



08 a 11 de Outubro de 2018
Instituto Federal Fluminense
Búzios - RJ

MÉTODOS HÍBRIDOS DE REDES NEURAI NA PREVISÃO DE SÉRIES TEMPORAIS DO CUSTO DA CESTA BÁSICA NA MICRORREGIÃO ILHÉUS-ITABUNA

Dárcio Rocha Silva¹ - darciosilvaddr@gmail.com

Dany Sanchez Dominguez¹ - dsdominguez@gmail.com

Paulo Eduardo Ambrósio¹ - peambrosio@uesc.br

¹ Programa de Pós-Graduação em Modelagem Computacional em Ciência e Tecnologia - Universidade Estadual de Santa Cruz, Campus Soane Nazaré de Andrade - Ilhéus, BA, Brasil

Resumo. *Técnicas de inteligência artificial têm sido amplamente utilizada na análise e previsão de séries temporais de dados socioeconômicos. Neste trabalho apresentamos duas abordagens híbridas aplicadas a previsão de séries temporais do custo da cesta básica de alimentos na região Sul da Bahia. A primeira metodologia combina Redes Neurais Artificiais (RNA) com o modelo Autoregressivo Integrado e de Médias Móveis (ARIMA) e a segunda RNA com um sistema de inferência Fuzzy (sistema Neurofuzzy). Foram realizadas previsões a curto prazo dividido em três etapas, prevendo quatro, seis e doze meses respectivamente, mostrando que os métodos híbridos aglutinam as vantagens das técnicas que os compõem e oferecem previsões de maior qualidade. A avaliação de desempenho das previsões é obtida por meio das medidas de acurácia, com destaque para o sistema Neurofuzzy que apresentou desempenho superior à medida que aumenta o número de previsões.*

Palavras-chave: *Séries Temporais, Dados Socioeconômicos, Redes Neurais Artificiais, Métodos Híbridos.*

1. INTRODUÇÃO

Uma série temporal é qualquer conjunto de observações ordenadas no tempo. Estes conjuntos de observações são objetos de estudos com a finalidade de investigar o mecanismo gerador da série temporal; fazer previsão de valores futuros; descrever apenas o comportamento da série e/ou procurar periodicidades relevantes nos dados. A fim de realizar este estudo, utilizamos uma série temporal obtida do projeto Acompanhamento do Custo da Cesta Básica (ACCB) (UESC, 2017). Este projeto é uma iniciativa do departamento de ciências econômicas da Universidade Estadual de Santa Cruz, que desde 1999 vem realizando a coleta de dados do custo da cesta básica na região Sul da Bahia. Esses dados são tabulados e submetidos a diversas instâncias governamentais para auxiliar na gestão de políticas públicas.

Com isso, buscar conhecer o comportamento da série temporal do projeto ACCB é de grande utilidade para a gestão pública, em que as previsões realizadas sobre o futuro poderá ser submetidas a diversas instâncias governamentais orientando-os na tomada de decisões em relação às políticas públicas e programas governamentais. Isso é de grande relevância, principalmente para a região Sul da Bahia, que juntamente com todas as outras sub-regiões do Nordeste, possui baixos indicadores socioeconômicos comparados com o restante do país.

Quando se trata de análise de séries temporais, a ciência que trata desse assunto é a estatística. Normalmente para dados lineares, os métodos estatísticos lidam muito bem com o comportamento da série, criando modelos que modelam de forma eficiente as características da série estudada. Entretanto, quando se tem séries temporais não lineares, a modelagem usando estatística necessita de grande complexidade matemática (de Mattos Neto et al., 2005). Com isso, busca-se o uso de métodos alternativos que possam modelar de forma eficiente o comportamento da série. Entre estes métodos, destaca-se a combinação de abordagens, criando assim modelos robustos de análise de séries temporais.

Desta forma, neste trabalho foi realizada a implementação de dois modelos híbridos. O primeiro modelo proposto combinou RNA com o método ARIMA (Box & Jenkins, 1976), e o segundo modelo foi realizado pela combinação de RNA com sistema de inferência Fuzzy (Jang, 1993). A combinação de modelos tem como objetivo obter modelos mais robustos que proporcione previsões precisas. Os modelos implementados foram testados utilizando uma série temporal do tipo econômica obtida do projeto ACCB, realizando previsões a curto prazo para os períodos de quatro, seis e doze meses. Os resultados foram comparados entre si em termo de acurácia, permitindo selecionar a melhor abordagem que forneça previsões mais acuradas para séries temporais econômicas.

