



INTER
FACES
CIENTÍFICAS

SAÚDE E AMBIENTE

ISSN IMPRESSO 2316-3313

E - ISSN 2316-3798

DOI - 10.17564/2316-3798.2018v6n3p53-62

PROGNÓSTICO DA INCIDÊNCIA DE CASOS DE DENGUE NA CIDADE DE SALVADOR – BAHIA, UTILIZANDO A TRANSFORMADA WAVELET DISCRETA EM CONJUNÇÃO COM REDES NEURAIS ARTIFICIAIS

PROGNOSIS OF DENGUE CASES INCIDENCE IN SALVADOR - BAHIA, APPLYING THE DISCRETE WAVELET
TRANSFORM IN CONJUNCTION WITH ARTIFICIAL NEURAL NETWORK

PRONÓSTICO DE LA INCIDENCIA DE CASOS DE DENGUE EN SALVADOR - BAHIA, UTILIZANDO LA TRANSFORMADA
ONDÍCULA DISCRETA EN CONJUNCIÓN CON REDES NEURONALES ARTIFICIALES

Arthur Pontes de Miranda Ramos Soares¹

Isabela Cavalcante Martins³

Frede de Oliveira Carvalho⁵

Pedro Henrique Pereira Alves²

Lucas Costa Barreto⁴

RESUMO

A dengue é uma arbovirose que tem como vetores transmissores os mosquitos do gênero *Aedes*, e é considerada uma das doenças mais perigosas das quais pode ser transmitida pelo mosquito *Aedes*, já que a sua difusão pode ser bem rápida, causando mortalidade (na forma de dengue hemorrágica principalmente) do indivíduo que a contrai. No Brasil, os números de casos

de dengue vêm crescendo de forma preocupante, com surtos cíclicos, intercalando-se com ocorrências de epidemias. Portanto, os investimentos governamentais têm sido cada vez maiores, objetivando diminuir esta propensão, buscando principalmente o entendimento das variáveis que favorecem o desenvolvimento do vetor, bem como a utilização de ferramentas

computacionais para prever os casos de incidência. Neste contexto, faz-se necessário o tratamento de dados confiáveis, os quais traduzam a dinâmica da incidência da doença. Desta forma, a obtenção dos dados de casos de dengue na forma de séries de temporais tem sido utilizada recorrentemente. Em posse desses dados, é possível desenvolver métodos analíticos os quais permitam efetuar o prognóstico e posterior prevenção da manifestação de casos da referida doença. Uma das técnicas mais eficiente e recorrentemente citada na literatura é a análise das séries temporais por meio da associação de sistemas inteligentes (como as Redes Neurais Artificiais) com técnicas de análise de sinais (como a Transformada Wavelet Discreta). Essa técnica denominada por alguns autores

como conjugação TWD-RNA (Transformada Wavelet Discreta com Rede Neural Artificial) tem apresentado resultados superiores em relação a métodos clássicos baseados somente em estatística. Desta forma, neste trabalho buscou-se investigar a eficiência da conjugação TWD-RNA no prognóstico de casos de dengue na cidade de Salvador, a partir dos dados mensais de casos de dengue evidenciados entre os anos de 2000 a 2008 obtidos no site do Sistema de Informações de Agravos de Notificação (SINAN).

PALAVRAS-CHAVE

Transformada Wavelet Contínua. Dengue. Salvador. RNA.

