

UNIVERSIDADE FEDERAL DO PARANÁ

LUANA BORATO

**USO DE REDES NEURAS ARTIFICIAIS PARA PREVISÃO DAS FLUTUAÇÕES
DO NÍVEL DO MAR EM CANANÉIA, SÃO PAULO, BRASIL**

PONTAL DO PARANÁ

2018

LUANA BORATO

**USO DE REDES NEURAS ARTIFICIAIS PARA PREVISÃO DAS FLUTUAÇÕES
DO NÍVEL DO MAR EM CANANÉIA, SÃO PAULO, BRASIL**

Monografia apresentada como requisito parcial à obtenção do título de Oceanógrafo, Curso de Graduação em Oceanografia, Centro de Estudos do Mar, Universidade Federal do Paraná.

Orientadores: Dr. Daiane Gracieli Faller e Prof. Dr. Eduardo Marone

PONTAL DO PARANÁ

2018

CATALOGAÇÃO NA FONTE:

UFPR / SiBi - Biblioteca do Centro de Estudos do Mar

Fernanda Pigozzi – CRB 9/1151

Borato, Luana

B726u Uso de redes neurais artificiais para previsão das flutuações do nível do mar em Cananéia, São Paulo, Brasil. / Luana Borato. – Pontal do Paraná, 2018.

85 f.: il., 29 cm.

Orientadora: Dra. Daiane Gracieli Faller.

Orientador: Prof. Dr. Eduardo Marone.

Monografia (Graduação) – Curso de Oceanografia, Centro de Estudos do Mar, Setor de Ciências da Terra, Universidade Federal do Paraná.

1. Redes neurais - artificiais. 2. Maré meteorológica - previsão. 3. Oceanografia. I. Título. II. Faller, Daiane Gracieli. III. Marone, Eduardo. IV. Universidade Federal do Paraná.

CDD 551.46

TERMO DE APROVAÇÃO

Luana Borato

“USO DE REDES NEURAIAS ARTIFICIAIS PARA PREVISÃO DE MARÉ METEOROLÓGICA EM CANANÉIA, SÃO PAULO”

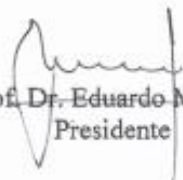
Monografia aprovada como requisito parcial para a obtenção do grau de
Bacharel em Oceanografia, da Universidade Federal do Paraná, pela
Comissão formada pelos membros:


Prof. Dr. Marcos Nicolas Gallo - COPPE/UFRJ


Prof. Dr. Ricardo de Camargo - IAG/USP


Prof. Dr. Mauricio de Almeida Noernberg - CEM/UFPR


Dra. Daiane Gracieli Falleo - LAMCE/COPPE/UFRJ


Prof. Dr. Eduardo Marone
Presidente

Pontal do Paraná, 07 de dezembro de 2018.

AGRADECIMENTOS

Agradeço à Daiane Gracieli Faller, pela paciência, pelo carisma e empatia e acima de tudo, por me incentivar a dar sempre o melhor e concluir esse trabalho com a certeza de que uma monografia não precisa ser dolorida nem “só uma monografia, mas a minha monografia”. Tomo essas palavras para dizer: não foi mesmo só uma monografia, foi um trabalho em equipe, uma experiência científica e um crescimento inestimável para minha profissão. Ter o prazer em dizer ser sua orientada é o que mais “brilha o olho” no meu trabalho. Essa é a nossa monografia.

Ao professor e meu orientador, Eduardo Marone, não só pelo apoio e orientação durante o processo de construção desse trabalho, mas por todo incentivo e suporte durante a graduação. Por acreditar e confiar nas minhas iniciativas e no meu trabalho dentro do Grupo de Física Marinha e pelo International Ocean Institute. Agradeço, em especial, a oportunidade em trabalhar junto do Instituto que me inspirou durante os últimos anos de graduação e me fez acreditar que a ciência é muito mais que gerar e/ou reproduzir dados. Graças a essas experiências concluo a graduação me sentindo primeiramente humana antes de ser oceanógrafa.

Agradeço à minha família. Aos meus pais, pelo apoio e esforço tentando sempre me dar o melhor. Às minhas irmãs que sempre me incentivaram, em especial a Aline Borato que ouviu e consolou meus desânimos e esteve junto, mesmo longe, nos dias ruins. Obrigada por serem meus exemplos.

Agradeço ao meu companheiro de graduação, Bruce. Esse trabalho se finaliza, em boa parte, pela perseverança e insistência que aprendi com você.

À Biblioteca do Centro de Estudos do Mar que é o melhor lugar para se estar dentro desse campus. Tenho certeza que aprendi mais em um ano trabalhando com essa equipe incrível do que em 4 anos de sala de aula. Aqui cabe um agradecimento especial a Caroline Felema, Bruno Gabriel Costelini, Ivo Spring, Camila Kerkhof, Daiana Lopes, Liliam Orquiza e Elda Lopes Lira, que foram as pessoas que estiveram comigo nesse capítulo da graduação.

Agradeço aos meus colegas e amigos que levo da graduação, em especial a Janayne Viebrantz, que tive a oportunidade de compartilhar uma casa e muitas conversas. Agradeço também a Mariana Aguirre e o Vitor Reis, que sempre estiveram dispostos a me ajudar e acompanharam de perto cada passo desse trabalho. Agradeço também toda oportunidade e crescimento que o GRR2014 me proporcionou.

Para ser grande, sê inteiro: nada

Teu exagera ou exclui.

Sê todo em cada coisa. Põe quanto és

No mínimo que fazes.

Assim em cada lago a lua toda

Brilha, porque alta vive

Ricardo Reis, in "Odes"

Heterónimo de Fernando Pessoa

RESUMO

As flutuações do nível relativo do mar representam um dos maiores impactos na dinâmica da zona costeira, em particular, em função das mudanças climáticas. Nesse cenário, previsões robustas da maré meteorológica e ressacas são importantes para a resiliência e adaptação dessas áreas e das pessoas que vivem e dependem desse ambiente. Neste trabalho, foi testado um modelo numérico baseado em redes neurais artificiais (RNA), com o objetivo de avaliar diferentes arquiteturas de rede e métodos de treinamento de uma RNA de múltiplas camadas (*multilayer perceptron* – MLP) através de simulações para prever uma série histórica (*hindcast*) de maré meteorológica na região de Cananéia (São Paulo). O processamento dos dados envolveu a extração da maré astronômica usando o filtro de Godin (1972), o cálculo das componentes e da tensão de cisalhamento do vento e, a interpolação de dados faltantes na série de dados meteorológicos. A RNA-MLP foi treinada usando uma série temporal de quatro anos (2003-2006), com os dados de maré da região de Cananéia (São Paulo) e os dados meteorológicos de duas fontes distintas: estação meteorológica de Pontal do Sul (Paraná) e de reanálise disponibilizados pelo *National Centers for Environmental Prediction (NCEP) Climate Forecast System Reanalysis (CFSR)*. Para o treinamento das redes, além de diferentes arquiteturas também foram testados três algoritmos de treinamento: gradiente descendente, gradiente descendente com aprendizado adaptativo e Levenberg-Marquardt. A comparação entre as séries previstas e observadas foi feita através do coeficiente de correlação (R), da raiz quadrada do erro quadrático médio (RMSE) e do erro médio absoluto (MAE). Dentre os 23328 testes realizados, a melhor arquitetura de rede obteve R igual à 0,96, RMSE igual à 0,11 cm e MAE igual à 8,32 cm. O método de treinamento que apresentou melhor desempenho foi o de Levenberg-Marquardt seguido do método do gradiente descendente com aprendizado adaptativo. O modelo mais satisfatório desenvolvido nesse trabalho apresentou uma melhora de 9,3% na previsão do nível do mar quanto comparado ao método harmônico.

Palavras – chave: maré meteorológica, redes neurais artificiais, previsão, oceanografia.

