

Previsão de Casos de Dengue em Itajaí - SC por meio de Redes Neurais Artificiais Multicamadas e Recorrentes

MunIQUE Mittelmann¹, Daniel Gomes Soares¹

¹Instituto Federal Catarinense (IFC) – Campus Rio do Sul
Rua Abraham Lincoln – 89160-202 – Rio do Sul – SC – Brasil
muniquee@gmail.com, daniel@ifc-riodosul.edu.br

Abstract. *Dengue is a disease transmitted by female Aedes mosquitoes, mainly by the specie Aedes aegypti. Being possible to take preventive actions for effective control of the disease, a prediction of the incidence of dengue acquires an indispensable social role. Among the techniques that can be used in the elaboration of prediction models, such as Artificial Neural Networks (ANNs). In this work, is developed a predictive model of dengue cases with RNAs in Itajaí - SC. The neural networks were modeled and trained with different initial bases. The results showed that RNAs were very effective in predicting the number of dengue confirmed-cases.*

Resumo. *A dengue é uma doença transmitida pela picada de mosquitos do gênero Aedes, sobretudo pela espécie Aedes aegypti. Ao possibilitar a tomada de ações preventivas para um controle efetivo da doença, a previsão da incidência da dengue adquire um papel social indispensável. Dentre as técnicas que podem ser utilizadas na elaboração de modelos de previsão, incluem-se as Redes Neurais Artificiais (RNAs). O propósito deste trabalho é desenvolver um modelo de previsão de dengue com RNAs para o município de Itajaí - SC. Foram modeladas e treinadas redes com diferentes parâmetros iniciais. Os resultados mostram que é possível realizar a previsão de dengue na área de estudo por meio de RNAs com erro e antecedência aceitáveis.*

1. Introdução

A dengue é uma doença infecciosa transmitida pela fêmea de mosquitos do gênero *Aedes*. A Organização Mundial da Saúde (WHO – World Health Organization) calcula que ocorram anualmente de 50 a 100 milhões de casos de dengue em todo o mundo [Aburas, Cetiner e Sari 2010]. Apesar de ser um problema de saúde pública mundial, países tropicais, como o Brasil, são os mais atingidos pela dengue em virtude das suas características ambientais, climáticas e sociais [Ribeiro *et al.* 2006].

De acordo com Gharbi *et al.* (2011), um alerta precoce de surtos de dengue pode aumentar a eficácia de campanhas de controle do vetor e contribuir no direcionamento de ações preventivas. Deste modo, intervenções precoces tem a capacidade de atrasar a epidemia e assim reduzir seu impacto no sistema de saúde. Phung *et al.* (2015) complementam que modelos de previsão podem ser uma ferramenta válida na preparação e controle de uma epidemia. Neste cenário, as instituições de saúde poderiam organizar a disponibilidade de leitos e a mobilização de recursos humanos e materiais. Estes fatores possibilitariam uma resposta mais adequada dos órgãos de saúde

pública e, conseqüentemente, a minimização da taxa de mortalidade da doença [Gharbi *et al.* 2011].

Ao possibilitar a tomada de ações preventivas para um controle efetivo da doença, a previsão da incidência da dengue adquire um papel social indispensável. Dentre as técnicas que podem ser utilizadas na elaboração de modelos de previsão, incluem-se as Redes Neurais Artificiais (RNAs). O uso de RNAs na previsão de séries temporais vem crescendo nos últimos anos. Modelos de previsão que utilizam esta técnica têm apresentado resultados com baixo erro em diversos tipos de aplicação, inclusive previsão de dengue, conforme pode ser observado no estudo de Aburas, Cetiner e Sari (2010).

Este trabalho apresenta os resultados de um modelo de previsão de casos de dengue para o município de Itajaí (Santa Catarina) por meio da técnica de Redes Neurais Artificiais. Além disso, o trabalho compara a utilização de diferentes arquiteturas de Redes Neurais, especificamente, redes Perceptron Multicamadas (MLP) e Redes Neurais Auto-Regressivas com Entradas Exógenas (NARX).