ABSTRACT

Dengue is an arbovirus transmitted by vectors as *Aedes* mosquitoes, and is considered one of the most dangerous diseases transmitted by these ones, since its diffusion may be considered so fast leading to death (when manifested in hemorrhagic dengue way mainly). In Brazil, the amount of dengue cases has been growing up in a terrible way, presenting cyclic outbreaks, and epidemics occurrences. Therefore, the government investments have been increasing aiming to decrease it, seeking understanding the variables that contribute to vector development, as well as, the use of forecast computational tools. In this context, suitable data treatment is required, and shows up the disease incidence dynamic. Thus, dengue data cases in temporal series way have been recurrently used. From this data, it is possible to perform analytics methods that allow dengue cases forecast and subsequent prevention cases manifestation of this disease. One of the most efficient techni-

ques presented in literature is temporal series analyses with intelligent systems (as Artificial Neural Network) and signals analyses technique (as Discrete Wavelet Transform) approach. This technique called ensemble DWT-ANN approach (Discrete Wavelet Transform with Artificial Neural Network), has shown up the best results than another classical based on statistics methods only. Thus, the efficiency of ensemble DWT-ANN in dengue cases forecast is investigated, analyzing data from Salvador City, by mensal dengue cases evidenced between the years 2000 to 2008, this data was obtained in SINAN (Sistema de Informações de Agravos de Notificação) website.

KEY WORDS

Discrete Wavelet Transform; Dengue; Salvador; ANN.

RESUMEN

El dengue es una arbovirosis que tiene como vectores transmisores los mosquitos del género *Aedes*, y es considerada una de las enfermedades más peligrosas de las cuales pueden ser transmitidas por el mosquito *Aedes*, ya que su difusión puede ser muy rápida causando mortalidad (en forma de dengue hemorrágico principalmente) del individuo que la contrae. En Brasil, los números de casos de dengue vienen creciendo de forma preocupante, con brotes cíclicos, intercalándose con ocurrencias de epidemias. Por lo tanto, las inversiones gubernamentales han sido cada vez mayores objetivando disminuir esta propensión, buscando principalmente el entendimiento de las variables que favorecen el desarrollo del vector, así como la utilización de herramientas computacionales para predecir los casos de incidencia. En este contexto, se hace necesario el tratamiento de datos confiables, que traducen la dinámica de la incidencia de la enfermedad. De esta forma, datos de casos de dengue en forma de series de temporales se ha utilizado recurrentemente. En posesión de esos datos, es posible desarrollar métodos analíticos que permitan efectuar el pronóstico y posterior pre-

vención de la manifestación de casos de dicha enfermedad. Una de las técnicas más eficiente y recurrentemente citada en la literatura es el análisis de las series temporales a través de la asociación de sistemas inteligentes (como las Redes Neuronales Artificiales) con técnicas de análisis de señales (como la Transformada Ondícula Discreta). Esta técnica denominada por algunos autores como conjunción TWD-RNA (Transformada Ondícula Discreta con Red Neuronal Artificial) ha presentado resultados superiores en relación a los métodos clásicos basados solamente en estadística. De esta forma, en este trabajo se buscó investigar la eficiencia de la conjunción TWD-RNA en el pronóstico de casos de dengue en la ciudad de Salvador, a partir de los datos mensuales de casos de dengue evidenciados entre los años 2000 a 2008 obtenidos en el sitio de la SINAN (Sistema de Informações de Agravos de Notificação).

PALABRAS CLAVE

Transformada Wavelet Discreta; Dengue; Salvador; RNA.

1. INTRODUÇÃO

A dengue é uma das doenças transmitidas por vetores mais prevalentes em regiões tropicais e subtropicais do planeta. O vírus da dengue (DENV) é transmitido principalmente por duas espécies de mosquito: *Aedes aegypti*, como o principal vetor e o *Aedes albopictus*, como vetor secundário. O DENV foi classificado em quatro tipos sorologicamente distintos (DEN-I, DEN-II, DEN-III e DEN-IV), que podem causar sintomas clínicos que incluem febre, dor de cabeça, dores musculares e articulares, dor retro-orbital. Anticorpos específicos para cada tipo podem ser produzidos contra casos de infecção pelo mesmo sorotipo de DENV; no entanto, a dengue hemorrágica e síndrome do choque

da dengue mediada por um mecanismo de aumento dependente de anticorpos, podem ocorrer se a infecção subsequente for causada por sorotipos diferentes.