ABSTRACT

The sea level fluctuations represent one of the most relevant forcing of the coastal zone dynamics, particularly under the context of climate changes. In this scenario, reliable forecasts of meteorological tides and storm surges are very important for the resilience and adaptive capacity of these areas. In the present work, we tested a numerical model based on artificial neural networks (ANN) to evaluate different network structures and training methods of an ANN multilayer perceptron (MLP) to predict the meteorological tide in Cananéia (São Paulo). The data processing involves the extraction of the astronomical tide using the Godin filter, the calculation of wind components (u and v), wind stress and the fulfilling of missing data from the meteorological time-series by interpolation. To train the ANN, it was used a meteorological tide dataset with four years of hourly data (2003-2006) from Cananéia (São Paulo) and a meteorological dataset (wind, atmospheric pressure) from two different sources: Pontal do Sul meteorological station (Paraná) and reanalysis data from NCEP CFSR. Three training algorithms are being analyzed: the gradient descent, the gradient descent with adaptive learning and the Levenberg-Marquardt. Several metric analyses were conducted to assess and compare the results obtained with the ANN experiments and the observational data: correlation coefficient (R), Root Mean Squared Error (RMSE) and Mean Absolute Error (MAE). Among the 23328 tests, the best ANN-MLP attained R equal to 0.96, RMSE equal to 0.11 cm and MAE equal to 8.32 cm. The better performance training method was the Levenberg-Marquardt and the gradient descent with adaptive learning. The most satisfactory model developed in this study showed an improved of 9.3% in sea level prediction when compared to the harmonic method.

Keywords: meteorological tides, artificial neural network, forecast, oceanography.

SUMÁRIO

1 INTRODUÇÃO	11
1.1 JUSTIFICATIVA	13
2 OBJETIVOS	15
2.1 OBJETIVO GERAL.....	15
2.2 OBJETIVOS ESPECÍFICOS	15
3 REFERENCIAL TEÓRICO	16
3.1 MARÉS.....	16
3.1.1 Maré astronômica.....	16
3.1.2 Maré meteorológica.....	23
3.1.3 Métodos de previsão de maré	25
3.2 REDES NEURAS ARTIFICIAIS	27
3.2.1 <i>Multilayer perceptron (MLP)</i>	33
4 MATERIAIS E MÉTODOS	36
4.1 ESTUDO DE CASO	36
4.2 CONJUNTO E PROCESSAMENTO DE DADOS	38
4.2.1 Processamento dos dados de nível do mar	39
4.2.2 Processamento dos dados meteorológicos.....	44
4.3 TREINAMENTO E IMPLEMENTAÇÃO DA RNA-MLP	46
5 RESULTADOS E DISCUSSÃO	49
5.1 ANÁLISE DAS SÉRIES TEMPORAIS	50
5.2 TESTES PRELIMINARES	55
5.3 DESEMPENHO DA RNA-MLP NAS SIMULAÇÕES DA MARÉ METEOROLÓGICA	58

6 CONCLUSÃO	71
REFERÊNCIAS	73
APÊNDICE I	82
APÊNDICE II	83
APÊNDICE III	84

1 INTRODUÇÃO

A previsão das variações do nível do mar nas regiões costeiras pode ser uma tarefa bastante difícil devido à complexidade dos processos morfodinâmicos que interagem nestas regiões. Ou seja, a variação do nível do mar depende das diferentes interações do oceano com seus limites, como o fundo oceânico, as bordas continentais e a atmosfera, assim como sofre influência astronômica, causada pelas forças de atração do Sol e da Lua.

As marés provocadas pela ação das forças de atração do Sol e da Lua são chamadas de marés astronômicas. As marés ocasionadas pelos outros fatores acima citados podem ser entendidas, de forma mais abrangente, como *maré não astronômica* ou *nível não astronômico*, como sugerido por Melo Filho (2017). Em geral, as interações entre o oceano e atmosfera apresentam maior impacto nas variações de curto prazo do nível do mar que os demais fatores como mudanças de relevo oceânico. Por esse motivo, a maré de origem não astronômica será designada neste trabalho apenas por maré meteorológica.

Uma das primeiras definições de maré meteorológica foi fornecida por Pugh, em 1996. Segundo ele, a maré meteorológica é a diferença entre a maré prevista e a maré real observada. Historicamente é comum encontrar essa definição, já que as primeiras previsões de maré foram desenvolvidas apenas para prever a sua parcela astronômica. A exemplo disso, no Brasil, as previsões são elaboradas a partir do método da análise harmônica descrito por Franco e Rock (1971) e publicadas anualmente pelo Centro de Hidrografia da Marinha (CHM) nas Tábuas de Maré.

O problema do método de Franco e Rock (1971) é que a maré meteorológica não é contemplada porque, como dito anteriormente, depende das interações entre o oceano e atmosfera e não dos fatores astronômicos. No Brasil, a imprevisibilidade desses eventos pode afetar diretamente 26% da população total do país que vivem em regiões costeiras e estão vulneráveis às variações do nível do mar (CEPAL, 2015).

O atual cenário mundial e brasileiro inspira a necessidade de desenvolvimento e aplicação de novas técnicas para a previsão das flutuações do nível do mar em resposta a eventos atmosféricos. Assim, foi selecionado um período de observações do nível do mar e de variáveis atmosféricas da região de Cananéia, no sul do estado de São Paulo, para testar uma metodologia diferenciada que inclui a maré meteorológica nas previsões do nível do mar. Essa metodologia se baseia na forma de aprendizado do cérebro humano, através de treinamento e

repetição. Por sua similaridade com o nosso sistema nervoso ela é chamada de Rede Neural Artificial (RNA) e seus primeiros modelos foram desenvolvidos na década de 40.

Dentre as muitas outras aplicações na oceanografia e ciências ambientais, destaca-se o uso de RNAs empregadas na estimativa da produção primária e biomassa nos oceanos, previsão de vazões de rios e taxas de precipitação, assimilação de dados de correntes oceânicas e análise de padrões e séries temporais (DEDECKER; GOETHALS; PAUW, 2002; TABACH et al., 2007; PASINI, 2009; DEO, 2010; PATIL; DEO, 2017).

Grande parte do sucesso das RNAs, não somente nas ciências ambientais, é devido a facilidade da sua aplicação e das suas distintas propriedades e capacidade de generalização. A capacidade de trabalhar com a não-linearidade dos dados de diversas naturezas, como é o caso de dados meteoceanográficos, é uma das propriedades mais atrativas das RNAs como ferramenta em trabalhos similares a este. Além dessa propriedade, as RNAs são capazes de mapear um caminho entre dados de entrada e saída e se adaptar até que esse caminho seja ótimo ou próximo do esperado.

Em trabalhos similares a este pode-se observar o desempenho das RNAs para previsão do nível do mar. Tsai e Lee (1999), Lee e Jeng (2002), Lee et al. (2002) e Lee (2004) utilizaram uma RNA com múltiplas camadas (do inglês *multilayer perceptron - MLP*) *backpropagation* com algoritmo de gradiente descendente, similar ao utilizado neste trabalho, que conseguiu realizar previsões satisfatórias para um mês, utilizando apenas os dados horários de um dia e para o período de um ano, utilizando os dados horários de 15 dias. Se pensarmos em previsões em tempo real, esse é um resultado bastante importante, pela quantidade reduzida de observações que foi requerida durante o experimento.

Ghorbani et al. (2010), com objetivo de sugerir uma melhor alternativa para a análise harmônica, compararam dois métodos de inteligência artificial para previsão do nível do mar: Programação Genética (do inglês *Genetic Programming*) e RNAs. Em alguns casos a programação genética apresentou melhores resultados, enquanto que em outros as RNAs obtiveram um melhor desempenho, entretanto, os dois métodos apresentaram boas performances como alternativas à análise harmônica.

Filippo et al. (2012) testou um modelo de RNA-MLP para São Paulo e Rio de Janeiro que pode ser associado à análise harmônica para melhorar as previsões de maré quando inseridos dados meteorológicos no treinamento da rede. Para a região de São Paulo, no trabalho citado, a aplicação da RNA-MLP reduziu em 12% a margem de erro nas previsões, mesmo com a baixa qualidade dos dados e ausência de alguns parâmetros locais no treinamento da RNA.

Uma aplicação prática e atual das RNAs também pode ser encontrada em Poseiro et al. (2018). O trabalho descreve uma metodologia que acopla uma RNA-MLP com as ferramentas do Sistema de Informações Geográficas (SIG), com intuito de aperfeiçoar as previsões de inundação utilizando como estudo de caso a Praia de Vitória, em Açores, Portugal. O trabalho citado é parte do Projeto HIDRALERTA (FORTES et al., 2013) e é um protótipo para a elaboração de um mapa de riscos para as regiões alagáveis no país.

Nos trabalhos acima citados, pode-se notar que existem diversos modelos de RNA que podem ser adaptados de acordo com o objetivo do pesquisador. Neste trabalho, foi utilizado um modelo com múltiplas camadas (*multilayer perceptron* – MLP) com alimentação direta (*feedforward*) e com algoritmo de aprendizagem por retropropagação do erro (*backpropagation*). Também foram testadas três variações de métodos de treinamento da rede: o método do gradiente descendente, do gradiente descendente com aprendizado adaptativo e de Levenberg-Marquardt.

