

## MODELAGEM FUZZY INCREMENTAL PARA PREVISÃO CLIMÁTICA

VANIA C. MOTA<sup>1</sup>, EDUARDO A. SOARES<sup>2</sup>, DANIEL F. LEITE<sup>3</sup>

<sup>1</sup>Matemática, Mestre em Estatística e Experimentação Agropecuária, Doutoranda em Engenharia Agrícola, Depto. de Engenharia, Universidade Federal de Lavras (UFLA). Lavras, MG. Fone: (35)984622727. E-mail: vaniamota33@gmail.com

<sup>2</sup>Sistemas de Informação, Mestrando em Engenharia de Sistemas e Automação, Depto. de Engenharia, Universidade Federal de Lavras (UFLA). Lavras, MG.

<sup>3</sup>Engenheiro de Controle e Automação, Professor Adjunto, Depto. de Engenharia, Universidade Federal de Lavras (UFLA). Lavras, MG.

**RESUMO:** Previsões de temperatura são importantes em muitas áreas e provêm fundamentos para vários empreendimentos humanos. Por exemplo, a agricultura é extremamente sensível à mudanças climáticas. Previsões dão suporte à produtores para que tomem decisões com relação a atividades e proteção de propriedade. Este artigo apresenta a aplicação de um método de inteligência computacional baseado em nuvens chamado Método Evolutivo Tipicidade e Excentricidade (TEDA) para prever temperatura média mensal em diferentes regiões. Valores passados de temperatura máxima, mínima e média mensal, nebulosidade, precipitação e umidade do ar são considerados. Um método não-paramétrico baseado em correlação é proposto para selecionar as características mais importantes para uma previsão mais eficiente. As bases de dados foram obtidas de estações meteorológicas das cidades de São Paulo, Manaus e Porto Alegre. Os resultados da previsão TEDA são comparados com resultados gerados por outros métodos de inteligência computacional. TEDA proveu previsões ligeiramente mais precisas ao preço de um maior custo computacional.

**PALAVRAS-CHAVE:** Previsão Climática, Sistema Evolutivo, Modelagem *Fuzzy*.

## INCREMENTAL FUZZY MODELING FOR WEATHER PREDICTION

**ABSTRACT:** Weather prediction is meaningful in different areas and may provide basis for many human endeavors. For example, agriculture is extremely sensitive to climate change. Predictions support producers to make decisions regarding activities and property protection. This paper concerns the application of a cloud-based computational intelligence method, namely, a typicality and eccentricity-based method for data analysis (TEDA), to predict mean monthly temperature in different regions. Past values of maximum, minimum and mean monthly temperature, cloudiness, rainfall and humidity are considered. A non-parametric correlation based method is proposed to rank and select the most relevant features for a more accurate prediction. The datasets were obtained from weather stations located in main cities such as Sao Paulo, Manaus, and Porto Alegre. TEDA prediction results are compared with results provided by other computational intelligence methods. TEDA provided slightly more accurate predictions at the price of a higher computational cost.

**KEYWORDS:** Weather Prediction, Evolving System, Fuzzy Modeling.

## INTRODUÇÃO

Uma tarefa complicada e de grande importância em uma variedade de domínios do conhecimento diz respeito ao desenvolvimento de preditores de valores futuros de séries temporais. No caso de series temporais climáticas, comportamento não-linear e não-

estacionário induzido por uma série de fatores atmosféricos tornam o problema ainda mais difícil de resolver (VASQUEZ, 2002; LEITE et al., 2012; LEITE & GOMIDE, 2011).

Previsão do tempo é útil em diferentes áreas e pode fornecer base para muitos empreendimentos humanos. Por exemplo, a agricultura é extremamente sensível às alterações climáticas. Previsões dão suporte à produtores para que tomem decisões com relação a atividades e proteção de propriedade. Áreas como energia, transporte, aviação e planejamento de inventário, por exemplo, também podem claramente tomar proveito de previsões meteorológicas. Qualquer sistema sensível ao estado da atmosfera pode se beneficiar de previsões (VASQUEZ, 2002; LEITE et al., 2012).