A problemática da dengue aumentou dramaticamente desde 1970, estimativas recentes indicam 390 milhões de infecções anualmente e aproximadamente 100 milhões de pessoas com sintomas. No Brasil, desde o início de 2015 foram notificados mais de 800 mil casos de dengue, enquanto que em 2014 foram 591 mil. Atualmente, a cada quatro cidades do país, três apresentam pelo menos um caso notificado. A dengue é dominante na América Latina, Sudeste Asiático e Ásia Pacífica; no entanto, os países do Sul Ásia, in-

cluindo Paquistão, Índia e Bangladesh, também relataram um número crescente de surtos e trouxe significativos impactos na saúde pública.

A ocorrência de epidemias de dengue vem aumentando de forma significativa, principalmente em países próximos à linha do Equador, gerando comoção da saúde pública à nível mundial. Por isso, trabalhos científicos nas mais diversas áreas estão sendo realizados com o intuito de descobrir e otimizar o funcionamento da dinâmica de incidência de casos de dengue, para que esse conhecimento possa ser aplicado no amparo às medidas públicas preventivas criadas pelo governo, aumentando sua eficiência prática e econômica.

As mudanças ecológicas na transmissão da dengue são atribuíveis a causas multifatoriais com interações complexas. O *A. aegypti* e o *A. albopictus* são bem adaptados ao meio urbano; assim, a urbanização desencadeada pela economia e desenvolvimento, pode criar microambientes artificiais ideais para os vetores da doença. Além disso, com a globalização, viagens internacionais e domésticas frequentes também aumentam a probabilidade de transmissão da dengue.

Devido aos aspectos negativos causados pela propagação do vírus da dengue se fazem necessárias ferramentas para a realização do prognóstico dos casos a fim de facilitar a tomada de decisão e aplicação de estratégias mais eficazes na resposta aos casos de dengue emergentes.

2. MATERIAL E MÉTODOS

Em vista da problemática descrita, a necessidade de se obter o máximo de informações possível sobre o fenômeno epidemiológico da dengue é crescente. Neste trabalho, foram utilizadas duas técnicas computacionais de previsão de séries temporais, a rede neural artificial sozinha e em conjunção com a transformada Wavelet discreta, na tentativa de construir um modelo de previsão eficiente dos casos de dengue na cidade de Salvador, Bahia.

2.1 BASE DE DADOS

Os dados de casos reportados de dengue na cidade de Salvador, dos anos de 2000 a 2008, foram obtidos por meio do portal Sistema de Informação de Agravos de Notificação (SINAN). Esta base de dados é alimentada a partir de notificações e investigações de casos de doenças e agravos que fazem parte da Lista Nacional de Doenças de Notificação Compulsória (LNDNC), portaria GM/MS nº 2325 de 8 de dezembro de 2003. A tabela de dados diários de dengue gerada foi filtrada para conter somente os valores numéricos dos casos de dengue durante os meses, não incluindo dados pessoais dos indivíduos registrados. Da tabela de dados diários, foi realizada uma média aproximada dos dados para obter a série mensal utilizada.

2.2 REDES NEURAIS ARTIFICIAIS

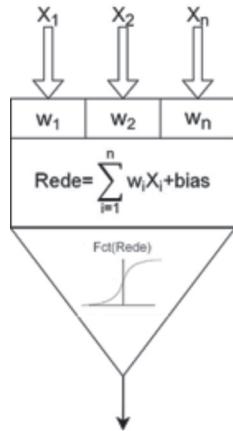
Segundo Osório e Bittencourt (2000), o conceito de Inteligência Artificial – I.A. foi abordado pela primeira vez em 1956 por McCarthy. Esse termo geralmente se refere à abordagem científico-computacional para a inteligência da máquina. Esta abordagem enfatiza o processamento simbólico. Assim, a I.A. tornou-se popular com a possibilidade de igualar o computador com as atividades cerebrais. Esta visão varia desde a especulação clássica de ficção científica até os sistemas de armas (KOSKO, 1992).

