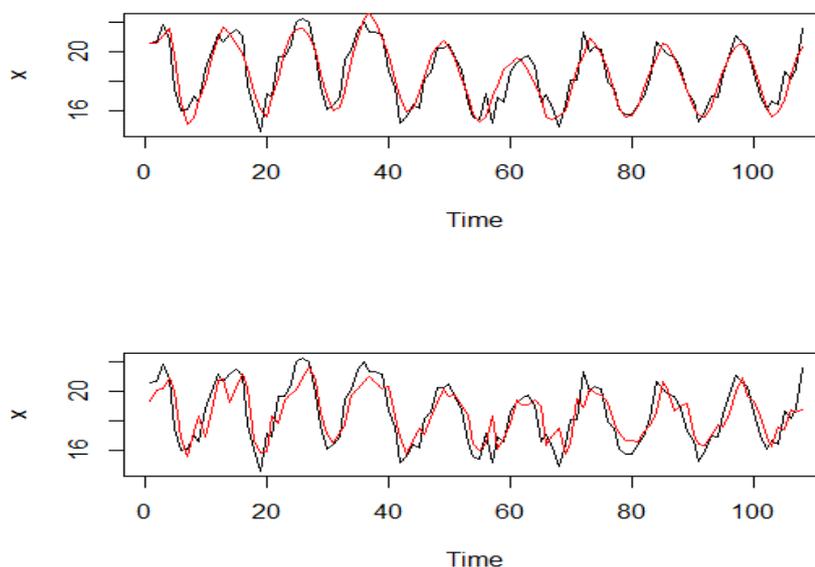


Figura 4: Valores observados das temperaturas ajustados aos modelos de SARIMA $(0,0,3)X(2,1,0)$ e ARIMA $(0,0,3)$.

O cálculo de previsões mensais de ambos os modelos, serviu para efeitos de comparação e escolha do que melhor se ajusta a série. A análise se baseia nas medidas de qualidade EQM e EAM, apresentadas na Tabela 4. Analisando o EQM e EAM, percebe-se que o modelo SARIMA $(0,0,3) \times (2,1,0)$, é o que apresenta uma melhor precisão na previsão dos dados, sendo o mais adequado para série em estudo.

Tabela 4: Avaliação da precisão das previsões obtidas a partir dos modelos ajustados.

Horizonte	Medida	Modelos	
		SARIMA	ARIMA
h=0	EQM	0,72	1,37
	EAM	0,67	0,95
h=1	EQM	1,16	2,23
	EAM	0,57	1,1

Apesar da importância da temperatura em diversos campos, como: transportes, turismo e lazer, o seu efeito mais visível é referente à área agrícola. Nesta área, a temperatura influencia diretamente em diversos efeitos fisiológicos das plantas. Fatores climáticos como este podem interferir de forma benéfica ou maléfica no desenvolvimento da planta, sendo assim, controlar esses fatores é de suma importância. A temperatura do ar e do solo afeta todos os estágios do processo de crescimento das plantas, devido ao limite térmico mínimo, ótimos e máximos para cada um dos estágios de crescimento.

Os cultivos tropicais exigem altas temperaturas o ano todo como o café, banana e cana-de-açúcar, que são sensíveis à geadas. Por outro lado, o centeio tem necessidade de baixa temperatura e pode até suportar as temperaturas de congelamento, durante um longo tempo hibernal de dormência. O resfriamento prolongado das plantas, com temperaturas acima do ponto de congelamento, retarda o crescimento vegetal e pode até matar as plantas adaptadas somente a condições quentes, reduzindo o fluxo de água das raízes, interferindo na transpiração e nutrição do vegetal. E para altas temperaturas, as plantas possuem uma maior resistência, desde que a umidade seja suficiente para evitar o murchamento.

CONCLUSÕES

Neste artigo, avaliou-se a qualidade do ajuste e a capacidade preditiva de um modelo SARIMA que representasse os dados de temperatura média mensal do ar na cidade de Santa Teresa, ES. Os resultados sugerem que a classe de modelos testados neste trabalho são adequadas para a modelagem de dados de temperatura.