Existe uma variedade de frentes de pesquisa e propostas de métodos voltados para as tarefas de modelagem e previsão de séries temporais. São exemplos os métodos e modelos provenientes da estatística. Tradicionalmente, estes métodos são baseados em modelagem de tendências, médias móveis, e em certos padrões gráficos. A maioria dos métodos trata-se de abordagens lineares, tais como a abordagem Box-Jenkins, Regressão Linear, Filtro de Kalman, entre outros.

Em anos recentes, métodos de modelagem baseados em inteligência computacional têm sido empregados em previsão de séries temporais. São exemplos as Redes Neurais Wavelet, Redes Neurais Feedforward em geral, Sistemas Fuzzy, Fuzzy-Genéticos e Neuro-Fuzzy. Estes métodos apresentam algumas vantagens com relação aos métodos estatísticos tradicionais visto que são métodos de natureza não-linear e, conseqüentemente, são capazes de aproximar comportamentos dinâmicos complexos com mais facilidade (ANDRADE et al., 2010; LEITE et al., 2011; LEITE et al., 2012; BUENO et al., 2015).

Com o aumento do número de dispositivos capazes de coletar dados continuamente - incluindo variáveis que afetam o clima - um grande número de dados tem sido produzido. Uma maneira de lidar com esses grandes volumes de dados é através do uso de uma classe de métodos computacionais conhecidos como métodos de aprendizagem incremental ou sistemas inteligentes evolutivos (KASABOV, 2007; ANGELOV & FILEV, 2010; LEITE et al., 2015). A abordagem evolutiva é uma forma eficaz de tratamento de fluxos de dados devido à sua capacidade de adaptar modelos à diferentes situações e proporcionar uma resposta rápida às alterações, isto é, às mudanças de conceito (LUGHOFER & ANGELOV, 2011; LEITE et al., 2016).

Apesar da existência de um grande número de modelos de previsão em várias áreas do conhecimento, ainda existe um esforço científico grande na direção do desenvolvimento de melhores esquemas de previsão (LEITE, 2012; BUENO, 2015). O presente trabalho tem como objetivo apresentar a aplicação de um método de inteligência computacional baseado em nuvens chamado Método Evolutivo Tipicidade e Excentricidade (TEDA) para prever temperatura média mensal em diferentes regiões.

## **MATERIAL E MÉTODOS**

Experimentos com dados reais das estações meteorológicas de São Paulo, Manaus e Porto Alegre foram estudados para ilustrar a utilidade da abordagem de seleção de características e previsão de temperatura propostas. Foram considerados para análise seis características, temperatura média ( $x_1$ ), temperatura mínima ( $x_2$ ) e temperatura máxima ( $x_3$ ); nebulosidade ( $x_4$ ), precipitação ( $x_5$ ) e umidade ( $x_6$ ); e dados mensais de janeiro de 1990 a dezembro de 2015 - 312 amostras de dados. Os dados das estações meteorológicas em questão estão disponíveis em [inmet.gov.br](http://inmet.gov.br).

Este artigo considera o método de seleção de características baseado na correlação de Spearman conforme (SOARES et al., 2017) combinado com o modelo preditor TEDA, vide (KANGIN & ANGELOV, 2016). As nuvens são tipos de agrupamento locais baseados em

métricas de similaridade entre amostras de dados. As nuvens não possuem forma geométrica específica no espaço de dados.

A aprendizagem e desenvolvimento do modelo preditor baseia-se na proximidade e densidade de amostras no espaço dos dados. Mais especificamente, a excentricidade depende do quão distinta é uma amostra com relação às outras amostras e do conhecimento atual sobre o sistema. Por outro lado, a tipicidade é baseada na semelhança de uma amostra com o conjunto de amostras inteiro. O TEDA não requer informações *a priori* sobre os dados e parâmetros pré-definidos. O seu objetivo é prever a temperatura média mensal (previsão um passo à frente) em cidades com diferentes padrões climáticos.