A estrutura deste artigo está assim organizada: a primeira seção apresenta esta introdução, a seção 2 apresenta a metodologia abordada, apresentando os conhecimentos necessários para o entendimento das propostas aqui apresentada e os modelos híbridos propostos. Na seção 3 são expostos os resultados obtidos e na seção final, são apresentadas as conclusões obtidas através deste estudo.

2. METODOLOGIA

Neste artigo apresentamos duas metodologias de modelos híbridos para análise e previsão de séries temporais. As abordagens híbridas são obtidas pela combinação de duas ou mais técnicas de modelagem, com a finalidade de obter modelos mais poderoso e com menos deficiências. Segundo (Sanchez, 2009), a construção de modelos híbridos pode acontecer de três formas, sendo elas: modelo híbrido sequencial, modelo híbrido auxiliar e modelo híbrido incorporado.

Neste trabalho utilizamos o modelo híbrido sequencial e o modelo híbrido incorporado. O modelo sequencial combina duas técnicas ARIMA e RNA, em que a saída da primeira técnica ARIMA, atua como entrada da segunda técnica definida pela RNA. Já o modelo incorporado apresenta alto grau de hibridização, ao ponto que não é possível a separação entre os dois modelos compostos pela combinação de sistema de inferência Fuzzy e RNA, resultando assim em um sistema Neurofuzzy.

2.1 Metodologia Híbrida ARIMA e RNA

A abordagem ARIMA é uma metodologia bastante utilizada na previsão de séries temporais. Essa abordagem consiste em ajustar modelos auto-regressivos integrados de médias

móveis ARIMA (Morettin & Tolo, 2006) a um conjunto de dados. Este modelo é resultado da combinação dos componentes auto-regressivo (AR), integração (I) e média móvel (MA), usados para analisar séries temporais não estacionárias, transformando-as em estacionárias através da ordem de integração, ou seja, a diferenciação da variável envolvida (Box & Jenkins, 1976).

Assim, um modelo ARIMA denotado por $ARIMA(p, d, q)$, realiza a previsão de uma variável assumindo a mesma como uma função linear de várias observações e erros aleatórios. O processo de construção desta metodologia é realizado através de ciclo iterativo constituído por identificação do modelo, estimação e verificação. De acordo (Morettin & Tolo, 2006), o procedimento padrão para realizar previsão usando o modelo ARIMA, consiste em primeiro determinar se a série temporal é estacionária. Caso não seja, é necessário tomar a diferença da série original tantas vezes for necessário para torna-la estacionária, encontrando assim o parâmetro d . Logo depois, deve fazer a análise das funções autocorrelação (ACF) e de autocorrelação parcial (PACF) para realizar a estimação dos parâmetros p e q . Depois de realizadas estas etapas, o passo seguinte é realizar a previsão, obtendo novos valores da série.

Quando se trata de previsões de séries temporais o modelo ARIMA lida muito bem com previsões imediatas, mas quando se trata de previsões em períodos mais longos este modelo tende a fornecer previsões com pouca precisão. A fim de contornar este problema, surgem os modelos de redes neurais artificiais que se destacam pela capacidade de lidar melhor com a não linearidade dos dados do que o modelo ARIMA, sendo indicados para analisar sistemas dinâmicos como séries temporais não estacionárias (Müller et al., 2012). De maneira geral, a estrutura das redes neurais artificiais computacionais é definida como um conjunto de unidades de processamentos, caracterizadas por neurônios artificiais que são interligados entre si, criando um grande número de interconexões permitindo que a mesma possua a capacidade de aquisição e manutenção do conhecimento com base nas informações apresentadas a ela (Silva et al., 2010).

Os neurônios artificiais são responsáveis por fazer a manipulação das informações através das interações entre si. A rede neural recebe sinais externos que são processados e gera sinais de saída, enviando-os entre si, fazendo com que a informação seja propagada pela rede. Assim, o modelo geral de um neurônio é composto por sinais de entrada, pesos sinápticos, combinador linear, limiar de ativação, potencial de ativação, função de ativação e sinal de saída – para mais detalhes consultar (McCulloch & Pitts, 1943).