Entre os modelos ajustados, o modelo SARIMA(0,0,3)X(2,1,0) foi considerado o mais adequado para realizar as previsões de temperatura média do ar na cidade de Santa Teresa, ES, principalmente por ter apresentado os melhores resultados para as medidas de qualidade e por ter sido capaz de representar a variabilidade dos dados sob estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

1. AMORIM, M. R. B. Modelagem em séries temporais aplicadas a dados de temperatura máxima na cidade de Campina Grande – PB. Tese de graduação. Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba. Campina Grande – PB, 2012.
2. AYOADE, J. O. Introdução à climatologia dos trópicos. 11. ed. Rio de Janeiro: Bertrand Brasil, 2006.
3. BAYER, F. M., SOUZA, A. M. Wavelets e modelos tradicionais de previsão: Um estudo comparativo. Revista Brasileira de Biometria. v.28, p.40-61, 2010.
4. CHECHI, L., BAYER, F. M. Modelos univariados de séries temporais para previsão das temperaturas médias mensais de Erechim, RS. Revista Brasileira de Engenharia Agrícola e Ambiental, v.16, p.1321-1329, 2012.
5. DICKEY, D.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a uni root. Econometrica, v. 49, n. 4, p. 1057-1073, 1981.
6. HUBBARD, K. G. Agricultural climatology. Journal of Service Climatology, v.1, p.1-9, 2007.
7. LATORRE, M. R. D. O, CARDOSO, M. R. A. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. Revista brasileira de epidemiologia, Vol.4, nº3. São Paulo, 2001.
8. MEDEIROS, S. S., CECÍLIO, R. A., MELO JÚNIOR, J. C. F., SILVA JÚNIOR, J. L. C. Estimativa e espacialização das temperaturas do ar mínimas, médias e máximas na região Nordeste do Brasil. Revista Brasileira de Engenharia Agrícola e Ambiental, v.9, p.247-255, 2005.

9. PINTO, W. P., LIMA, G. B., ZANETTI J. B. Análise comparativa de modelos de séries temporais para modelagem e previsão de regimes de vazões médias mensais do Rio Doce, Colatina - Espírito Santo. *Ciência e Natura*, Santa Maria. Revista do Centro de Ciências Naturais e Exatas – UFSM. 2015.v. 37 n. 4, 2015, p. 1–11.
10. PINTO, W. P., LIMA, G. B., ZANETTI J. B. Estudo de predição e previsão de temperaturas médias diárias da cidade de Cariacica, Espírito Santo, Brasil, utilizando a metodologia de séries temporais. *Revista GEINTEC*. São Cristóvão/SE – 2015. Vol. 5. n. 1.p.1881-1895.
11. PINTO, W. P., LIMA, G. B., ZANETTI J. B. Análise das variações das temperaturas médias diárias da cidade de Cariacica, Espírito Santo, Brasil, via metodologia de Box e Jenkins. *Congresso Brasileiro de Engenharia Sanitária e Ambiental*. Rio de Janeiro. 2015.
12. REISEN, V. A.; SILVA, A. N. O uso da linguagem R para cálculos de estatística básica. Vitória, ES: EDUFES, 2011.
13. SILVA, M. I. S.; GUIMARAES, E. C.; TAVARES, M. Previsão da temperatura média mensal de Uberlândia, MG, com modelos de séries temporais. *Rev. bras. eng. agríc. ambient.* [online]. 2008, vol.12, n.5, pp.480-485.
14. TEIXEIRA-GANDRA, C. F. A.; DAMÉ, R. C. F.; SIMONETE, M. A.; BACELAR, L. C. S., DISCONZI, P. B.; SANTOS, J. P. dos. Modelagem estocástica: previsão das temperaturas para a localidade de Pelotas/RS/Brasil. *Revista Agroambiente On-line*. 2014, vol. 8,, n.1, p.18-28.
15. WEI. W. *Time Series Analysis: univariate and multivariate methods*. Pearson. Boston. 2 ed. 2006.