Inicialmente foi aplicado o algoritmo TEDA para predição (TEDA Predict) (BEZERRA, et al., 2015; ANGELOV et al. 2013; BEZERRA, et al., 2016), e os métodos evolutivos eTS (ANGELOV & ZHOU, 2006) e xTS (ANGELOV & ZHOU, 2006) - método Fuzzy Takagi-Sugeno Estendido. Estes métodos são comparados em termos de precisão e tempo de processamento considerando uma compactação similar dos modelos.

O método de correlação de Spearman é um método simples, porém rápido e não-paramétrico. Foi definido em princípio, uma janela deslizante de tamanho 24 (24 meses anteriores).

Para o estudo, determinou-se as variáveis de entrada e saída para gerar o sistema de inferência TEDA que modela o comportamento dos dados. Os dados foram normalizados entre 0 e 1. Portanto, as variáveis de entrada dos modelos preditores são:

$$X = [x_{1(k-23)} \dots x_{6(k-23)} \quad x_{1(k-22)} \quad \dots \quad x_{6(k-22)} \quad \dots \quad x_{1(k)} \dots x_{6(k)}] \dots \dots \quad (1)$$

A saída dos preditores evolutivos é a temperatura média estimada para o próximo mês, ou seja:

$$(\bar{y}_{(k+1)} = x_{1(k+1)}). \quad (2)$$

Após a disponibilização do valor de temperatura média do mês seguinte, pode-se calcular o erro entre a saída estimada e o valor verdadeiro da saída. Assim o desempenho do modelo TEDA e demais modelos é calculado a partir da raiz do erro quadrado médio (RMSE), que é representada pela seguinte expressão:

$$RMSE = \frac{1}{k_c} \sum_{k=1}^{k_c} \sqrt{(\bar{y}_{(k+1)} - y_{(k+1)})^2}, \quad (3)$$

em que,  $k_c$  é o número de interações. Foi também determinado o índice de erro não dimensional (NDE) conforme:

$$NDE = \frac{RMSE}{std(y^{(k) \forall k})}, \quad (4)$$

em que, *std* significa desvio padrão. O índice NDE é útil para comparar a precisão de um mesmo preditor para diferentes séries. Valores menores dos índices indicam melhores resultados.

## RESULTADOS E DISCUSSÃO

Simulações computacionais foram realizadas para avaliar a utilidade e a precisão dos preditores evolutivos combinados com o método proposto de seleção de variáveis baseado na correlação de Spearman. A Tabela 1 resume os resultados obtidos pelo preditor TEDA, eTS e xTS para a estação meteorológica de São Paulo considerando diferentes quantidades de variáveis de entrada. Os parâmetros iniciais dos algoritmos de aprendizagem foram forçados para que o número de modelos locais dos preditores TEDA, eTS e xTS (nuvens ou clusters) fossem semelhantes.

TABELA 1. Previsão: Estação meteorológica de São Paulo.

Preditor TEDA	#Número de variáveis de entrada					
	144	120	96	72	48	24
RMSE	<b>0,0329</b>	0,0369	3,09	0,0497	0,0357	0,0438
NDE	<b>0,2854</b>	0,3208	0,3513	0,4321	0,3104	0,3808
Tempo (s)	3,75	2,80	3,09	3,04	2,82	<b>2,75</b>
# Nuvens	10	10	10	10	10	10
eTS	#Número de variáveis de entrada					
	144	120	96	72	48	24
RMSE	<b>0,0479</b>	0,0669	0,0704	0,0747	0,0697	0,0658
NDE	<b>0,4154</b>	0,5802	0,6106 1	0,6479	0,6045	0,5707
Tempo (s)	1,95	1,76	1,69	1,72	1,82	<b>1,21</b>
# Regras	6	6	6	6	6	6
xTS	#Número de variáveis de entrada					
	144	120	96	72	48	24
RMSE	<b>0,0550</b>	0,0642	0,0696	0,0816	0,0784	0,0762
NDE	<b>0,4770</b>	0,5568	0,6036 1	0,7077	0,6800	0,6609
Tempo (s)	1,49	1,52	1,56	1,65	1,58	<b>1,41</b>
# Regras	5	5	5	5	5	5