As ferramentas de I.A. evoluíram para sistemas programados unicamente para resolver um determinado problema. Posteriormente, estas ferramentas foram munidas de mecanismos de aquisição automática de conhecimentos, chegando assim ao que conhecemos por Redes Neurais Artificiais (RNA). As RNA são sistemas computacionais inteligentes inspiradas nos neurônios naturais e, portanto, foram aperfeiçoadas para terem a capacidade de se adaptar e de aprender a realizar certa tarefa, ou comportamento, a partir de um conjunto de dados exemplo.

Na Figura 1, é mostrado um esquema básico da estrutura de uma rede neural onde x , de 1 à n , são as variáveis de entrada e w , os pesos, que serão ajusta-

dos de acordo com o erro obtido na saída. Nas últimas décadas, as redes neurais têm sido utilizadas para identificação, avaliação e previsão de dados, principalmente no estudo de séries temporais, envolvendo, entre outras coisas, variáveis climáticas (OSÓRIO; BITTENCOURT, 2000; SILVA, 2014).

Figura 1 – Representações da estrutura um neurônio artificial



Fonte: Autores.

Portanto, uma Rede Neural Artificial é um modelo computacional de inspiração biológica que consiste em processar elementos (chamados neurônios) e conexões entre eles com coeficientes (pesos) vinculados às conexões, que constituem a estrutura neuronal, treinamento e algoritmos que guardam a informação, anexados à estrutura (SARAIVA, 2017).

2.3 TRANSFORMADA *WAVELET* DISCRETA

A Transformada *Wavelet* Discreta (TWD) é um método de análise espectral que separa os componentes de frequência do sinal de acordo com a magnitude. A TWD decompõe o sinal, característico das variáveis climáticas, em altas frequências e baixas frequências, por meio de uma função característica chamada *Wavelet*-mãe, de forma que o sinal decomposto tenha as mes-

mas características desta função. Assim, é possível extrair informações sobre a frequência embutida na série temporal e realizar o prognóstico mais eficientemente (DEO; WEN; QI, 2016; ZHU *et al.*, 2016; SARAIVA, 2017).

A descrição matemática da Transformada *Wavelet* é dada pela Equação (1), onde $x(t)$ representa o sinal temporal.

$$W(a, b) = \int_{-\infty}^{+\infty} x(t) \varphi_{a,b}(t) dt \quad (1)$$

em que:

$$\varphi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \left(\frac{t-b}{a} \right) \quad (2)$$

O termo é a função ondulatória chamada de *Wavelet*-mãe, cuja área sob seu gráfico é igual a zero, e cuja energia tem valor finito.