Após a justificativa do presente trabalho a seguir, são apresentados os objetivos na seção 2. O item 3 foi elaborado com intuito de contextualizar o leitor nos principais conceitos, definições e métodos utilizados ao longo do trabalho. No item 4 pode ser encontrada uma descrição da área de onde foram utilizados os dados e também dos procedimentos e tratamento dos dados. No mesmo item, a arquitetura da RNA é explicada junto com os diferentes modelos que foram testados. Em 5 os resultados são apresentados e discutidos, seguido da conclusão no item 6.

1.1 JUSTIFICATIVA

A necessidade do desenvolvimento e/ou aprimoramento de técnicas para previsão do nível do mar, que incluam a maré meteorológica, se respalda em estudos e preocupações globais e nacionais. Um estudo da Comissão Econômica para América Latina e o Caribe (CEPAL), de 2015, publicado através da Organização das Nações Unidas (ONU), relata os efeitos das mudanças climáticas nas áreas costeiras da América Latina e do Caribe. A avaliação dos efeitos foi feita através de um banco de dados de 60 anos (1948-2010) e o primeiro capítulo do estudo é específico para impactos causados pelas variações no nível relativo do mar (NRM).

Segundo os dados apresentados pelos autores, a tendência geral para toda América Latina e Caribe é de aumento no NRM. Na costa brasileira, a taxa atual de elevação é em torno de 3 mm/ano e o cenário que assume um aumento de até 1 m, revela que 20% das pessoas que

moram nessas regiões seriam afetadas por esse aumento. Se a taxa de elevação do nível do mar se mantiver pelos próximos anos, estima-se que em aproximadamente 330 anos este cenário poderá se tornar realidade.

No Brasil, com um litoral de mais de 7 mil km de extensão, o que preocupa são os chamados desastres naturais ou eventos extremos. O nível de inundação para costa brasileira durante esses eventos é de cerca de 3 m com alta variabilidade entre eventos. Especula-se que com as mudanças climáticas os eventos extremos tendem a ser mais intensos e mais frequentes, colocando em risco a segurança de quase 10 milhões de pessoas no país. Esses eventos são compostos, principalmente, pelas grandes ondas de ressaca e elevação do NRM pelas marés meteorológicas (CEPAL, 2015; AUGUSTO, 2018).

No caso das marés meteorológicas, sabe-se que o nível do mar depende da variação de forçantes locais (incidência de vento, pressão atmosférica, temperatura, etc.) e, portanto, os métodos de previsão devem ser aperfeiçoados de acordo com cada região, como exemplo, no presente trabalho, a avaliação das melhores arquiteturas é especificamente para a região de Cananéia (São Paulo). Partindo desse resultado, estudos futuros poderão verificar a validade desse modelo para a previsão futura do NRM para a região e também a viabilidade de estender o uso da RNA para outros pontos da costa do Brasil.

No âmbito geral da oceanografia, existe uma vasta mobilização para popularização dessa ciência e incentivo no desenvolvimento de pesquisas na área. Foi pensando nisso que a Organização das Nações Unidas (ONU) estabeleceu, durante a Conferência dos Oceanos em 2017, a Década Internacional dos Oceanos que se iniciará no ano de 2021 e se estende até 2030 (ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU), 2017). O período será dedicado para o incentivo à pesquisa e preservação dos oceanos, dos quais cerca de 3 bilhões de pessoas dependem diretamente para suas necessidades básicas e, mesmo assim, conhecemos menos de 5% do total desse ambiente. Só para a economia, os oceanos representam em média 5% do PIB global, ou seja, 3 trilhões de dólares por ano (PLATAFORMA AGENDA 2030, 2018). A Conferência dos Oceanos também foi importante para o estabelecimento de metas e compromissos voluntários dos países em prol dos oceanos. O Brasil, além de se comprometer com medidas de enfoque a proteção e conservação da biodiversidade e dos ecossistemas marinhos, manifestou-se, através do Ministério do Meio Ambiente, com o Programa Nacional para a Conservação da Linha de Costa (PROCOSTA), cujo objetivo é gerar informações e dados sobre a linha de costa brasileira (AUGUSTO, 2018). É, também, nesse programa que se

inspira o presente trabalho, com intuito de contribuir para o monitoramento das costas brasileiras.

2 OBJETIVOS

2.1 OBJETIVO GERAL

O objetivo deste trabalho é avaliar a efetividade de uma metodologia baseada em redes neurais artificiais (RNA) do tipo *perceptron* de múltiplas camadas (do inglês *multilayer perceptron* - MLP) para a modelagem preditiva da maré meteorológica utilizando a combinação de forçantes astronômicas e meteorológicas.

2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos deste trabalho são:

- a) avaliar a previsão do nível do mar das RNAs-MLP para região de Cananéia (São Paulo, Brasil), considerando os parâmetros meteorológicos e astronômicos da maré;
- b) identificar através de diversos experimentos a arquitetura da rede e método de treinamento da RNA-MLP que melhor se adequa na previsão de maré meteorológica para a região;

Em termos de hipótese, neste trabalho pretende-se testar se o uso de RNAs melhora a capacidade preditiva das variações de nível relativo do mar considerando não apenas às forçantes astronômicas, mas, também às meteorológicas.

3 REFERENCIAL TEÓRICO

3.1 MARÉS

3.1.1 Maré astronômica

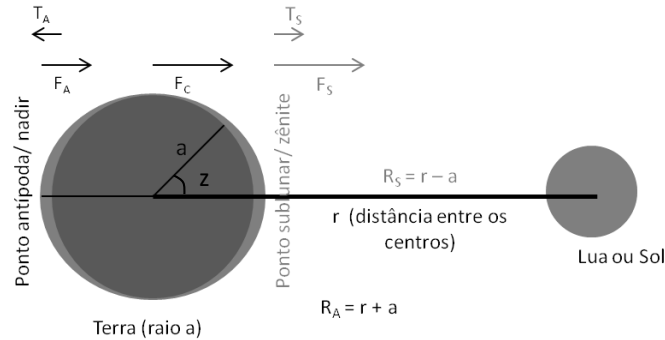
A maré astronômica pode ser definida como oscilações verticais periódicas do nível do mar, devido à ação gravitacional da Lua e do Sol e aos movimentos de rotação e translação do sistema Terra – Lua – Sol. Desde os primeiros esforços para descrever as forças e processos geradores de tais oscilações diversas teorias e conceitos vem sendo aplicados.

A força geradora das marés pode ser entendida, desde um sistema inercial, como a diferença entre a força de atração gravitacional da Lua e/ou Sol e da força centrífuga associada ao movimento de rotação da Terra em torno do centro de massa do sistema Terra – Lua (ou Sol).

As forças geradoras de maré, sejam elas representadas pela aceleração gravitacional na Terra ou em qualquer ponto do oceano, dependem da distância entre a Terra e os astros em questão. Por esse motivo, as marés são associadas, principalmente, aos movimentos da Lua (GUIMARÃES; MARONE, 1996, p.50).

Na FIGURA 1 pode ser observado um esquema das forças de atração gravitacional entre a Terra e a Lua (ou Sol). Nela são considerados dois pontos extremos relativos à posição da Lua (ou Sol). O ponto antípoda ou nadir se encontra no lado oposto à posição da Lua, e o ponto sublunar ou zênite se encontra entre a Terra e a Lua. As forças de atração entre a Lua e os pontos antípoda e sublunar, na Terra, são representadas por F_A e F_S , respectivamente. A força de atração entre os centros da Lua e da Terra são representados por F_C . A resultante da força de atração no ponto antípoda (F_A) e no centro da Terra (F_C) é representada por T_A , enquanto que essa resultante para o centro da Terra (F_C) e o ponto sublunar (F_S) é indicado por T_S . Ainda na figura, a é o raio da Terra e r é a distância entre os centros da Terra e da Lua (ou Sol). R_A e R_S representam a distância entre o ponto antípoda e sublunar, respectivamente, do centro da Lua.

FIGURA 1 – REPRESENTAÇÃO DAS FORÇAS DE ATRAÇÃO GRAVITACIONAL NO SISTEMA TERRA-LUA (OU SOL). AS FORÇAS F_A , F_S E F_C REPRESENTAM AS FORÇAS DE ATRAÇÃO ENTRE O CENTRO DA LUA E OS PONTOS ANTÍPODA, SUBLUNAR E O CENTRO DA TERRA, RESPECTIVAMENTE. T_A E T_S REPRESENTAM A RESULTANTE ENTRE AS FORÇAS F_A E F_C E F_C E F_S , NESSA ORDEM.