Pode-se observar na Tabela 1 que em geral, os preditores evolutivos são mais precisos se todas as 144 características forem consideradas. Informações são perdidas quando certas variáveis são eliminadas. No entanto, um grande número de variáveis pode ser desconsiderado sem perda significativa de precisão. Por exemplo, o valor RMSE do método TEDA aumenta de 0,0329 para 0,0357 utilizando um terço da dimensão original do espaço de entrada. O número de termos antecedentes das regras TEDA, a compacidade do modelo resultante e o tempo de processamento são melhorados em detrimento de uma perda marginal na precisão da previsão.

De acordo com os índices RMSE e NDE, o preditor TEDA é ligeiramente mais preciso em comparação com eTS e xTS. O eTS usando 24 características é o mais rápido dos métodos. A Figura 1 ilustra a previsão TEDA de um passo para São Paulo.




FIGURA 1. Previsão de temperatura de um passo para São Paulo usando TEDA

Os resultados de previsão obtidos utilizando os dados de Manaus são mostrados na Tabela 2.

TABELA 2. Previsão: Estação meteorológica de Manaus

# Número de variáveis de entrada						
<b>Preditor TEDA</b>	<b>144</b>	<b>120</b>	<b>96</b>	<b>72</b>	<b>48</b>	<b>24</b>
RMSE	<b><u>0,0373</u></b>	0,0524	0,0706	0,0715	0,0495	0,0452
NDE	<b><u>0,3243</u></b>	0,4556	0,6139	0,6217	0,4304	0,3930
Tempo (s)	3,47	3,23	3,17	<b>2,94</b>	2,98	2,96
# Nuvens	10	10	10	10	10	10
# Número de variáveis de entrada						
<b>eTS</b>	<b>144</b>	<b>120</b>	<b>96</b>	<b>72</b>	<b>48</b>	<b>24</b>
RMSE	<b><u>0,0576</u></b>	0,0724	0,0732	0,0716	0,0695	0,0652
NDE	<b><u>0,5009</u></b>	0,6296	0,6365	0,6226	0,6043	0,5669
Tempo (s)	1,97	1,83	1,80	1,76	1,75	<b>1,41</b>
# Regras	5	5	5	5	5	5
# Número de variáveis de entrada						
<b>xTS</b>	<b>144</b>	<b>120</b>	<b>96</b>	<b>72</b>	<b>48</b>	<b>24</b>
RMSE	<b><u>0,0449</u></b>	0,0589	0,0614	0,0697	0,0749	0,0642
NDE	<b><u>0,3904</u></b>	0,5122	0,5339	0,6061	0,6513	0,5583
Tempo (s)	1,69	1,62	1,54	1,61	1,68	<b><u>1,32</u></b>
# Regras	7	7	7	7	7	7

O preditor TEDA forneceu os melhores índices de erro usando todas as características originais. No caso desta série temporal, quando os primeiros conjuntos de variáveis foram eliminados, uma rápida queda no desempenho foi observada. No entanto, essa tendência não é monotônica, ou seja, usando apenas 24 variáveis, TEDA forneceu resultados melhores em comparação com todas as configurações eTS e xTS, e melhores resultados em comparação com si mesmo quando consideradas de 48 a 120 variáveis de entrada. O método xTS usando 24 características foi o mais rápido para Manaus.