2. Redes Neurais Artificiais

Uma RNA pode ser definida como um processador paralelamente distribuído constituído de unidades de processamento simples, os neurônios artificiais, os quais possuem a capacidade de armazenar conhecimento experimental e disponibilizá-lo para uso [Haykin 2001]. Segundo Loesch e Sari (1996), os neurônios artificiais, que são emulações simplificadas de neurônios biológicos, recebem informações de sensores ou de outros neurônios artificiais, em seguida produzem operações simples sobre estes dados e então passam o resultado para outros neurônios artificiais.

Além disso, as RNAs podem ser consideradas ferramentas poderosas para aplicação em diversos tipos de problemas, pois, conforme apontam Silva, Spatti e Flauzino (2010), as características mais atrativas destes modelos consistem de suas elevadas habilidades em mapear sistemas não-lineares, aprendendo os comportamentos a partir de informações (medidas, amostras ou padrões) obtidas.

2.1. Redes Multilayer Perceptron

Redes Multilayer Perceptron (MLP) pertencem à arquitetura neural conhecida como *feedforward* de camadas múltiplas, sendo caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a camada neural de saída. [Silva, Spatti e Flauzino 2010].

Os sinais são apresentados à rede em sua camada de entrada. As camadas intermediárias extraem a maioria das informações referentes ao seu comportamento e as codificam através dos pesos sinápticos e limiares de seus neurônios [Silva, Spatti e Flauzino 2010]. O processamento realizado por cada neurônio de uma determinada entrada é definido pela combinação dos processamentos realizados pelos neurônios da camada anterior que estão conectados a ele [Braga, Carvalho e Ludermir 2011]. Os neurônios da camada de saída da rede recebem os estímulos vindos dos neurônios da última camada intermediária, produzindo um padrão de resposta que será a saída disponibilizada pela rede.

O processo de treinamento de redes MLP normalmente é realizado com o algoritmo *backpropagation*, que utiliza pares de entrada e saída para, por meio de um mecanismo de correção de erros, ajustar os pesos e limiares da rede [Braga, Carvalho e Ludermir 2011]. O treinamento ocorre por meio de aplicações sucessivas de duas fases. Na fase de *forward*, os sinais de uma amostra do conjunto de treinamento são inseridos nas entradas da rede e são propagados camada a camada até a produção das respectivas saídas. A seguir, são calculados os erros entre as respostas produzidas pela rede e as respostas desejadas. Em função dos valores destes erros, o algoritmo aplica a fase *backward*, que executa alterações nos pesos sinápticos e limiares de todos os neurônios da rede. Assim, a aplicação sucessiva de ambas as fases faz com que os pesos sinápticos e limiares de neurônios se ajustem em cada iteração, de modo que haja uma gradativa diminuição da soma dos erros produzidos pelas respostas da rede em comparação às desejadas [Silva, Spatti e Flauzino 2010].

2.2. Redes NARX

Redes auto-regressivas não-lineares com entradas exógenas (*Nonlinear Auto-regressive with exogenous inputs* - NARX) pertencem à arquitetura neural recorrente ou realimentada. Estas redes permitem a recuperação de respostas passadas a partir da realimentação de sinais produzidos em instantes anteriores [Silva, Spatti e Flauzino 2010]. Em uma NARX, a predição de valores futuros associados ao comportamento do processo, a partir do instante t , será também baseada em função dos valores anteriores que foram produzidos por suas saídas.

Uma rede NARX executa, implicitamente, o mapeamento entre entradas e saídas de processos que sejam tanto não-lineares como também variantes no tempo. O treinamento de uma rede NARX é efetuado de maneira similar ao de uma MLP, ou seja, promovendo o ajuste dos pesos para minimizar o erro entre o valor esperado e a resposta estimada pela rede [Silva, Spatti e Flauzino 2010].

3. Metodologia

3.1. Área de Estudo

A cidade de Itajaí é uma cidade litorânea, situada no Vale do Itajaí, norte de Santa Catarina. Sua população estimada para o ano de 2015 foi de 205.271 habitantes. A densidade demográfica do município, no ano de 2010, foi de 636,11 habitantes/km², sendo que cerca de 94,6% da população vive na área urbana [IBGE 2016].