FONTE: Adaptado de TALLEY et al. (2011, p. 238)

Dentro desse sistema, a força centrífuga, que é resultado do movimento de rotação da Terra, também é a força que explica o motivo pelo qual a Lua não é atraída para a Terra. Se substituída a força de atração no centro da Terra (F_C) pela força centrífuga (F_{cf}), que é igual em todos os pontos da superfície (FRANCO, 2009, p.20), e soma-se a ela a força gravitacional nos oceanos, tem-se

$$T_S = F_{cf} + F_S \quad (1a)$$

$$T_A = F_{cf} + F_A \quad (1b)$$

onde T_S é a resultante da força de atração no ponto antípoda e no centro da Terra e T_A é a mesma resultante para o ponto sublunar.

A força centrífuga é balanceada, então, pela força de atração nos centros da Terra e da Lua, ou seja, $-F_C$. Desta forma, pode-se substituir F_{cf} por $-F_C$ nas equações 1a e 1b e tem-se (equações 2a e 2b):

$$T_S = -F_C + F_S \quad (2a)$$


$$T_A = -F_C + F_A \quad (2b)$$

Em resumo, o que acontece na prática, se a força centrífuga for considerada como parte das forças geradoras e que, para que a massa de água se movimente, é necessário que a resultante das forças que agem sobre ela não seja nula. O sistema Terra-Lua pode ser considerado como em equilíbrio dinâmico, isto é, a soma das forças deve ser vetorialmente nula. Como a força centrífuga é igual em todos os pontos da Terra e a força de atração da Lua é variável, então há diferentes resultantes para cada ponto, que são compensadas pelas forças

geradoras das marés em cada ponto, que causam o deslocamento das massas de água e promovem que a resultante de todas as forças seja nula (i.e., equilíbrio dinâmico). É essa mesma força que explica a resultante T_A , em direção oposta à Lua e o sentido da força de atração lunar (ver FIGURA 1) (FRANCO, 2009, p.20).

O movimento de rotação da Terra também implica na forma como cada ponto do oceano responde à força de atração da Lua (ou Sol). Para entender melhor esse processo, a maré é dividida em uma componente vertical e outra horizontal (FIGURA 2). Na FIGURA 2c, pode-se observar a componente horizontal para o momento em que a Lua está no plano do equador, onde o aumento e a redução do nível médio ocorrem devido ao acúmulo de água nos pontos antípoda e sublunar para os quais ela foi arrastada pela força de tração.

FIGURA 2 – CONSIDERANDO A LUA NA LINHA DO EQUADOR TEMOS O POTENCIAL GERADOR DE MARÉ EM a) A COMPONENTE VERTICAL, MÁXIMA NO EQUADOR E INVERSA NOS POLOS; b) A COMPONENTE HORIZONTAL, MÁXIMA AOS 45° DE LATITUDE E EM c) A FORÇA DE TRAÇÃO GERADA POR CONTA DA MOVIMENTAÇÃO DAS COMPONENTES.



FONTE: Adaptada de NUNES (2007); FRANCO (2009).

A componente vertical (F_v) é definida pela equação 3a e a horizontal (F_h) pela 3b, Entre as duas componentes, a componente horizontal sobressai a vertical como principal responsável pelas alterações do nível médio do mar. Doodson e Warburg (1941, apud FRANCO 2009) denominaram a componente horizontal (F_h) de *força de tração*. Em Franco (2009, p. 17-28), pode ser encontrada a explicação matemática detalhada dessa afirmação, que leva a:

$$F_v = G \frac{ma^2}{Mr^2} \left[\frac{\cos z - \frac{a}{r}}{\left(1 + \frac{a^2}{r^2} - 2\frac{a}{r} \cos z\right)^{3/2}} - \cos z \right] \quad (3a)$$

$$F_h = G \frac{ma^2}{Mr^2} \left[\frac{\sin z}{\left(1 + \frac{a^2}{r^2} - 2\frac{a}{r} \cos z\right)^{3/2}} - \sin z \right] \quad (3b)$$

onde G é a constante gravitacional igual à $6,67 \times 10^{-11} \text{ Nm}^2/\text{kg}$, m e M são as massas da Lua e da Terra, respectivamente, a é o raio da Terra, r é a distância entre os centros da Terra e da Lua

e z é o ângulo formado entre a linha que une os centros dos astros e o ponto em questão onde é analisada a componente.

Tratando-se da Lua como principal gerador das marés, os dois máximos de amplitude ocorrem a cada 12 horas e 25 minutos, que corresponde à metade denominado de dia lunar. Quando a frequência em que o nível médio sobe e desce é de dois ciclos por dia lunar (ou solar, quando a maré é gerada pelo sol), a maré é caracterizada como maré semidiurna. Quando a frequência é de um ciclo no do dia lunar, então as marés são caracterizadas como diurnas.

A FIGURA 3 esquematiza os níveis e planos de referências mais citados e utilizados quando se refere às marés.

FIGURA 3 – NÍVEIS DE MARÉ E PLANOS DE REFERÊNCIA. ONDE *MHWS* É A MÉDIA DAS PREAMARES DE SIZÍGIA, *MHW* É A MÉDIA DAS PREAMARES OU ALTURA MÉDIA DAS PREAMARES AO LONGO DE UM DETERMINADO PERÍODO E *MHWN* É A MÉDIA DAS PREAMARES DE QUADRATURA. *MLWN* MÉDIA DAS BAIXA-MARES DE QUADRATURA, *MLW* É A MÉDIA DAS BAIXA-MARES OU ALTURA MÉDIA DAS BAIXA-MARES E *MLWS* É A MÉDIA DAS BAIXA-MARES DE SIZÍGIA. *NR* É O NÍVEL DE REDUÇÃO, PELO QUAL SÃO REFERIDAS TODAS AS DEMAIS MEDIDAS.



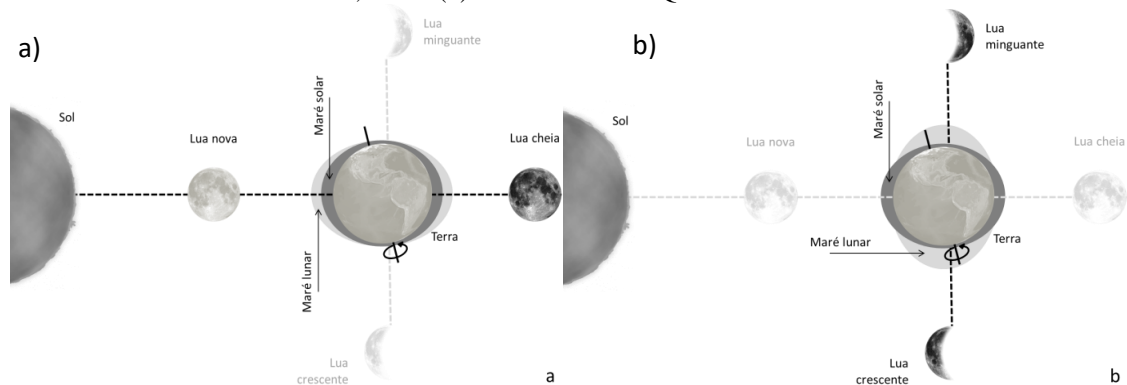
FONTE: MIGUENS (1995).

Com base na FIGURA 3, o nível médio (NM) é a média de n observações da altura da superfície da água em relação ao zero hidrográfico, sendo que n deve ser um número representativo dentro da escala trabalhada. O nível de redução (NR) ou zero hidrográfico (ZH) é um nível arbitrário estabelecido para cada região a partir das médias das baixa-mares mais baixas do local (MLWN). Segundo a Organização Hidrográfica Internacional, é “um plano tão

baixo que a maré, em condições normais, não fique abaixo dele”. Baixa-mar (BM), também chamada de maré baixa, é o nível mais baixo da maré. O oposto da baixa-mar é a preamar, ou seja, o nível mais alto da maré (MHW). A ocorrência da passagem de uma baixa-mar para uma preamar, e vice-versa, é acompanhada pelo aparecimento das correntes de maré. Essas correntes estão relacionadas com a componente horizontal da atração exercida pela Lua e pelo Sol sobre a Terra e a superfície dos oceanos. Quando a descida do nível da água ocasiona as correntes de vazante e, no oposto, a subida do nível da água ocasiona as correntes de enchente, significa que as ondas de maré estão em fase com a variação das correntes. Nesse caso a onda de maré é denominada *estacionária*. Quando as máximas velocidades das correntes ocorrem durante a baixa-mar (vazante) e a preamar (enchente) a onda é denominada *progressiva*. A velocidade da corrente na meia-maré é nula e esse período é denominado estofo da maré (INSTITUTO HIDROGRÁFICO DA MARINHA DE PORTUGAL, 2018; INFORMAÇÕES SOBRE MARÉ (MARINHA DO BRASIL), 2018).