Para este trabalho, utilizamos uma rede neural do tipo multilayer perceptron, cuja configuração é um arranjo sequencial que abrange três tipos de camadas compostas pelos neurônios, são elas: camada de entrada, oculta e saída. A Fig. 1 apresenta a estrutura da rede neural, composta por camada de entrada, oculta e saída respectivamente. De acordo com (Hair Junior et al., 2005), o aumento da capacidade sináptica advindo das camadas oculta e saída, possibilita a análise de sistemas complexos, sendo ideal para análise de séries temporais não estacionárias.

Assim, ao analisar uma série temporal, os valores observados são usados para alimentar a rede através da camada de entrada. O neurônio de saída recebe o sinal de entrada advindo da camada oculta e calcula um valor de saída. Para modelos preditivos, esse valor representa a previsão. De acordo (Hair Junior et al., 2005), as camadas ocultas permitem a análise de modelos não lineares, o que auxiliam a rede neural se adaptar a comportamentos como tendência e sazonalidade, possibilitando previsões mais acuradas quando comparadas ao modelo ARIMA.

Estes dois modelos individualmente abstraem características da série, os quais são realizados para realizar as previsões. Logo, ao realizar a combinação destes modelos, resulta em um modelo final com a absorção das características individuais de cada um, o que possibilita previsões mais acuradas. Partindo desta ideia, realizamos a combinação dos modelos ARIMA e RNA. Este modelo foi inspirado no trabalho (de Abreu Silva, 2012), que propõe uma metodo-




Figura 1- Estrutura geral de uma rede neural multilayer perceptron

logia híbrida usando ARIMA e RNA. No primeiro passo, foi realizado a estimação do modelo ARIMA da série temporal, e logo em seguida, utilizou-se o modelo estimado para alimentar uma RNA e conseqüentemente obter bons resultados de previsão. As etapas desta abordagem podem ser melhor visualizadas na Fig. 2.

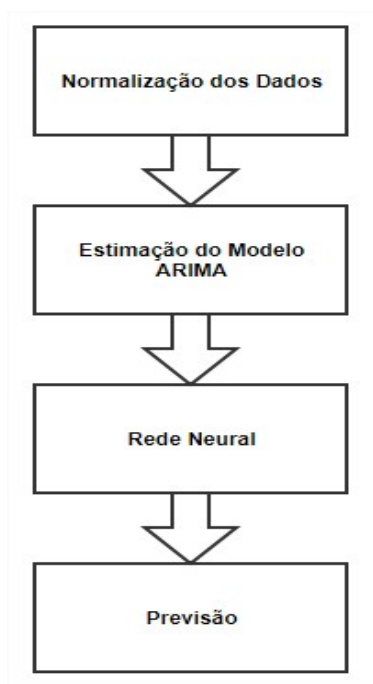


Figura 2- Etapas da metodologia híbrida ARIMA e RNA

Como pode ser visto na Fig. 2, o primeiro passo desta metodologia consiste em normalizar os pontos da série temporal, de forma que os valores estejam compreendidos entre 0 e 1, para evitar a saturação da rede neural (Silva et al., 2010).

Feito a normalização, a série foi então utilizada para construir o modelo ARIMA. Para realizar este procedimento, foi feito o uso do software R, utilizando a biblioteca forecast (Hyndman & Khandakar, 2007). Neste ponto, o interesse é determinar a configuração da modelo ARIMA,

sendo que para isto foi realizado o estudo da ACF e da PACF como proposto por (Morettin & Toloí, 2006).

O estudo do par de correlograma ACF e PACF é uma das maneiras mais utilizadas para determinar a configuração do modelo ARIMA. Em (Morettin & Toloí, 2006), define-se a metodologia para determinar esta configuração. Seguindo esta metodologia, foi realizada a análise do par de correlograma determinado a configuração ideal do modelo ARIMA resultando no modelo com a seguinte configuração ARIMA(4, 1, 2).

Após estimar o modelo ARIMA, o passo seguinte foi alimentar a rede neural com dados do modelo estimado do processo anterior. Para isto, foi necessário encontrar a melhor configuração e arquitetura de rede que forneça a melhor previsão. (Fernandes et al., 1996) define que, em si tratando de previsão de séries temporais utilizando redes neurais, o melhor tipo de rede é do tipo multilayer perceptron (Beale & Jackson, 1990).