Itajaí é um dos 27 municípios catarinenses que apresentou manutenção e presença disseminada do vetor da dengue, ou seja, com infestação da doença. Em 2015, o município de Itajaí registrou a primeira epidemia de dengue no estado, com registro de mais de 3.244 casos autóctones da doença [DIVE 2015].

3.2. Dados Disponíveis

Os estudos de Ribeiro *et al.* (2006) e de Lima, Firmino e Gomes Filho (2008) evidenciam a relação de variáveis climáticas com a incidência de dengue. Deste modo, a inclusão de informações climáticas em modelos de previsão de casos de dengue pode aumentar sua eficácia. Neste estudo, foram utilizados dados meteorológicos de Itajaí, os

quais foram obtidos através do Instituto Nacional de Meteorologia (INMET). A base de dados meteorológicos consiste em dados mensais de julho de 2010 a junho de 2015 referentes a precipitação total (mm), temperatura máxima (°C), temperatura mínima (°C), temperatura média do ar (°C) e umidade relativa média do ar (%).

A quantidade mensal de casos confirmados de dengue em Itajaí foi obtida através dos sistemas TABNET (dados de julho de 2010 a dezembro de 2012) e SINAN - Sistema de Informação de Agravos de Notificação (dados de janeiro de 2013 a junho de 2015). Os dados obtidos não possuíam divisão em relação a origem da doença. Deste modo, os casos confirmados de dengue no município de Itajaí incluem tanto casos autóctones quanto casos importados.

Antes de utilizar os dados na rede neural, foi realizada a normalização dos dados. Este processo objetiva escalonar as amostras de dados para a faixa de valores dinâmica das funções de ativação das camadas escondidas, de modo a evitar a saturação dos neurônios [Silva, Spatti e Flauzino 2010].

Este trabalho utilizou a estratégia conhecida como validação cruzada por amostragem aleatória, na qual 70% do conjunto total de dados disponíveis foram aleatoriamente escolhidos para o subconjunto de treinamento. Por sua vez, os dados restantes (30%) integraram o subconjunto de teste e validação.

3.3. RNA proposta

As RNAs construídas neste trabalho possuem seis entradas, uma camada intermediária com n neurônios e um neurônio na camada de saída. A Figura 1 ilustra o modelo de rede MLP empregado para a previsão de casos de dengue em Itajaí.




Figura 1. Modelo de MLP para previsão de casos de dengue em Itajaí

Nas redes NARX modeladas, optou-se pela utilização de dois atrasos nos valores de entrada e dois atrasos de realimentação, após a realização de alguns testes preliminares com atrasos maiores houve a constatação de que nestes não havia melhorias significativas nos resultados das redes.

A Figura 2 apresenta o modelo de rede NARX adotado, com dois atrasos de entrada e dois atrasos de realimentação, nos quais a saída estimada da rede nos

momentos anteriores também é utilizada como parâmetro de entrada da rede no momento atual.