Nos períodos de Lua Cheia e Lua Nova ocorrem as maiores amplitudes da maré (maiores preamares e menores baixa-mares) e são chamados de *sizígia*, maré “de lua” ou marés vivas (FIGURA 4a). Nesse período a Terra, a Lua e o Sol estão alinhados, com sobreposição das forças solares e lunares, ocasionando um maior acúmulo de água no plano do equador. Vale lembrar que a órbita da Lua ao redor da Terra não coincide com o plano do equador e, portanto, esse acúmulo se comporta de maneiras diferentes próximo ao equador. Nos períodos de Lua Crescente e Minguante ocorrem as menores amplitudes de maré e são chamados de *quadratura*, marés “de quarto” ou marés mortas (FIGURA 4b). Nesse período, a linha que une a Terra e a Lua se encontra a $\sim 90^\circ$ da linha que une a Terra e o Sol (GUIMARÃES; MARONE, 1996). O intervalo de ocorrência entre períodos de sizígia e quadratura é de aproximadamente duas semanas (ou metade do mês lunar).

FIGURA 4 – ESQUEMA DO SISTEMA SOL – TERRA – LUA E A RELAÇÃO COM AS MARÉS. EM (a) AS MARÉS DE SIZÍGIA; E EM (b) AS MARÉS DE QUADRATURA.



FONTE: O autor (2018)

Em uma escala maior, de meses, há a necessidade de adicionar as variações das órbitas da Lua ao redor da Terra e do sistema Terra – Lua em torno do Sol como uma das forças responsáveis pelas oscilações do nível do mar. Como a forma dessas órbitas é elíptica, em alguns períodos a Lua está mais próxima (perigeu) ou mais distante (apogeu) da Terra, e o mesmo é aplicável na órbita em torno do Sol, um período mais próximo (periélio) do sistema Terra – Lua e outro mais distante (afélio). Como visto anteriormente, a distância entre os corpos determina a intensidade das forças de atração e centrífuga que ocorrem neles e, portanto, a força geradora de maré. Assim, durante o perigeu e periélio teremos maiores amplitudes de maré, enquanto que durante o apogeu e afélio teremos as menores amplitudes (TALLEY et al., 2011, p. 240).

A descrição dos processos responsáveis pela geração das marés astronômicas só se tornou viável após a aceitação das condições hipotéticas da Teoria do Equilíbrio das Marés. Essa teoria estabeleceu um padrão de referência que poderia ser utilizado para comparar observações do nível do mar e fazer previsões dos seus movimentos periódicos e oscilatórios. Entretanto, o que observamos na prática, é que quando a onda de maré encontra as bordas dos continentes ou as diversas formas de relevo submarino, a interação entre eles será característica para cada local. A frequência com que essa interação ocorre é definida com relação às periodicidades astronômicas principais (diurna ou semidiurna) (FRANCO, 2009, p. 35; TALLEY et al., 2011, p.240).

O somatório dessas interações astronômicas e batimétricas e/ou geomorfológicas correspondem aos constituintes ou componentes da maré. Um componente de maré representa os ciclos distintos do movimento orbital da Lua e do Sol e da consequente variação do potencial gerador das marés. Na TABELA 1 estão apresentadas as principais componentes astronômicas da maré. Cada região na costa possui a maré determinada por suas constituintes dominantes, as

quais estão associadas as suas constantes harmônicas, suas amplitudes e suas fases (GUIMARÃES; MARONE, 1996).

TABELA 1 – COMPONENTES ASTRONÔMICAS DA MARÉ, COM SUAS RESPECTIVAS SIGLAS E FREQUÊNCIAS ANGULARES. AS COMPONENTES SÃO DIVIDAS EM ESPÉCIES: *COMPONENTES DE LONGO PERÍODO* E *COMPONENTES HARMÔNICAS* (DIURNAS, SEMIDIURNAS E TERDIURNAS).

Componentes Astronômicas		
Símbolo	Nome	Frequência (°/h)
Espécie: Longo período		
Sa	Solar anual	0,0410686
Ssa	Solar semestral	0,0821373
Mm	Lunar mensal	0,5443747
Mf	Lunar quinzenal	1,0980331
Mtm	Lunar termensal	1,6424077
Espécie: Diurnas		
2Q ₁	Lunar elíptica de 2 ordem	12,8542862
σ ₁	Variacional	12,9271398
Q ₁	Lunas elíptica maior	13,3986609
ρ ₁	Eveccional maior	13,4715145
O ₁	Lunar principal	13,9430356
M ₁	Lunar elíptica menor	14,4966940
χ ₁	Eveccional menor	14,5695475
π ₁	Solar elíptica maior	14,9178647
P ₁	Solar principal	14,9589314
S ₁	Meteorológica	15,0000000
K ₁	Lunissolar declinacional	15,0410686
ψ ₁	Solar elíptica menor	15,0821353
φ ₁	Solar de 2 ordem	15,1232059
θ ₁	Eveccional	15,5125897
J ₁	Lunar elítica	15,5854433
OO ₁	Lunar de 2 ordem	16,1391017
Espécie: Semidiurnas		
2N ₂	Lunar elíptica de 2 ordem	27,8953549
μ ₂	Variacional	27,9682084
N ₂	Lunar elíptica maior	28,4397295
v ₂	Eveccional maior	28,5125831
M ₂	Lunar principal	28,9841042
λ ₂	Eveccional menor	29,4556253
L ₂	Lunar elíptica menor	29,5284789
T ₂	Solar elíptica maior	29,9589333
S ₂	Solar principal	30,0000000
R ₂	Solar elíptica menor	30,0410667
K ₂	Lunissolar declinacional	30,0821373
Espécie: Terdiurna		
M ₃	Terdiurna lunar	43,4761563

FONTE: FRANCO (2009).

A partir do entendimento dos componentes de maré para um determinado local é possível realizar previsões com relação à altura da maré para a região. No Brasil, por exemplo, essas previsões, para intervalos horários, são divulgadas anualmente pela Diretoria Nacional de Hidrografia da Marinha do Brasil, nas chamadas Tábuas de Marés para os principais portos e

locais de interesse da costa. Atualmente, elas são bastante aprimoradas dado o desenvolvimento de modelos numéricos específicos e ao elevado conhecimento das componentes harmônicas locais. Uma descrição dos principais métodos de previsão de maré é abordada no item 3.1.3.

3.1.2 Maré meteorológica

Um complicador para a previsão e descrição da maré nas regiões costeiras é que a maré astronômica prevista nas Tábuas de Marés quase sempre difere da observada devido a influências meteorológicas, ou seja, a ação da pressão atmosférica e do vento sobre a superfície do mar. Essa diferença entre a maré prevista e a real observada foi chamada de maré meteorológica (MM) por Pugh (1996). As forçantes da MM atuam com intensidades e períodos diferentes, podendo ocasionar tanto o aumento (distúrbio positivo), quanto a redução significativa do nível do mar (distúrbio negativo) (GODIN, 1988, p. 99-100). Essas flutuações do nível do mar podem causar problemas de inundação de áreas costeiras e também se refletir em um perigo para grandes navegações em regiões portuárias (CAMARGO; HARARI, 2015, p.250).

No presente trabalho a maré meteorológica pode ser definida como as variações do nível do mar de origem não astronômica, causadas pela ação do vento na superfície da água e pelas variações da pressão atmosférica seja por ação local ou efeitos remotos. Devido a escassez de dados para o mesmo período em regiões adjacentes não foi possível analisar os efeitos remotos na geração das marés meteorológicas na região de estudo. A faixa de ocorrência dos eventos de maré meteorológica é compreendida no intervalo de poucos dias até cerca de duas semanas. Em Melo (2017) esse intervalo é fixado entre 3 e 30 dias com o intuito de facilitar as comparações entre as regiões analisadas.

A ação do vento causa tensões nas camadas superficiais na interface oceano-atmosfera ocasionando o deslocamento das parcelas de água superficiais e conseqüentemente também nas camadas inferiores. O deslocamento da parcela afetada diretamente pela ação do vento não ocorre paralelamente a direção do vento, assim como a transferência de energia de uma camada para a camada imediatamente abaixo sofre um ângulo de deslocamento. Esse processo é conhecido hoje como transporte de Ekman e foi descrito por Ekman, após observações feitas por Fridtjof Nansen sobre o movimento dos icebergs a 20° e 40° em relação à direção do vento e não paralelamente a ele (BROWN et al., 1989, p.37).