As características desta rede segundo (Fernandes et al., 1996), apresenta 13 neurônios na camada inicial. Nas camadas seguintes, a primeira camada oculta é composta por 6 neurônios e a segunda camada oculta composta por 2 neurônios e por último, a camada final com um neurônio que é a configuração padrão. O treinamento durou um total de 100 épocas, e para realizar o treinamento, foi utilizado o método de aprendizado supervisionado, usando o algoritmo do gradiente descendente (Silva et al., 2010).

2.2 Metodologia Híbrida Sistema Neurofuzzy

A arquitetura ANFIS (adaptive Neuro-Fuzzy Interence System) foi proposta por (Jang, 1993). Este sistema processa as variáveis linguísticas com a capacidade de aprendizado de uma rede neural, fazendo com que o mesmo se ajuste e otimize uma solução qualquer para o ambiente, resultando em um sistema Neurofuzzy.

Um sistema Neurofuzzy é um sistema Fuzzy onde é aplicado algum algoritmo de treinamento de aprendizado de máquina sobre o mesmo (Oliveira et al., 2007). Essa abordagem é considerada uma ferramenta poderosa para o desenvolvimento de sistemas Fuzzy, sendo sua utilidade evidenciada quando surge a necessidade de lidar com sistemas fortemente não lineares, de comportamento variável no tempo, o que ocorre nas séries temporais compostas por tendência e sazonalidade.

A ideia básica é simples: os modelos Neurofuzzy nada mais são que representações de sistema Fuzzy (formulados por meio de regras fuzzy do tipo IF-THEN) na forma de redes (ou grafos direcionados) possíveis de treinamento por técnicas similares às usadas em redes neurais artificiais (Oliveira et al., 2007).

A arquitetura utilizada no sistema Neurofuzzy é uma rede adaptativa, isto é, uma espécie de grafo com nós interconectados por ramos direcionados em que alguns nós apresentam comportamento adaptativo, ou seja, sofrem alterações paramétricas no decorrer do treinamento, enquanto outros mantêm seu comportamento dinâmico inalterado (Jang, 1993). Na Fig. 3 é apresentado o modelo ANFIS com duas entradas utilizado nesta pesquisa. As camadas deste modelo são descritas a seguir:

- Camada 1: Esta camada é responsável por transformar cada variável de entrada em variáveis do universo fuzzy. Cada neurônio desta camada representa uma função de pertinência das diversas variáveis fuzzy;
- Camada 2: Esta camada realiza a aplicação da t-norma (de Barros & Bassanezi, 2010) às saídas das camadas anteriores, logo, é nesta camada que se encontram as regras de

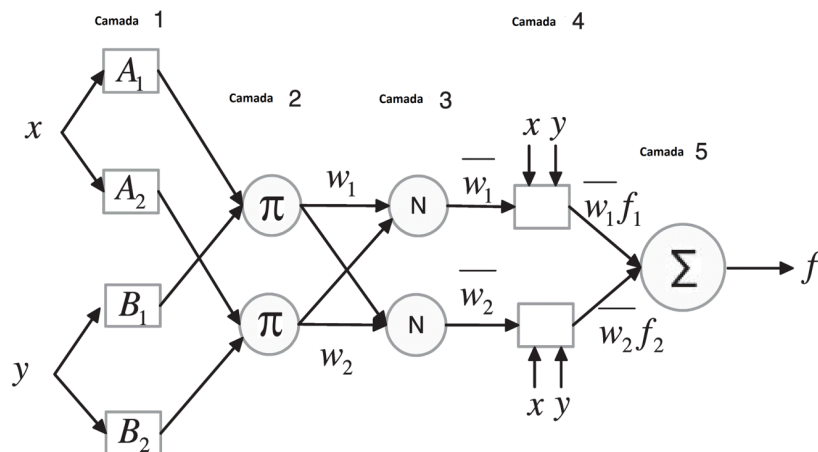


Figura 3- Modelo ANFIS com duas entradas e uma saída (Jang, 1993)

conhecimento do especialista fuzzy. Isso equivale à aplicação das operações IF-THEN;

- Camada 3: É responsável pelo cálculo do grau de ativação normalizado das variáveis, dos valores gerados pelas regras IF-THEN, evitando assim uma distorção nos parâmetros de consequência do sistema;
- Camada 4: Cada nó desta camada é adaptativo por conter uma função adaptativa para realizar o cálculo com os parâmetros de consequência do sistema;
- Camada 5: O nó desta última camada da arquitetura, calcula a saída precisa do sistema e juntamente com os nós das camadas 3 e 4, promovem a defuzzificação ou soma total de todos os sinais de entrada, ou seja, transforma as variáveis fuzzy de consequência obtidas na camada 4 em um único valor dos conjuntos clássicos.