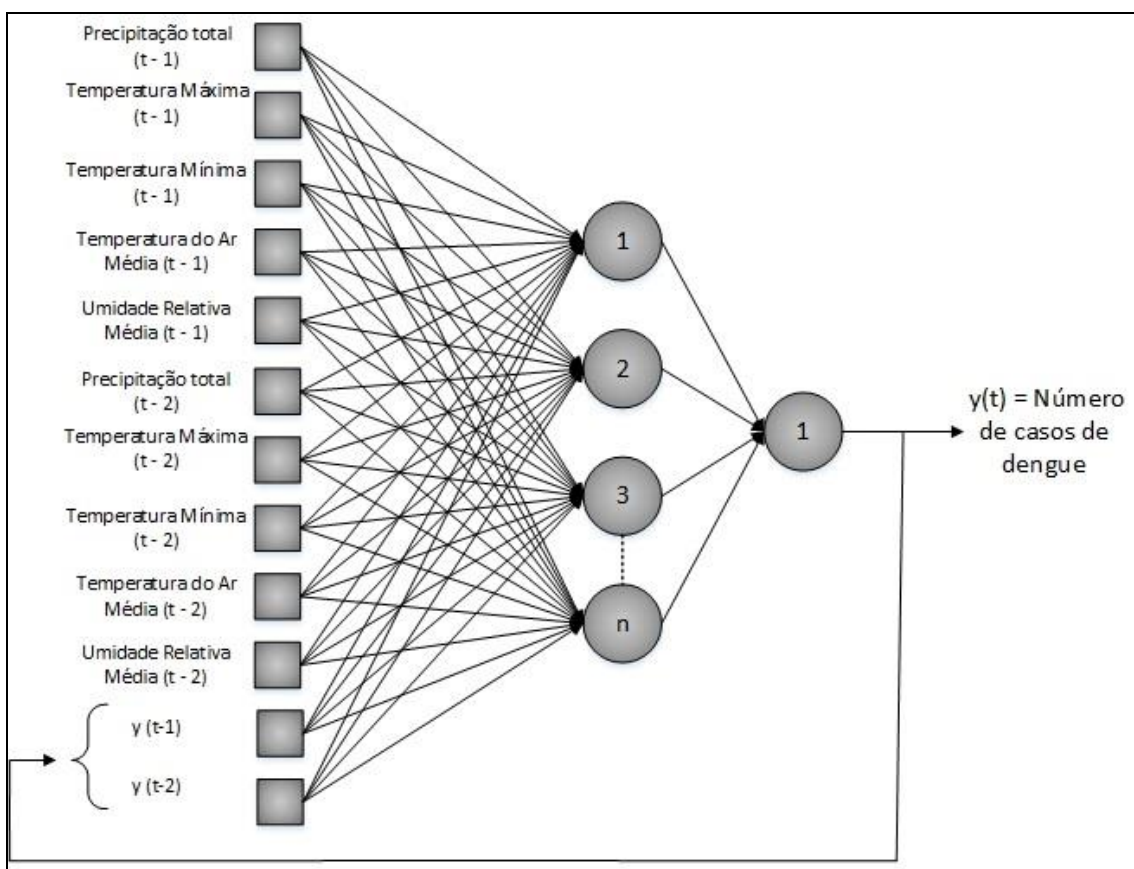


Figura 2. Modelo de NARX para previsão de casos de dengue em Itajaí

Além das redes descritas, foram modeladas RNAs com 15 variações do conjunto de entrada. Por exemplo, algumas redes não incluíram como entrada dados de todas as variáveis ou adicionaram informações referentes ao número de casos de dengue dos meses anteriores.

3.4. Índices para análise da qualidade de previsão

Os índices para avaliação da qualidade da previsão adotados neste trabalho foram o RMSE (Raiz do Erro Quadrático Médio) e o MAPE (Erro Médio Percentual Absoluto). A seguir, são apresentadas as equações para o cálculo destes índices.

O RMSE pode ser calculado por:

$$RMSE = \sqrt{\frac{\sum_{k=1}^n (t_k - o_k)^2}{n}} \quad (1)$$

Por sua vez, o MAPE é definido pela seguinte equação:

$$MAPE = \frac{1}{n} \cdot \sum_{k=1}^n \frac{|t_k - o_k|}{(t_k + o_k)/2} \cdot 100\% \quad (2)$$

Nos quais t_k representa a saída esperada na amostra k (valor alvo ou observado), o_k é a saída da rede (valor previsto) para a amostra k e n é o número total de amostras [Prema e Rao 2015; Zafari, Kianmehr, Abdolhazadeh 2013]. O RMSE tem sua unidade igual aos valores de saída da rede, enquanto o MAPE é representado por uma porcentagem. Em ambas as métricas de erro, o valor mais próximo de zero indica um melhor desempenho da rede.