Quando o vento sopra sobre o oceano ele transfere energia para sua camada superficial (a Camada de Ekman) e essa energia pode gerar ondas ou correntes superficiais. Esse processo

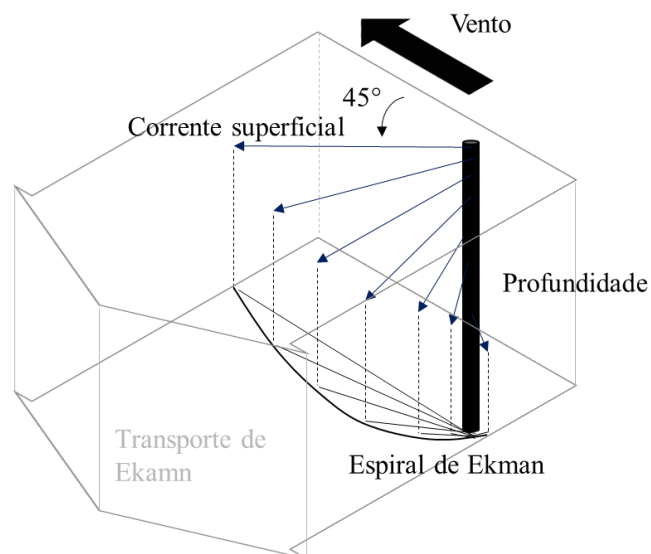
ocorre através da força de fricção também conhecida por tensão de cisalhamento do vento (τ), e é calculado pela equação (4):

$$\tau = \rho C_D W^2 \quad (4)$$

onde ρ é a densidade do ar ($1,2 \text{ kg/m}^3$), C_D é o coeficiente de arrasto, dependente das condições atmosféricas predominantes, relacionadas a turbulência na interação oceano-atmosfera e, W é a velocidade do vento (BROWN et al., 1989, p.33).

A camada de Ekman é governada pelos processos de fricção (ou tensão do vento) e pela força de Coriolis, que irá determinar a direção de desvio da corrente (para direita no hemisfério Norte e para esquerda no hemisfério Sul). A velocidade da corrente vai diminuindo exponencialmente nas camadas mais profundas até desaparecer. Nesse intervalo, a corrente descreve um perfil espiral, chamado de Espiral de Ekman (FIGURA 5). O resultado líquido da variação ao longo das camadas, terá um transporte resultante, o Transporte de Ekman, que será perpendicular à direção do vento (TALLEY et al., 2011, p. 197; MELO FILHO, 2017, p. 14).

FIGURA 5 – ESQUEMA DO ESPIRAL DE EKMAN PARA O HEMISFÉRIO SUL FORMADO DEVIDO À AÇÃO DO VENTO NA SUPERFÍCIE.



FONTE: Adaptado de THURMAN (1994).

Enquanto que a energia resultante do efeito do vento na superfície da água é transferida de forma diferente nas camadas da coluna de água, o efeito da mudança de pressão atmosférica age verticalmente sobre a superfície da água e transferida uniformemente em todas as profundidades. Esse efeito é conhecido como Barômetro Invertido e consiste na tentativa de manter constante a pressão total sobre o fundo oceânico, através do aumento/ diminuição do nível do mar que é determinado pela diminuição/ aumento da pressão atmosférica. Como a água

é um fluido incompressível, e os oceanos possuem fronteiras laterais e profundidade limitada, o princípio da conservação da massa dita que em resposta ao aumento/ diminuição do nível do mar em um dado local o oposto deverá acontecer em outro local (MELO FILHO, 2017).

Os efeitos resultantes da ação do vento e da mudança da pressão na oscilação do nível do mar, apesar de serem explicados individualmente, agem concomitantemente sobre o movimento das parcelas de água. As alterações de pressão atuam igualmente em toda coluna de água, enquanto o efeito do vento depende de diversos fatores, como a intensidade e o tempo de atuação do mesmo e a situação de estratificação da coluna de água. Entretanto, o efeito do vento é mais efetivo do que as variações de pressão atmosférica para as flutuações do nível do mar (CAMARGO; HARARI, 2015, p.251; MELO FILHO, 2017, p. 12). Em termos gerais, os efeitos meteorológicos no nível do mar não necessariamente estão relacionados com as estações do ano, já que as alterações de pressão atmosférica e intensidade do vento ocorrem independente da época, entretanto, vale ressaltar que esse é um parâmetro que pode ser influenciado também pela região em questão.

3.1.3 Métodos de previsão de maré

Entre os métodos para a previsão da maré, o mais comumente utilizado é o método da análise harmônica, um processo matemático onde são realizadas as previsões da altura do nível do mar encontradas nas Tábuas de Maré. Partindo do pressuposto que a onda de maré é o somatório das suas diversas componentes harmônicas, o método consiste em identificar essas componentes através dos seus períodos, que são conhecidos para cada componente, obtendo as amplitudes e fases, que variam de acordo com a localidade (TIDES AND CURRENTS: GLOSSARY, NOAA, 2018; COELHO, 2016).

Franco e Rock (1971) propuseram essa análise através da aplicação da Transformada Rápida de Fourier (*Fast Fourier Transform - FFT*) no registro de dados. Método este de análise de séries temporais no domínio das frequências que não era utilizado na época, para a análise de registros de nível do mar. Esse método tornou-se conhecido pois, além de identificar as componentes de maré, consegue indicar as frequências de possíveis componentes de águas rasas e/ou de anomalias locais a serem estudadas. Outra vantagem é que o método FFT permite a inserção de novos componentes para a análise, e não está restrita à análise de apenas séries cujo período seja múltiplo de meias lunações como os métodos anteriores faziam (FRANCO, 2009, p.163).

Para analisar os dados de altura do nível do mar no domínio do tempo e não através das frequências da onda de maré, como é feito no modelo de análise harmônica, é utilizado o Método dos Mínimos Quadrados, que consiste na análise espectral dos dados observados de altura do nível do mar. Outros métodos de análise de maré também utilizam o mesmo princípio dos mínimos quadrados comumente utilizado em estatística, assim como variações aperfeiçoadas deste para a previsão de marés (SCHUREMANN, 1941 apud MARONE, 1991; FOREMAN; CHERNIAWSKY; BALLANTYNE, 2009).

Entretanto, por mais completos que sejam esses métodos para prever as flutuações, as influências meteorológicas no nível do mar podem ser significativas e, quando não são levadas em consideração podem gerar erros que praticamente inutilizam as Tábuas de Marés em determinadas regiões (MELO FILHO, 2017, p. 8-9).

Um dos primeiros modelos a incluir a variável da maré meteorológica para previsão do nível do mar foi proposto por Munk & Cartwright, em 1966, chamado de Método da Resposta. O método é baseado no princípio da caixa preta, constituído por um sinal de entrada, a caixa em si (ou sistema) e um sinal de saída. Analogamente, o sinal de entrada pode ser tanto o potencial gerador da maré astronômica, como os efeitos meteorológicos. A caixa preta é considerada como um meio oceânico e a sua resposta às marés será o sinal de saída, que é a altura do nível do mar (FIGURA 6).

FIGURA 6 – ESQUEMA REPRESENTANDO O MÉTODO DA RESPOSTA, ATRAVÉS DO PRINCÍPIO DA CAIXA PRETA.



FONTE: O autor (2018).

O método de Munk & Cartwright tornou possível incluir as forçantes meteorológicas, pois em oposto aos demais métodos citados que somente usam os registros da maré para gerar as constantes harmônicas através do método dos mínimos quadrados, torna possível analisar as flutuações do nível do mar em um determinado ponto, já as considerando como uma resposta da forçante de maré, seja ela astronômica ou meteorológica. Entretanto, dois questionamentos podem ser levantados nesse raciocínio. Primeiro, os harmônicos que dão origem a uma resposta no oceano (sejam eles astronômicos ou não) possuem frequências muito próximas e quando analisada a altura do nível do mar a partir da sua resposta e não das constituintes que a geraram, as relações de causa e efeito podem não ser corretas devido ao *credo of smoothness*. Esse

conceito não permite que a razão entre a saída e as entradas (*admittance*) do modelo variem drasticamente, e isso acontece por conta da proximidade entre as frequências das constituintes da maré, já que frequências muito semelhantes não necessariamente geram respostas diferentes no nível do mar (PUGH; WOODWORTH, 2014, p. 78-79).

Além desses problemas, os demais métodos supracitados também possuem limitações. Marone e Mesquita (1994) e Marone (1996) testaram diferentes métodos de análise espectral das marés com intuito de separar os efeitos lineares e não lineares da interação entre o oceano e a atmosfera. Apesar de frequentemente adotadas, as condições de linearidade não são observadas na prática e os próprios autores, levantam a importância da inclusão do caráter não-linear das marés nos modelos de análise.