Assim, os sistemas Neurofuzzy permite a extração do conhecimento baseado nas regras de inferências Fuzzy (de Barros & Bassanezi, 2010), mediante a integração do conhecimento gerado pelo especialista ou de uma base de dados, permitindo o processo de inferência mais apurado, isto devido a capacidade que estes sistemas possuem de associar a capacidade de aprendizado e de tolerância a falhas das RNA com a interpretabilidade dos sistema Fuzzy.

3. RESULTADOS

A série analisada é do tipo econômica, adquirida do projeto Acompanhamento do Custo da Cesta Básica (UESC, 2017), correspondendo o preço da cesta básica da cidade de Ilhéus situada na região Sul da Bahia. A Fig. 4, ilustra o comportamento temporal da série analisada no período correspondente ao intervalo de janeiro de 2005 a dezembro de 2016.

As duas metodologias propostas apresentaram resultados satisfatórios na modelagem do estudo e previsão de séries temporais do tipo econômica. A série analisada contém no total 144 pontos referente a coleta do custo da cesta básica na cidade de Ilhéus. Destes 144 pontos, foram selecionados 100 pontos para realizar o treinamento das duas metodologias propostas e os 44 pontos restantes para validar o treinamento. Após realizar o treinamento dos dois modelos



Figura 4- Preço da cesta básica da cidade de Ilhéus-Ba, janeiro de 2005 a dezembro de 2016

e suas respectivas validações, foram realizadas três previsões a curto prazo, prevendo quatro meses, seis e doze meses respectivamente.

Na Tabela 1 apresentamos os resultados obtidos na previsão. Na primeira coluna temos os valores reais da série, na segunda e terceira colunas, contém a previsão e o erro usando a metodologia ARIMA com RNA, e na quarta e quinta colunas os resultados do sistema Neurofuzzy.

Tabela 1- Resultado de previsão dos modelos híbridos

Valor Real	ARIMA e RNA	Erro Relativo	Neurofuzzy	Erro Relativo
344,77	345,29	1,51E-03	341,55	9,34E-03
341,74	345,472	1,09E-02	338,489	9,52E-03
339,22	343,49	1,26E-02	336,327	8,53E-03
345,29	342,91	6,89E-03	342,113	9,20E-03
357,61	352,481	1,43E-02	352,819	1,34E-02
342,11	349,518	2,17E-02	337,865	1,24E-02
336,46	337,59	3,36E-03	333,678	8,27E-03
351,03	345,728	1,51E-02	347,402	1,03E-02
328,45	338,508	3,06E-02	325,015	1,05E-02
308,69	317,915	2,99E-02	306,873	5,88E-03
319,36	315,345	1,26E-02	319,089	8,50E-04
325,24	320,431	1,48E-02	324,332	2,79E-03

A Fig. 5 ilustra a previsão dos modelos híbridos propostos. A curva vermelha representa o valor real da série, a curva preta representa a previsão do modelo ARIMA com RNA e a curva azul representa a previsão do sistema Neurofuzzy prevendo doze meses.

Para realizar a validação das previsões, foram utilizadas quatro medidas de acurácias, sendo elas: Erro Quadrático Médio (MSE - Mean Squared Error), Erro Percentual absoluto Médio (MAPE - Mean Absolute Percentage Error), Erro Percentual Absoluto Médio Ajustado (SMAPE - Adjusted Mean Absolute Percent Error) e o Erro Máximo (Erro Max) (Hyndman et al., 2006). Na Tabela 2 são apresentadas estas medidas de acurácia, sendo que cada coluna dos períodos é dividida em duas células, em que a primeira célula representada por M1 refere ao modelo híbrido ARIMA com RNA e a segunda célula representado por M2 refere ao modelo híbrido sistema Neurofuzzy.