4. Resultados e Discussão

Para a previsão de casos de dengue em Itajaí, foram treinadas e testadas um total de 660 redes MLP e a mesma quantidade de redes NARX. Além do conjunto de entrada das RNAs, nestes treinamentos e testes foram alterados os seguintes parâmetros das redes: a função de ativação da camada oculta, o algoritmo de treinamento e a quantidade de neurônios na camada intermediária (5 a 15 neurônios). Alguns testes foram realizados com menos de cinco e mais de quinze neurônios na camada oculta, entretanto, a rede não produziu melhoras significativas nos resultados, apenas aumentava consideravelmente o tempo de treinamento.

Além disso, cada uma destas configurações de RNA, tanto MLP como NARX, foram treinadas 50 vezes, com o objetivo de minimizar os efeitos causados pela aleatoriedade das condições iniciais.

Em relação às redes MLP, a rede que obteve o melhor RMSE no conjunto de testes ($6,65 \cdot 10^{-4}$) foi treinada com o algoritmo de Levenberg-Marquardt, função de ativação logística e 6 neurônios na camada oculta. A Figura 3 apresenta a comparação entre a saída calculada pela RNA e o número de casos mensais observados. Pela comparação gráfica, é possível perceber um pequeno erro da previsão antes de ocorrer um surto (grande número de casos) da doença.




Figura 3. Valores reais observados e calculados pela MLP com menor RMSE

A rede MLP que obteve o melhor MAPE (0,036995 %) foi treinada com o algoritmo de Regularização Bayesiana, função de ativação tangente hiperbólica e 8 neurônios na camada oculta. A Figura 4 apresenta a comparação entre a saída calculada

pela RNA e o número de casos mensais observados. O erro entre a saída calculada e a saída desejada praticamente não é perceptível pela comparação gráfica.




Figura 4. Valores reais observados e calculados pela MLP com menor MAPE

Ambas as MLPs apresentadas obtiveram baixos erros e foram modeladas incluindo as informações de casos de dengue de um ou dois meses anteriores. Pela comparação gráfica, percebe-se que ocorreram menos erros significativos na previsão da rede treinada com o menor MAPE, por isto, esta rede foi eleita a melhor MLP para previsão na área de estudo selecionada.

Em relação as redes NARX, o melhor RMSE no conjunto de testes obtido foi de $7,17 \cdot 10^{-04}$. A rede que obteve este resultado foi treinada com o algoritmo de Levenberg-Marquardt, função de ativação logística e utilizou 7 neurônios na camada oculta. A Figura 5 apresenta a comparação entre a saída calculada e o número de casos mensais observados.