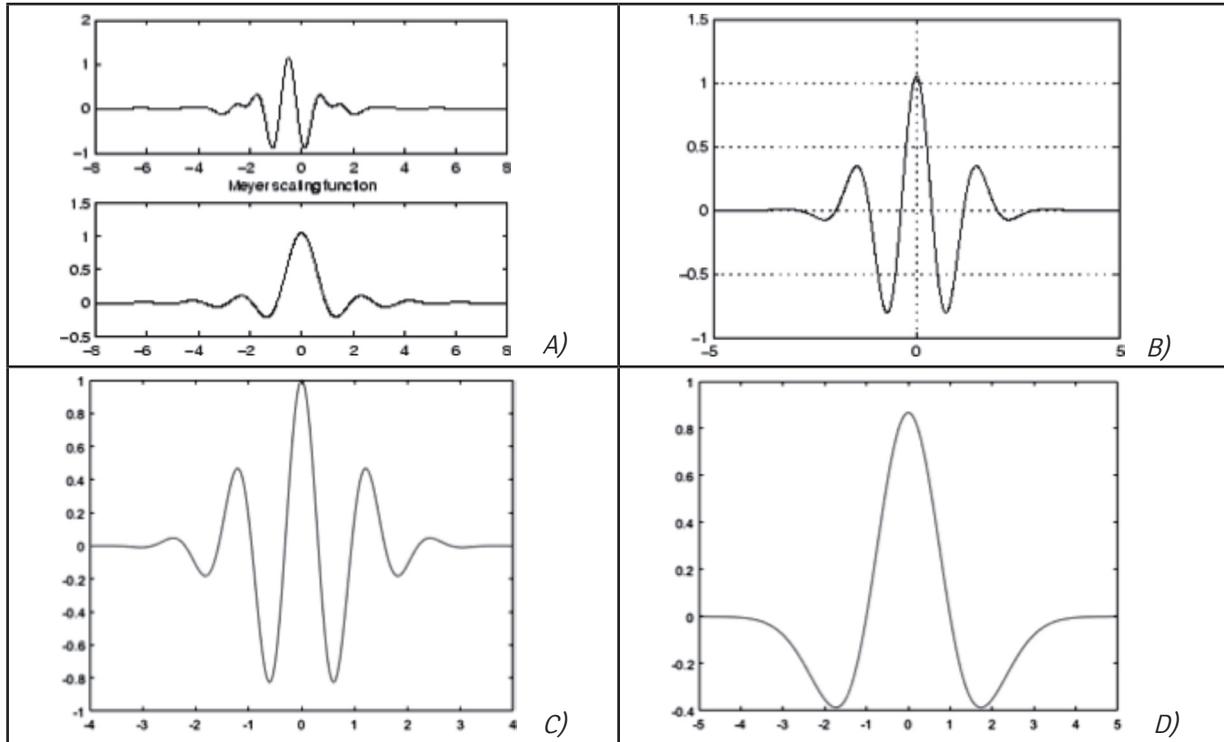
$$\int_{-\infty}^{+\infty} \varphi(t) dt = 0 \quad (3)$$

então:

$$0 < \int_{-\infty}^{+\infty} |\varphi(t)|^2 dt < \infty \quad (4)$$

Existem várias funções características dentro das *Wavelets*-mãe que têm exatamente as mesmas particularidades que as fazem ser “funções *Wavelet*”, mudando apenas a leitura do sinal. Alguns exemplos dessas funções estão presentes na Figura 2, sendo todos retirados do *Math Work - Wavelet Toolbox Functions*.

Figura 2 – Funções Wavelet: A - Meyer; B - Gaussiana; C - Morlet; D - Chapéu Mexicano

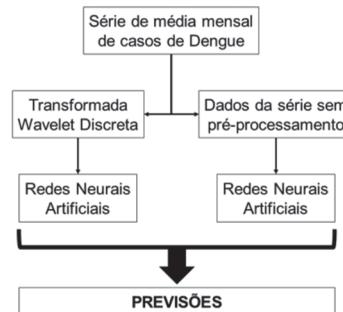


Fonte: Math Works (2018).

2.4 ARQUITETURA DOS MODELOS

O presente artigo apresenta a comparação entre dois modelos que envolvem RNA, um puramente RNA e o segundo um modelo híbrido de *Wavelet* com RNA (TWD+RNA). Estes modelos são modelos não fenomenológicos, mas sim em caixa preta, os dados a entrarem na rede não dependem ser de uma área específica. Assim, a Figura 3 resume esquematicamente as etapas de investigação desta série temporal pelos dois modelos.

Figura 3 – Metodologia empregada nos modelos RNA puro e modelo *Wavelet* + RNA



Fonte: Autores.

No modelo constituído puramente de RNA, não há pré-processamento, conforme a Figura 4. Assim, cerca de 85% dos dados originais que consistem em a série temporal foram utilizados para treinamento e validação da rede e os últimos 15% utilizados para checagem do modelo, sendo as funções de ativação escolhidas foram sigmoide (camada escondida) e identidade, ou linear, para a camada de saída. Para o treinamento supervisionado da rede foram utilizados 3 dias atrás para prever um à frente (número de atraso) e 3 camadas escondidas.