A Figura 2 mostra a melhor previsão de um passo para a cidade de Manaus dada por TEDA usando 144 características. É importante notar na figura que uma mudança de conceito é visível após  $k = 200$ ; a temperatura gradualmente aumenta. Um método não-evolutivo não poderia ser capaz de seguir tal mudança. Além disso, a partir da Fig. 2, observamos que o erro de previsão representado pela curva azul é maior nos picos e depressões da componente sazonal da série temporal. Nenhum dos métodos evolutivos inteligentes considerados neste artigo têm procedimentos algorítmicos específicos para tratar ou contornar esse problema.




FIGURA 2. Previsão de temperatura de um passo para Manaus usando TEDA

Segundo DIAS & DIAS (2007), as alterações previstas na sazonalidade da temperatura e da precipitação podem ter impactos na biodiversidade e nas atividades agrícolas. De acordo com o Painel Intergovernamental sobre Mudanças Climáticas (IPCC), as atividades antrópicas foram a principal causa do aquecimento global e mudanças climáticas globais relacionadas com padrões de precipitação e temperatura do ar (NOBRE, 2007). Assim, o clima pode ser considerado um dos fatores preponderantes para a ecologia e para a socioeconomia de determinada região (VIANELLO & ALVES, 1991).

Os resultados para a cidade de Porto Alegre são apresentados na Tabela 3. Novamente, o preditor TEDA superou eTS e xTS em relação aos índices RMSE e NDE. O eTS foi o mais rápido dos métodos. É interessante notar neste experimento que o uso de apenas 24 características no desenvolvimento do preditor TEDA foi suficiente para alcançar a maior precisão. Em outras palavras, o método de seleção de variáveis baseado em correlação proposto desempenhou um papel chave na redução de sobreposição de dados ao eliminar variáveis que poderiam confundir os preditores. A interpretação do modelo e a velocidade de

processamento são claramente melhoradas com regras TEDA baseadas em nuvens mais compactas.

Ressalta-se que métodos de previsão de condições climáticas no contexto agrário, ou mesmo no cotidiano das pessoas, têm papel relevante em diversas atividades econômicas. Previsões de temperatura e precipitação auxiliam no planejamento do plantio e colheita da lavoura e prevenção de geadas, granizo e secas. Logo, são peça fundamental numa agricultura competitiva. Tem-se observado que o estudo dessas variáveis, auxiliam no combate e tentativa de redução da mudanças climáticas globais (NOBRE, 2001). De modo geral, entre essas mudanças, as mais significativas foram: o aumento de temperatura, as modificações nos padrões de chuvas e alterações na distribuição de extremos climáticos (MOTA, 2008).

TABELA 3. Previsão: Estação meteorológica de Porto Alegre

Preditor TEDA	# Número de variáveis de entrada					
	144	120	96	72	48	24
RMSE	0,0410	0,0678	0,0764	0,0377	0,0616	<b>0,0332</b>
NDE	0,3565	0,5895	0,6643	0,3278	0,5356	<b>0,2887</b>
Tempo (s)	3,48	3,69	2,73	3,19	3,08	<b>2,69</b>
# Nuvens	10	10	10	10	10	10
eTS	# Número de variáveis de entrada					
	144	120	96	72	48	24
RMSE	<b>0,0597</b>	0,0718	0,0793	0,599	0,0632	0,0621
NDE	<b>0,5191</b>	0,6243	0,6896	0,209	0,5496	0,5400
Tempo (s)	1,82	1,71	1,68	1,57	1,37	<b>1,13</b>
# Regras	6	6	6	6	6	6
xTS	# Número de variáveis de entrada					
	144	120	96	72	48	24
RMSE	<b>0,0501</b>	0,0562	0,0617	0,0638	0,0677	0,0594
NDE	<b>0,4357</b>	0,4887	0,5365	0,5548	0,5887	0,5165
Tempo (s)	1,2	1,57	1,58	1,64	1,81	<b>1,54</b>
# Regras	5	5	5	5	5	5