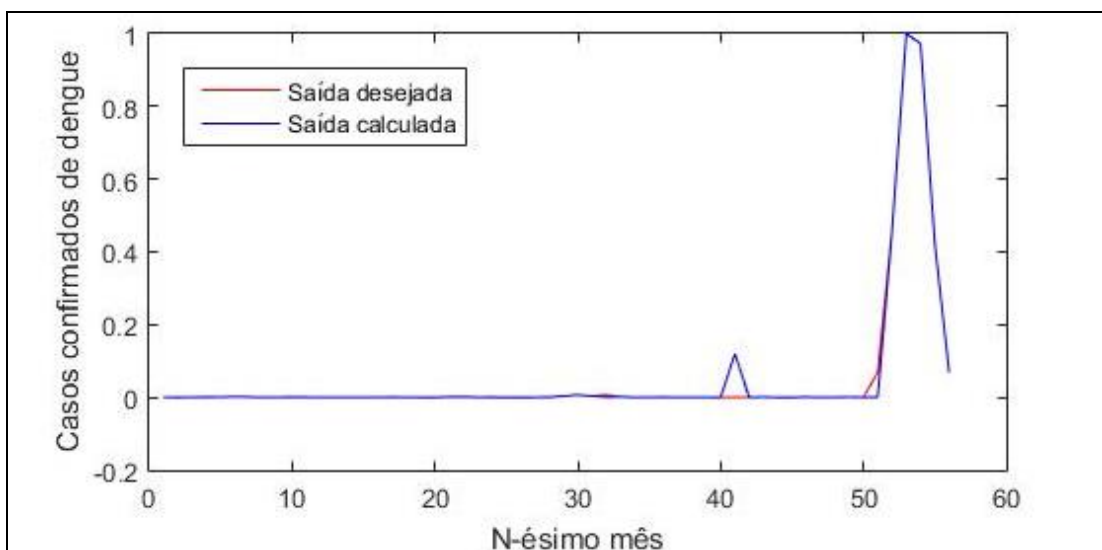


Figura 5. Valores reais observados e calculados pela NARX com menor RMSE

O melhor MAPE obtido pelas redes NARX foi de apenas 0,053705 %. A rede que atingiu este resultado foi treinada com o algoritmo de Levenberg-Marquardt, função de ativação tangente hiperbólica e apenas 5 neurônios na camada oculta. A Figura 6 compara a saída calculada pela rede NARX e o número de casos observados. O erro entre a saída calculada e a desejada praticamente não é perceptível pela comparação gráfica.




Figura 6. Valores reais observados e calculados pela NARX com menor MAPE

Ambas as redes NARX apresentadas obtiveram erros baixos. Entretanto, pela comparação gráfica, a segunda rede aparentou uma melhor previsão do número de casos de dengue. Além disso, esta rede precisou de menos neurônios na camada oculta. Deste modo, a rede com menor MAPE foi eleita a melhor NARX para previsão na região de estudo escolhida.

Assim sendo, a melhor rede MLP foi treinada com 8 neurônios na camada oculta função de ativação tangente hiperbólica e com o algoritmo de Regularização Bayesiana. Seus erros MAPE e RMSE no conjunto de testes foram, respectivamente, 0,0369% e $2,68 \cdot 10^{-3}$. Por sua vez, a rede NARX com melhor desempenho foi a alternativa com 5 neurônios na camada intermediária, função de ativação tangente hiperbólica e algoritmo de treinamento de Levenberg-Marquardt. Esta rede obteve MAPE de 0,0537% e RMSE de $1,02 \cdot 10^{-3}$.

Comparando-se as redes escolhidas como melhores MLP e NARX, pode-se observar que a rede MLP obteve um desempenho superior à rede NARX em relação ao MAPE, enquanto que a rede NARX atingiu o menor RMSE. A Tabela 1 apresenta a comparação entre a quantidade de casos de dengue calculada pelas redes com alguns valores reais observados.

Tabela 1. Previsões para Itajaí realizadas pelas redes MLP e NARX eleitas

Mês observado	Casos de dengue	Previsão (casos)		Módulo do Erro (casos)	
		MLP	NARX	MLP	NARX
Fevereiro/2011	2	1,9991	2,0031	0,000862	0,003192
Abril/2013	7	7,0004	6,9896	0,000409	0,010338

Julho/2014	1	0,9988	1,3081	0,001141	0,308197
Janeiro/2015	72	71,9998	71,9821	0,000156	0,017805
Março/2015	1050	1049,9999	1049,9867	$2,58 \cdot 10^{-05}$	0,013253

Conforme apresentado pela Tabela 1, ambas as alternativas de rede neural não tiveram erros significativos na previsão. Entretanto, a rede MLP atingiu maior precisão na estimação dos valores selecionados.

Deste modo, analisando as métricas de erro e os resultados apresentados na Tabela 1, chega-se à conclusão que a RNA mais aderente à área de estudo foi a rede MLP cujo conjunto de entrada foi composto pelos dados referentes à precipitação, temperatura máxima, mínima e do ar, umidade relativa e ao número de casos confirmados de dengue no mês anterior. Os resultados apresentados pela rede mostram que é possível fazer a previsão de casos de dengue em Itajaí, utilizando RNAs com dados meteorológicos e históricos da quantidade de casos de dengue.

5. Conclusões

Este trabalho descreve a modelagem de RNAs para o problema de previsão de casos de dengue em Itajaí - SC. Além disso, este trabalho compara a utilização de duas arquiteturas distintas de RNAs, as redes Perceptron Multicamadas e as Redes Neurais Auto-Regressivas com Entradas Exógenas.