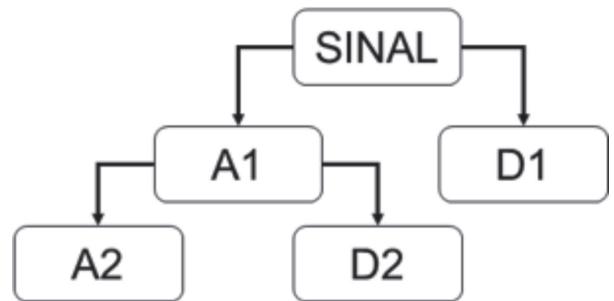
Para a conjugação de *Wavelet* e Redes Neurais Artificiais, o pré-processamento consistiu em decompor os dados (Domínio amplitude e tempo), conforme a Figura 6, por meio da decomposição *Wavelet*. Os vetores, detalhe e aproximação criados, estão no domínio da escala e tempo e D1, D2, A2 são os vetores agora de entrada no modelo híbrido e a sua saída consiste já nos dados previstos de média mensal da incidência dos casos de dengue. Vale ressaltar que com os dados decompostos a rede consegue extrair melhor informações da série temporal, de modo, que a utilizamos para isso e não há extração de ruídos como normalmente é encontrado na literatura e que as funções de ativação, o número de atraso e o número de camadas escondidas são os mesmos do modelo puramente RNA.

Assim, sendo a única diferença entre os modelos, como objeto de estudo do presente trabalho, a existência ou não de um pré-processamento por meio de decomposição *Wavelet*. O número de decomposições é calculado segundo o critério de Nourani, Kisi e Komasi (2009), isto é:

$$N_{dec} = [\log(\text{número de dados})] \quad (5)$$

onde os colchetes [], representam a função maior inteiro ou função piso. Assim, o número de decomposições é 2, conforme a Figura 4. A família *Wavelet* escolhida para decomposição do sinal foi a *Wavelet* discreta de Meyer.

Figura 4 – Decomposição *Wavelet* do Sinal



Fonte: Autores.

Todos os modelos utilizados neste trabalho foram construídos e executados em ambiente MATLAB.

3. RESULTADOS

Uma análise criteriosa requer parâmetros estatísticos que validem a superioridade de um modelo em relação a outro.

Os critérios aqui escolhidos para discussão e comparação entre os modelos foram *mean-square error* (MSE) e o coeficiente de correlação de Pearson (R):

$$MSE = \frac{1}{n} \sum (y_{obs} - y_{mod})^2$$

$$R = \frac{\sum(y_{obs} - Y) * \sum(y_{mod} - Y)}{\sqrt{(\sum(y_{obs} - Y)^2) * (\sum(y_{mod} - Y)^2)}}$$

onde, y_{obs} são os valores observados, dados da série original; y_{mod} os valores obtidos por meio dos modelos discutidos; Y o valor médio dos dados observados, y o valor médio dos valores obtidos por modelos e n o número de dados que se deseja investigar.

Podem-se comparar os modelos, de modo que as Tabelas 1 e 2 demonstram os erros para cada modelo (RNA e TWD+RNA) com cada ferramenta estatística na fase de teste e para 3 algoritmos de treinamento distintos.

Tabela 1 – Erros associados para o modelo RNA puro para 3 algoritmos de treinamento distintos

RNA	Algoritmos		
	LM	BR	SCG
R	0,295324	0,472212	0,479206
MSE	95,01277	98,13541	105,9364

MSE: *mean-square error*; LM: Levenberg-Marquardt; BR: Bayesian Regularization; SCG: Scaled Conjugate Gradient.

Fonte: Dados da pesquisa.

Tabela 2 – Erros associados para o modelo W+RNA puro para 3 algoritmos de treinamento distintos

W+RNA	Algoritmos		
	LM	BR	SCG
R	0,93146	0,99818	0,54199
MSE	80,1526	44,0057	132,0342

MSE: *mean-square error*; LM: Levenberg-Marquardt; BR: Bayesian Regularization; SCG: Scaled Conjugate Gradient.