Em geral, os experimentos mostraram que o modelo TEDA é eficiente para prever séries temporais climáticas. As precisões de predição foram maiores do que àquelas dos modelos eTS e xTS para os dados considerados neste artigo. O número de cálculos algébricos necessários no algoritmo TEDA é maior e, portanto, o método tende a ser mais lento do que outros métodos evolutivos. No entanto, o tempo de processamento não é uma restrição em problemas de previsão mensal, diária e até mesmo horária; mas pode ser um problema crítico em aplicações de fluxo de dados de frequência mais alta.

## CONCLUSÕES

Neste artigo, foi aplicado um método de inteligência evolutiva baseada em tipicidade e excentricidade (TEDA) para previsão de séries temporais de diferentes cidades localizadas no Brasil. Valores de temperatura máxima, mínima e média mensal, bem como valores anteriores de variáveis exógenas como nebulosidade, precipitação e umidade foram considerados nas análises. Essas variáveis são fundamentais na tomada de decisão relacionada a agricultura, como no planejamento do plantio e colheita da lavoura e prevenção de geadas, granizo e secas. Em particular, assumiu-se uma janela de tempo de 24 meses. Foi proposto um método de classificação e de seleção de características baseado em correlação de *Spearman* para identificar os melhores conjuntos de variáveis e atrasos de tempo a serem utilizados para o desenvolvimento dos preditores.

O método de seleção apresentou bons resultados no sentido que reduziu a complexidade computacional global e acelerou as etapas de processamento. Curiosamente, para a estação meteorológica de Porto Alegre, o uso de apenas um sexto das características originais foi suficiente para fornecer o melhor preditor TEDA. As variáveis adicionais confundiram o processo de aprendizagem. TEDA apresentou melhor desempenho em comparação com os métodos eTS e xTS considerando as estações São Paulo, Manaus e Porto Alegre, e os índices de erro RMSE e NDE. Estes últimos métodos, eTS e xTS, foram mais rápidos para aprender a partir do fluxo de dados. Em geral, o uso dessa modelagem é interessante para o caso de previsão no contexto agrário, sendo relevante para produtores e para a população em suas atividades econômicas.

Trabalhos futuros irão discutir sobre novos parâmetros associados às nuvens, como especificidade da informação, entropia e cardinalidade, e sobre o uso dessas variáveis para otimizar a estrutura do modelo durante a aprendizagem online. Previsão intervalar de séries climáticas também é uma questão de investigação futura.

## REFERÊNCIAS

ANGELOV, P.; ZHOU, X. "Evolving Fuzzy Systems from Data Streams in Real-Time." Int Symp on Evolving Fuzzy Systems, p.29-35, 2006.

ANGELOV, P.; ZHOU, X. "Evolving Fuzzy-Rule-Based Classifiers from Data Stream." In: IEEE TRANSACTIONS ON FUZZY SYSTEMS, v.16, n.6, p.1462-1475, 2006.

ANGELOV, P.; FILEV, D.; KASABOV, N. **Evolving Intelligent Systems: Methodology and Applications**. Wiley-IEEE Press, 2010.

ANGELOV, P.; SKRJANC, I.; BLAZIC, S. "Robust Evolving Cloud-Based Controller for a Hydraulic Plant." In: IEEE CONFERENCE ON EVOLVING AND ADAPTIVE INTELLIGENT SYSTEMS (EAIS'13), p.1-8, 2013.

BEZERRA, C. G.; COSTA, B. S.; GUEDES, L. A. ANGELOV, P. "Online Fault Detection based on Typicality and Eccentricity Data Analytics." In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN'15), p.6, 2015.

BEZERRA, C. G.; COSTA, B. S.; GUEDES, L. A. "A New Evolving Clustering Algorithm for Online Data Streams." In: IEEE CONFERENCE ON EVOLVING AND ADAPTIVE INTELLIGENT SYSTEMS (EAIS'16), p.7, 2016.