As redes MLPs e NARXs foram comparadas entre si para eleição da rede com melhor desempenho na previsão de dengue na área de estudo. Assim, o melhor desempenho foi obtido pela MLP treinada com 8 neurônios na camada oculta, função de ativação tangente hiperbólica e o algoritmo de Levenberg-Marquardt. O conjunto de entrada que obteve este resultado foi composto pelos dados referentes à precipitação, temperatura máxima, mínima, temperatura do ar, umidade relativa e ao número de casos confirmados de dengue no mês anterior.

Os resultados apresentados pelas redes mostram que é possível fazer a previsão de casos de dengue nas áreas de estudo, utilizando RNAs com dados meteorológicos e históricos da quantidade de casos de dengue de meses anteriores. No entanto, cabe salientar que como toda modelagem matemática, a generalização dos resultados obtidos em um estudo de caso específico não pode ser utilizada diretamente para outros casos, pois se deve levar em consideração que as características de cada região são únicas, sendo a utilização dos modelos construídos neste trabalho restrita a área de estudo selecionada.

Para trabalhos futuros, sugere-se o desenvolvimento de um portal que aplique o modelo, visando disponibilizar informações que possam auxiliar a população e os órgãos públicos na preparação e controle de uma possível epidemia de dengue.

Referências

- Aburas, H. M., Cetiner, B. G. and Sari, M. (2010). Dengue confirmed-cases prediction: A neural network model. *Expert Systems with Applications*, v. 37, n. 6, p. 4256–4260.
- Braga, A. de P., Carvalho, A. P. de L. F. De and Ludermit, T. B. (2011). *Redes Neurais Artificiais: Teoria e Aplicações*. 2. ed. Rio de Janeiro: LTC.

- DIRETORIA DE VIGILÂNCIA EPIDEMIOLÓGICA DE SANTA CATARINA (DIVE).
Nota Técnica Nº 08/2015/DIVE/SUV/SES, 2015. Disponível em:
<<http://www.dive.sc.gov.br/>>. Acesso: 4 de junho de 2015.
- Gharbi, M., Quenel, P., Gustave, J., et al. (2011). Time series analysis of dengue incidence in Guadeloupe, French West Indies: forecasting models using climate variables as predictors. *BMC infectious diseases*, v. 11, n. August 2015, p. 166.
- Haykin, S. (2001). *Redes neurais: princípios e práticas*. 2. ed. Porto Alegre: Bookmann.
- IBGE. Itajaí, 2016. Disponível em: <<http://cidades.ibge.gov.br/>>. Acesso em: 9 de agosto de 2016.
- Loesch, C. and Sari, S. T. (1996). *Redes Neurais Artificiais: Fundamentos e Modelos*. 1. ed. Blumenau: Editora da FURB.
- Lima, E. D. A., Firmino, J. L. D. N. and Gomes Filho, M. F. (2008). A relação da previsão da precipitação pluviométrica e casos de dengue nos estados de Alagoas e Paraíba nordeste do Brasil. *Revista Brasileira de Meteorologia*, v. 23, n. 3, p. 264–269.
- Phung, D., Huang, C., Rutherford, S., et al. (2015). Identification of the prediction model for dengue incidence in Can Tho city, a Mekong Delta area in Vietnam. *Acta Tropica*, v. 141, p. 88–96.
- Prema, V. and Rao, K. U. (2015). Time series decomposition model for accurate wind speed forecast. *Renewables: Wind, Water, and Solar*.
<http://www.jrenewables.com/content/2/1/18>.
- Ribeiro, A. F., Marques, G. R. a M., Voltolini, J. C. and Condino, M. L. F. (2006). Associação entre incidência de dengue e variáveis climáticas. *Revista de Saude Publica*, v. 40, n. 4, p. 671–676.
- Silva, I. N. Da, Spatti, D. H. and Flauzino, R. A. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber.
- Zafari, A., Kianmehr, M. H. and Abdolahzadeh, R. (2013). Modeling the effect of extrusion parameters on density of biomass pellet using artificial neural network. *International Journal Of Recycling of Organic Waste in Agriculture*, v. 2, n. 1, p. 9.