Fonte: Dados da pesquisa.

4. DISCUSSÃO

Na literatura, a TWD é recorrentemente citada como técnica de análise de sinais em trabalhos de análise de séries temporais. Assim, com a intenção de aplicar a Transformada *Wavelet* Discreta em conjunção com sistemas inteligentes, é possível perceber que a RNA surge como método preditivo adequado, visto que a Rede Neural Artificial apresentada no estudo de Ibrahim e outros autores (2005), se adaptou com sucesso ao mecanismo não linear dos dados de treinamento e produziu resultados promissores com o erro de predição de apenas 10%. Os autores mostraram que é possível prever o dia antes que a febre dos pacientes com dengue começa a diminuir para que os clínicos possam decidir a melhor estratégia de tratamento, já que a dengue hemorrágica costuma se apresentar como uma complicação da dengue comum.

Wickramaarachchi, Perera e Jayasinghe (2015), explicam que a maioria das pesquisas disponíveis na literatura se baseiam em modelos estatísticos de análise de séries temporais de dengue e que esses são usualmente incapazes de descrever o mecanismo de transmissão de dengue que é extremamente não estacionário, complexo e repleto de ruídos, devido a fatores externos. Por isso, a Transformada *Wavelet* foi utilizada, tendo em vista que é um método de análise espectral de séries temporais criada com o intuito de suprir as limitações técnicas apresentadas por métodos clássicos.

A proposta para a realização do presente artigo estava em determinar um método ótimo para o processamento de dados e aplicá-lo em um método preditivo, tão eficaz quanto, em séries temporais. Assim, por meio do MSE e do R dos modelos, determinou-se que o algoritmo de treinamento que melhor compreendeu o padrão da série temporal, foi o algoritmo Bayesian Regularization. E com base nas Tabelas 1 e 2, pode-se notar a superioridade do modelo híbrido em questão em relação ao modelo puro, visto que os coeficientes de correlação se aproximam mais da unidade e os MSE de menor magnitude, exceto o de *Scaled Conjugate Gradient*, talvez pela forma do treinamento, mas ainda possui MSE maior em pouca quantidade.

Segundo Laureano-Rosareo e outros autores (2018), os casos de dengue são influenciados por uma série de parâmetros ambientais e demográficos. Dessa maneira, uma análise mais abrangente da incidência de dengue poderá ser realizada, utilizando fatores como precipitação, a temperatura do ar e fatores sociais (isto é, casos anteriores de dengue e tamanho da população), que poderão ser inseridas na rede neural para melhorar os resultados obtidos, tornando-os mais eficazes no prognóstico da incidência de casos de dengue, devida a sua alta complexidade e dependência de fatores climáticos e sociais.

Ainda como sugestão para trabalhos futuros que envolvam a conjunção e análise de métodos de regressão, pode-se citar o *Support Vector Machine* (SVM) que, assim como a Rede Neural Artificial, também pode ser melhorado com a utilização da Transformada *Wavelet* Discreta. Para tanto, vê-se que os

resultados empíricos de Yusof e Mustaffa (2011), em seu artigo sobre Previsão de Surtos de Dengue, revelaram que a abordagem com SVM produz melhores resultados quando comparada à Rede Neural Artificial em conjunção com a *Wavelet* Discreta.

5. CONCLUSÃO

De acordo com os resultados obtidos neste trabalho, foi observado que os modelos híbridos, ou provenientes de conjunções entre modelos, têm altíssimo potencial para prognóstico da incidência dos casos de dengue. Especificamente neste trabalho, o modelo híbrido de RNA com Wavelet obteve um significativo decréscimo de erro se comparado com o de RNA puro, para as 2 ferramentas estatísticas utilizadas, tendo em vista as Tabelas 1 e 2. Conforme estes resultados e pela literatura consultada, constatou-se também que estes modelos híbridos, pelo seu alto potencial na resolução de problemas deste tipo, necessitam ser mais estudados.