BEZERRA, C. G.; COSTA, B. S.; GUEDES, L. A.; ANGELOV, P. "An Evolving Approach to Unsupervised and Real-Time Fault Detection in Industrial Processes." **Expert Systems With Applications**, v.63, n.(C), p.134-144, 2016.

BUENO, L.; COSTA, P.; MENDES, I.; CRUZ, E.; LEITE, D. "Evolving Ensemble of Fuzzy Models for Multivariate Time Series Prediction". In: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, p. 1-6, 2015.

COSTA, B.; SKRJANC, I.; BLAZIC, S.; ANGELOV, P. "A Practical Implementation of Self-Evolving Cloud-Based Control of a Pilot Plant." In: IEEE INTERNATIONAL CONFERENCE ON CYBERNETICS, p.7-12, 2013.

DIAS, M. A. F. da S.; DIAS, P. L. da S. As incertezas regionais nos cenários de mudanças climáticas globais. **Boletim da Sociedade Brasileira de Meteorologia**, São José dos Campos, v. 31, n.1, p.12-16, abr. 2007.

LEITE, D.; GOMIDE, F.; BALLINI, R.; COSTA, P. "Fuzzy Granular Evolving Modeling for Time Series Prediction. In:" IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, p.2794-2801, 2011.

LEITE, D.; BALLINI, R.; COSTA, P.; GOMIDE, F. "Evolving Fuzzy Granular Modeling from Nonstationary Fuzzy Data Streams." **Evolving Systems**, v.3,n.2, p.65-79, 2012.

LEITE, D.; PALHARES, R.; CAMPOS, V.; GOMIDE, F. "Evolving Granular Fuzzy Model-based Control of Nonlinear Dynamic Systems." In: IEEE TRANSACTIONS ON FUZZY SYSTEMS, n.23, v.4, p. 923-938, 2015.

LEITE, D.; SANTANA, M.; BORGES, A.; GOMIDE, F. "Fuzzy Granular Neural Network for Incremental Modeling of Nonlinear Chaotic Systems." In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, p.64-71, 2016.

LUGHOFER, E.; ANGELOV, P. "Handling Drifts and Shifts in Online Data Streams with Evolving Fuzzy Systems." **Applied Soft Computing**, v.11, n.2, p. 2057-2068, 2011.

KANGIN, D.; ANGELOV, P. "Evolving Clustering, Classification, and Regression with TEDA." In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, p.8, 2015.

KANGIN, D.; ANGELOV, P. J. A. Iglesias. "Autonomously Evolving Classifier TEDA Class." **Information Sciences**, n.366, p.1-11, 2016.

KASABOV, N. **Evolving Connectionist Systems: The Knowledge Engineering Approach**. Springer Science & Business Media, 2007.

MOTA, V. C. **Metodologia geostatística para caracterizar a variabilidade temporal de elementos climáticos de Juiz de Fora - MG.** Lavras. 111p. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, 2008.

NOBRE, C. A. Mudanças climáticas globais: possíveis impactos nos ecossistemas do país: modelos e cenários para a Amazônia: o papel da ciência. **Revista Parcerias estratégicas**, Brasília, DF, n.12, p.20, set. 2001.

NOBRE, C. A. Mudanças climáticas globais e o Brasil: porque devemos nos preocupar. **Boletim da Sociedade Brasileira de Meteorologia**, São José dos Campos, v. 31, n. 1, p. 7-11, abr. 2007.

SOARES, E.; MOTA, V.; POUÇAS, R.; LEITE, D. Cloud-Based Evolving Intelligent Method for Weather Time Series Prediction, In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, p.1-6 (In process), 2017.

VASQUEZ, T. **Weather Forecasting Handbook.** Weather Graphics Technologies, 5th edition, June 2002.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações.** Viçosa, MG: UFV, p.449, 1991.