Todos modelos supracitados podem ser encontrados com mais detalhes na revisão dos métodos feita por Marone (1991, 1996), e Marone et al (1994). Dentre esses modelos, o Método da Resposta é o modelo que mais se aproxima ao conceito de neurônios, nas redes neurais artificiais utilizadas neste trabalho para prever as marés meteorológicas como descrito na seção 3.2 a seguir.

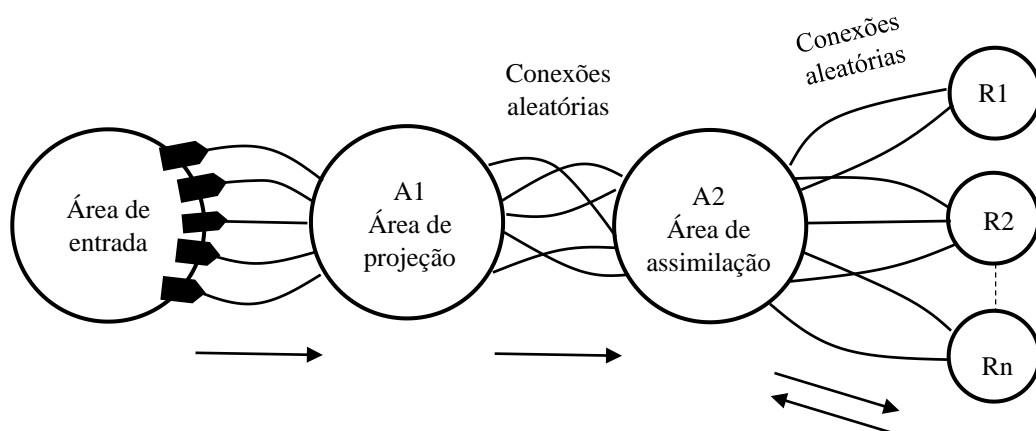
3.2 REDES NEURAIS ARTIFICIAIS

As primeiras tentativas de realizar a reprodução do funcionamento de um cérebro humano datam de 1940, antes do surgimento dos computadores, quando Donald Hebb e Karl Lashley fizeram simulações para um mecanismo de aprendizagem dos neurônios. Em 1943, McCulloch e Pitts publicaram o artigo *A logical calculus of the ideas immanent in nervous activity* onde propuseram um modelo simplificado de neurônio biológico, o qual tornaria possível a modelagem numérica do mesmo. Esse trabalho é considerado o marco de nascimento das *Redes Neurais Artificiais*.

Redes Neurais Artificiais (RNAs) também chamadas de “neurocomputadores”, “redes conexionistas” ou “processadores paralelamente distribuídos” são ferramentas computacionais emergentes inspiradas no funcionamento da estrutura neural humana. Elas são compostas por unidades simples de processamento, os chamados neurônios artificiais, que estão interligados entre si de forma maciça e paralela. Assim como o cérebro, as RNAs são capazes de adquirir conhecimento através da aprendizagem pela experiência e podem armazenar esse conhecimento através da conexão entre os neurônios (pesos sinápticos) (LOESCH; SARI, 1996; HAYKIN, 2001).

Rosenblatt (1958) descreveu a teoria do *perceptron*, que remete exatamente a ideia de um sistema nervoso hipotético simples em seu modelo de organização. A constituição do *perceptron* (FIGURA 7), segundo Rosenblatt se dá por uma área de entrada onde o estímulo é sentido por sensores unitários, cuja resposta será baseada na teoria do tudo ou nada, assim como supunha McCulloch e Pitts (1943) para a atividade neuronal. A resposta desses sensores será então transmitida em forma de impulso para a “célula de associação” em uma “área de projeção” (A1). Em alguns modelos, a área de projeção poderia ser omitida e o impulso transmitido diretamente para a área seguinte, a “área de associação” (A2). Os impulsos entre os sensores e as células de associação podem ser excitatórios ou inibitórios. Se a soma de impulsos excitatórios com os inibitórios for maior ou igual a um limiar pré-definido para a área de projeção, então as células de associação liberam um novo impulso que será recebido na área de associação. Ao contrário do que acontece entre a área de entrada e a área de projeção, onde cada sensor unitário corresponde a uma célula de associação, o espaço entre a área de projeção e a área de associação possui conexões são aleatórias. O número de impulsos e as características da área de associação são os mesmos da área de projeção, porém a distribuição dos impulsos é dada de forma aleatória entre A1 e A2. Por último, tem-se as respostas equivalentes a cada impulso transmitido pelas células de associação (R_n). Em todas as conexões (área de entrada – A1 – A2) a direção do impulso se propaga em uma única direção, da esquerda para a direita, mas na conexão entre a área de associação A2 e as respostas, essa conexão é bidirecional. Esse processo é chamado de *feedback* e pode acontecer de forma a inibir ou excitar as próprias células de associação.

FIGURA 7 – MODELO DE ORGANIZAÇÃO DO *PERCEPTRON* DE ROSENBLATT.




FONTE: Adaptado de ROSENBLATT (1958).

Essas unidades, chamadas de células de associação eram o equivalente aos neurônios de McCulloch e Pitts, em 1943.

Pode-se descrever o neurônio de McCulloch e Pitts (1943), através de uma analogia ao neurônio biológico, como mostra a FIGURA 8. As conexões de entrada são o equivalente aos dendritos, elas são a porta de entrada para o neurônio artificial. Nela, o conjunto de entradas (x_i) é multiplicado por um peso sináptico (w_n), determinado inicialmente aleatoriamente e ajustado durante o treinamento da rede (toda conexão entre neurônios possui um peso numérico associado). O somatório dessas multiplicações do conjunto de entrada, ou seja, as entradas ponderadas, é realizado pelo combinador linear que é a representação, no neurônio artificial, do corpo celular do neurônio biológico. Nessa mesma lógica, o axônio é representado pela função de ativação. A função de ativação (ϕ), também conhecida como “função restritiva”, limita (ou restringe) o intervalo possível do sinal de saída do neurônio. A amplitude do intervalo da função de ativação é dependente do tipo de função utilizada e pode variar entre 0 e 1 ou -1 e 1. Quando o sinal de saída for igual à 0 (zero), o neurônio sofrerá inibição e o sinal não será transmitido adiante. Ainda na figura, y é a saída do neurônio, que poderá ser transmitida a um novo neurônio na camada seguinte, quando for o caso, ou resultar na saída final da RNA.

FIGURA 8 – À ESQUERDA A REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO E, À DIREITA, O MODELO DE NEURÔNIO PROPOSTO POR MCCULLOCH E PITTS EM 1943. ONDE: x SÃO OS DADOS DE ENTRADA, w REPRESENTA OS PESOS SINÁPTICOS E y É A SAÍDA DA REDE.



FONTE: Adaptado de OLIVEIRA (2004).

Há 3 tipos básicos de função de ativação (ϕ): função limiar, função linear por partes e função sigmoide (FIGURA 9) (HAYKIN, 2001, p. 38). A função limiar é baseada no “princípio tudo ou nada” também utilizado no neurônio de McCulloch e Pitts, ou seja, para um neurônio k , teremos como saída:

$$y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases}$$

onde v_k é o “campo local induzido” e é definido pela equação (5):

$$v_k = \sum w_{ki}x_i + b_i \quad (5)$$

onde x_i (x_1, x_2, \dots, x_n) são os sinais de entrada, w_{ki} ($w_{k1}, w_{k2}, \dots, w_{kn}$) são os pesos sinápticos do neurônio k e b_i é o *bias* (viés). Esse último, pode ser considerado um peso suplementar da rede que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, sendo importante no processo de treinamento e adaptação da rede. Em alguns casos, o *bias* é utilizado para garantir que a saída da rede não seja nula. Isso se torna possível porque o resultado da soma desse parâmetro, geralmente unitário, positivo ou negativo, acarreta no deslocamento do campo local induzido, fazendo com que a função de ativação não passe mais pela origem do plano cartesiano. A função limiar também pode se estender até o intervalo $[-1,1]$, se tornando uma função ímpar no campo local induzido. Nesse caso, a função limiar é chamada de “função sinal” e assume os valores:

$$y_k = \begin{cases} 1 & \text{se } v_k < 0 \\ 0 & \text{se } v_k = 0 \\ -1 & \text{se } v_k > 0 \end{cases}$$

A função linear por partes é, dentre as demais, a função mais básica e seus resultados apresentarão valores iguais à:

$$y_k = \begin{cases} 1, & v_k \geq +1/2 \\ v, & +1/2 > v_k > -1/2 \\ 0, & v_k \leq -1/2 \end{cases}$$


Por último, a função sigmoide é a mais comumente encontrada nas RNAs, por causa da sua capacidade em demonstrar a não-linearidade de forma suave, característica que é muito importante nesses modelos. Um tipo de função sigmoide é a “função logística”, definida pela equação (6):

$$\varphi(v_k) = \frac{1}{1 + \exp(-av_k)} \quad (6)$$

onde a é o parâmetro de inclinação da função. A função sigmoide assume um intervalo contínuo de valores entre 0 e 1, enquanto as demais funções assumem valores fixos (0, -1 ou 1, v ou 0). A função sigmoide também pode ser estendida até o intervalo $[-1,1]$ e, nesse caso, será chamada de “função tangente hiperbólica”, definida pela equação (7).

$$\varphi(v) = \tanh(v) \quad (7)$$

FIGURA 9 – REPRESENTAÇÃO GRÁFICA DAS FUNÇÕES DE ATIVAÇÃO (φ). EM a) A FUNÇÃO LIMIAR; EM b) A FUNÇÃO LINEAR POR PARTES E; EM c) A FUNÇÃO SIGMOIDE LOGÍSTICA.