REFERÊNCIAS

DEO, R.C.; WEN, X.; QI, F. A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset. **Ap Energy** v.168, p.568-593, 2016.

IBRAHIM, F. *et al.* A novel dengue fever (DF) and dengue haemorrhagic fever (DHF) analysis using artificial neural network (ANN). **Comput Methods Programs Biomed** v.79, n.3, p.273-81, 2005.

KOSKO, B. **Neural networks and fuzzy systems: a dynamical systems approach to machine intelligence.** Englewood Cliffs: Prentice-Hall International, 1992.

LAUREANO-ROSARIO, A.E. *et al.* Application of Artificial Neural Networks for dengue fever outbreak predictions in the Northwest Coast of Yucatan, Mexico and San Juan, Puerto Rico. **J Trop Med Infect Dis.**, v.3, n.1, p.1-16, 2018.

MATH WORKS. **Wavelet toolbox functions R2018a.** 2018. Disponível em: <<https://la.mathworks.com/help/wavelet/functionlist.html#buxs3yu-1>>. Acesso em: 5 fev. 2018.

NOURANI, V.; KISI, Ö.; KOMASI, M.I.K. Two hybrid Artificial Intelligence approaches for modeling rainfall-runoff process. **J Hidrol.**, v.402, n.1-2, p.41-59, 2011.

OSÓRIO, F.; BITTENCOURT, J.R. **Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens.** Workshop de Inteligência Artificial. 1. Universidade de Santa Cruz do Sul, Santa Cruz do Sul. 2000.

SARAIVA, S.V. **Estudo de um controlador preditivo baseado em Sistemas Inteligentes.** 2017. Trabalho de Conclusão de Curso (Engenharia Química) – Universidade Federal de Alagoas, Maceió, 2017.

SILVA, I.A.F. **Aplicações de redes neurais e neuro-fuzzy em engenharia biomédica e agronomia.** 2014. 82f. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual Paulista “Julio de Mesquita Filho”, Ilha Solteira, 2014.

WICKRAMAARACHCHI, W.P.T.M.; PERERA, N.N.S.; JAYASINGHE, S. Modelling and analysis of dengue disease transmission in urban Colombo: a wavelets and cross wavelets approach. **J Natn Sci Foundation Sri Lanka** v. 43, n. 4, p. 337-345, 2015.

YUSOF, Y.; MUSTAFFA, Z. Dengue outbreak prediction: a least squares support Vector Machines approach. **Int J Comput Theory En.**, v.3, n.4, p.489-493, 2011.

ZHU, H. *et al.* A power prediction method for photovoltaic power plant based on Wavelet Decomposition and Artificial Neural Networks. **Energies**, v.9, n.11, p.1-15, 2016.

1 Acadêmico em Engenharia Química, Universidade Federal de Alagoas – UFAL, Maceió, Alagoas, Brasil. E-mail: eq.arthurpms@gmail.com

2 Acadêmico em Engenharia Química, Universidade Federal de Alagoas – UFAL; Programa Especial de Capacitação Discente (PEC), Maceió, Alagoas, Brasil. E-mail: pedro.pereira@ctec.ufal.br

3 Acadêmica em Engenharia Química, Universidade Federal de Alagoas – UFAL, Maceió, Alagoas, Brasil. E-mail: cavalcante.eq.ufal@gmail.com

4 Acadêmico em Engenharia Química, Universidade Federal de Alagoas – UFAL, Maceió, Alagoas, Brasil. E-mail: lucascosta_108@hotmail.com

5 Doutor em Engenharia Química pela Universidade Estadual de Campinas – Unicamp; Grupo de Pesquisa Qualidade, Meio Ambiente e Energia; Docente da Universidade Federal de Alagoas – UFAL, Maceió, Alagoas, Brasil. E-mail: fredcarvalho@yahoo.com.br

Recebido em: 8 de Fevereiro de 2018

Avaliado em: 11 de Maio de 2018

Aceito em: 25 de Maio de 2018