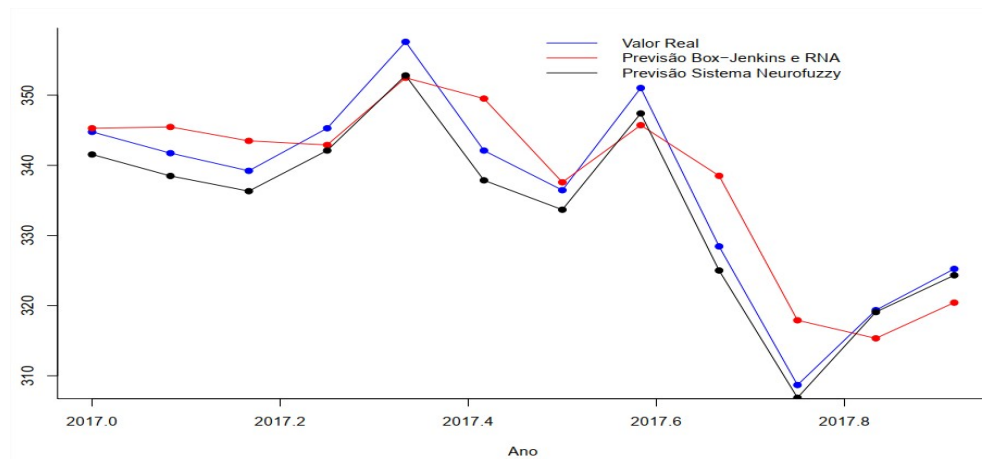


Figura 5- Previsão das duas metodologias

Tabela 2- Medidas de acurácia, M1 – modelo ARIMA com RNA, M2 – modelo sistema Neurofuzzy

Medidas	Quatro Meses		Seis Meses		Doze Meses	
	M1	M2	M1	M2	M1	M2
SME	9,52E+00	9,85E+00	1,99E+01	1,34E+01	3,12E+01	9,77E+00
MAPE	7,98E-01	9,15E-01	1,13E+00	1,04E+00	1,45E+00	8,41E-01
SMAPE	3,97E-03	4,59E-03	5,64E-03	5,23E-03	7,22E-03	4,23E-03
ErroMax	1,26E+00	9,52E-01	2,17E+00	1,34E+00	3,06E+00	1,34E+00

Analisando a Tabela 2 e a Fig. 5 podemos observar que a metodologia utilizando o sistema Neurofuzzy apresentou melhores resultados do que a metodologia ARIMA com RNA. Para a previsão de quatro meses, podemos verificar que a metodologia híbrida ARIMA apresentou melhores resultado, entretanto, a medida em que aumenta o número de previsões, o sistema Neurofuzzy tende a fornecer melhores resultados de previsão em termo de acurácia.

4. CONCLUSÕES

Os dois modelos híbridos propostos apresentaram bons resultados na previsão. O modelo híbrido que combinou ARIMA com RNA, tem como principal dificuldade a estimação do modelo ARIMA adequado, sendo necessário várias etapas iterativas para obter o modelo apropriado. Já o modelo híbrido sistema Neurofuzzy tem por principal limitação a restrição a redes feedforward, além disso, surge a necessidade de manter o controle do número de entradas devido à explosão combinatória de regras. Entretanto, os dois modelos mostraram ser eficiente na realização de previsão, em que o modelo híbrido ARIMA com RNA mostrou ser mais eficiente ao realizar previsões imediatas, apresentando previsões mais acuradas até o quarto mês de previsão. Já o sistema Neurofuzzy apresentou ser uma opção válida para a abordagem ao problema de previsão de séries temporais, apresentando previsões mais acuradas para predições longas.

Agradecimentos

Agradecemos ao apoio financeiro da FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia), ao PPGMC (Programa de Pós-Graduação em Modelagem Computacional em Ciência e Tecnologia) pelo programa de mestrado e ao NBCGIB (Núcleo de Biologia Computacional e Gestão de Informações Biotecnológicas) por oferecer suporte computacional e infra-estrutura física para a realização desta pesquisa.

REFERÊNCIAS

- Beale, R., and Jackson, T. (1990). “*Neural Computing-an introduction*”, CRC Press.
- Box, G. E. P and Jenkins, GM (1976). “*Time series analysis: Forecasting and control*”, 1985.
- de Mattos Neto, P. S., Petry, G. G., Ataíde, J. P. D. M., and Ferreira, T. A. (2005). “*Combinação de Redes Neurais Artificiais com Algoritmo Genético Modificado para a Previsão de Séries Temporais*”, In XXV Congresso da Sociedade Brasileira de Computação (SBC), São Leopoldo/RS.
- de Barros, L. C., and Bassanezi, R. C. (2010). “*Tópicos de lógica fuzzy e biomatemática*”, Grupo de Biomatemática, Instituto de Matemática, Estatística e Computação Científica (IMECC), Universidade Estadual de Campinas (UNICAMP).
- de Abreu Silva, T. A. (2012). “*Previsão de carga elétrica através de um modelo híbrido de regressão com redes neurais*”, Dissertação de Mestrado, UNESP/ Ilha Solteira – SP.
- Fernandes, L. G. L., Portugal, M. S., and Navaux, P. O. (1996). “*Previsão de séries de tempo: redes neurais artificiais e modelos estruturais*”, Pesquisa e Planejamento Econômico, 26(2), 253-276.
- Hair Junior, J. F. (2005). “*Análise multivariada de dados*”, Trad. Adonai Schlup Sant’Anna e Anselmo Chaves Neto.
- Hyndman, R. J., and Khandakar, Y. (2007). “*Automatic time series for forecasting: the forecast package for R (No. 6/07)*”, Monash University, Department of Econometrics and Business Statistics.
- Hyndman, R. J., and Koehler, A. B. (2006). “*Another look at measures of forecast accuracy*”, International journal of forecasting, 22(4), 679-688.
- Jang, J. S. (1993). “*ANFIS: adaptive-network-based fuzzy inference system*”, IEEE transactions on systems, man, and cybernetics, 23(3), 665-685.
- Lin, C. T., and Lee, C. G. (1996). “*Neural fuzzy systems*”, PTR Prentice Hall.
- McCulloch, W. S., and Pitts, W. (1943). “*A logical calculus of the ideas immanent in nervous activity*”, The bulletin of mathematical biophysics, 5(4), 115-133.
- Morettin, P. A., and Toloí, C. (2006), “*Análise de séries temporais*”, 2ed ed. São Paulo: Blucher.
- Müller, B., Reinhardt, J., & Strickland, M. T. (2012). “*Neural networks: an introduction*”, Springer Science & Business Media.
- Oliveira, H., Caldeira, A., Machado, M. A., SOUZA, R., and TANSCHKEIT, R. (2007). “*Inteligência Computacional aplicada a administração, economia e engenharia em Matlab*”, Rio de Janeiro, Thompson.
- Sanchez, E. C. M. (2009). “*Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência*”, Rio de Janeiro: PUC-Rio.
- Silva, I. D., Spatti, D. H., and Flauzino, R. A. (2010). “*Redes neurais artificiais para engenharia e ciências aplicadas*”, São Paulo: Artliber, 23(5), 33-111.
- Sousa, A. P. D. (2012). “*Análise comparativa de métodos de previsão de séries temporais através de modelos estatísticos e rede neural artificial*”, Dissertação de Mestrado, MEPROS/ PUC, Goiás. Universidade Estadual De Santa Cruz (UESC). “*Projeto Acompanhamento do custo da cesta básica (ACCB)*”, Ilhéus, 2017. Disponível em: nbcgib.uesc.br/cesta/area_publica/index.php, Acesso em: 12 mar. 2017.

HYBRID METHODS OF NEURAL NETWORKS IN THE FORECAST OF TIME SERIES OF THE COST OF THE STAPLE FOOD BASKET IN THE ILHÉUS-ITABUNA MICROREGION

Abstract. Artificial intelligence techniques have been widely used in the analysis and review of time series of socioeconomic data. This paper we present two hybrid approaches applied to forecast time series of the cost of the basic food basket in the southern region of Bahia.

The first methodology combines Artificial Neural Networks (ANN) with the autoregressive integrated moving average (ARIMA) model, and the second ANN with a Fuzzy inference system (Neurofuzzy system). Short-term forecasts were divided into three stages, predicting four, six and twelve months respectively, showing that the hybrid methods combine the advantages of the techniques that compose them and offer forecasts of higher quality. The performance evaluation of the forecasts is obtained by means of the accuracy measures, with emphasis on the Neurofuzzy system, which presented superior performance as the number of forecasts increases.

Keywords: *Time Series, Socioeconomic Data, Artificial Neural Networks, Hybrid Methods.*