FONTE: ZUBEN (1993).

Além da unidade (ou neurônio) de uma RNA, também deve-se considerar a forma como esses neurônios estão estruturados na rede, denominada de arquitetura da rede, pois é ela que irá ditar a forma de aprendizagem do modelo (algoritmo de aprendizagem).

Em Haykin (2001, p. 46), são citados três tipos principais de arquiteturas (ou estruturas) de redes: as redes *feedforward* de camada única, as *feedforward* de múltiplas camadas e as redes recorrentes.

Uma rede *feedforward* de camada única é uma rede cuja alimentação ocorre para frente, da camada de entrada para a camada de saída. O termo “de camada única” é utilizado porque apenas a camada de saída é considerada, visto que somente nela são realizadas operações computacionais.

As redes *feedforward* de múltiplas camadas (FIGURA 10) se baseiam no mesmo princípio das redes de camada única, mas diferem das mesmas por apresentarem uma ou mais camadas ocultas. Essas camadas são importantes pois auxiliam a rede a lidar com a não-linearidade dos dados, e aumentam a capacidade da rede realizar estatísticas de alto nível.

Por último, as redes recorrentes se diferenciam das acima citadas por possuírem um mecanismo de retroalimentação. Nela, os sinais de saída de cada neurônio são capazes de voltar e interferir nas entradas dos outros neurônios e até mesmo na sua própria entrada (*feedback*). As redes recorrentes podem apresentar uma ou mais camadas e gerar bons resultados na capacidade de aprendizagem e no desempenho geral da rede.

Para analisar a capacidade de aprendizagem de uma rede faz-se necessário considerar quais são as regras básicas, pré-estabelecidas e bem definidas para solucionar o problema chave da RNA e como a mesma se relaciona com o meio em que está inserida.

O processo de aprendizagem ocorre pela modificação dos parâmetros da RNA em resposta a um estímulo do meio em que ela está inserida. Isso resulta que a resposta em b , denominado como “paradigma de aprendizagem”, é extremamente importante para entender

como os resultados serão gerados. Os paradigmas de aprendizagem podem ser divididos em supervisionado e não-supervisionados.

No aprendizado supervisionado são fornecidos à rede os dados de entrada e a saída desejada e os pesos serão adaptados pela diferença da saída da rede e da saída desejada. Esse método também pode ser chamado de aprendizagem com um professor, já que a saída desejada é estipulada por um “professor” que possui conhecimento prévio do ambiente em que está inserido e é submetido ao mesmo estímulo que a rede neural. O desempenho ótimo da rede então seria relacionado a ela alcançar o mesmo resultado que o professor estipulou, através do ajuste dos seus pesos, sem ter conhecimento do ambiente.

Outro paradigma de aprendizagem é o aprendizado sem um professor. Ele pode ser dividido em aprendizagem por reforço e aprendizagem não-supervisionada. Ambas se diferenciam do método anterior por não possuírem uma “ajuda externa” de aprendizagem, no caso, o professor. Destas duas, a aprendizagem não-supervisionada é a mais conhecida e utilizada nas RNAs ditas “mapas auto organizáveis” (Kohonen, 1982). Ela funciona através do fornecimento de uma medida que é independente da tarefa a ser realizada pela rede e a otimização dos parâmetros é feita através dessa medida, uma camada por vez (BECKER, 1991; HAYKIN, 2001).

Quando o termo “aprender” é utilizado para as RNAs o que está sendo considerado é o processo de adaptação dos pesos através de um determinado conhecimento prévio ou pela aplicação de algoritmos. Na literatura diversos algoritmos são conhecidos para esse fim: aprendizado *hebbiano*, regra delta, retropropagação (*backpropagation*), aprendizado competitivo, aprendizado reforçado, aprendizado aleatório e aprendizado evolutivo. Detalhes sobre os diferentes tipos de algoritmos de aprendizado podem ser conferidos no trabalho de Barreto (2002).

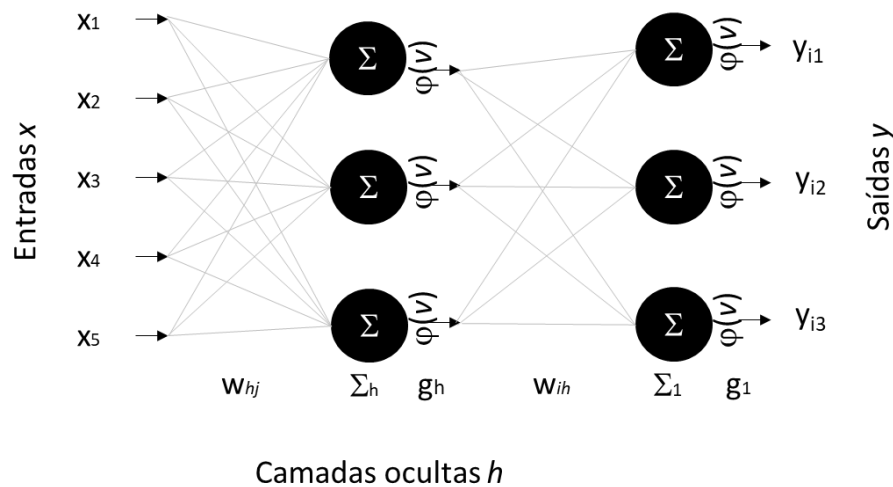
O algoritmo por retropropagação de erro (do inglês, *backpropagation*) é o mais comumente descrito e utilizado nas RNAs (LEK; GUÉGAN, 1999; OLIVEIRA et al, 2007; IMANI; YOU; KUO, 2014). O *backpropagation* foi descrito por Rumelhart, Hinton e Williams (1986) no trabalho *Learning representations by back-propagating errors* e apesar de sua aplicação ser viável em diversos tipos de rede, ele é usualmente empregado para redes chamadas de *multilayer perceptron* (*perceptron* de múltiplas camadas) descritas no 33.

3.2.1 *Multilayer perceptron (MLP)*

Em uma rede *multilayer perceptron* - *MLP* (*perceptron* de múltiplas camadas) são consideradas três tipos de camadas distintas: uma camada de entrada onde são recebidos os padrões disponibilizados pelo modelador (variáveis preditoras), uma ou mais camadas ocultas (ou intermediárias) responsáveis pelo processamento e extração dos padrões de entrada e da combinação não linear das entradas e uma camada de saída onde é construída a resposta (variável predita) baseada nos estímulos das camadas ocultas. A RNA-MLP é uma rede *feedforward* (alimentação direta) o que implica que o fluxo de sinal através da rede progride para frente, da esquerda para a direita e de camada para camada (HAYKIN, 2001).

Na RNA-MLP, cada neurônio de uma camada é conectado a todos os neurônios da camada anterior, porém nenhum neurônio pode estimular um neurônio pertencente a mesma camada (interconexão de neurônios da mesma camada) (FIGURA 10). Apesar das camadas ocultas auxiliarem a rede a lidar com a não-linearidade dos dados, não necessariamente um maior número de camadas ocultas resultará em melhores resultados de saída. Quando o número de camadas é demasiadamente grande para dados de baixa complexidade a rede pode sofrer o efeito de *overfitting*. Esse efeito é resultado do ajuste exagerado da rede aos dados, o que faz com que a mesma “decore” um padrão e não o “aprenda”. Busca-se, portanto, um balanço entre a complexidade da rede e esforço computacional e o seu poder de generalização, associado a um erro máximo.

FIGURA 10 – ARQUITETURA DA RNA-MLP E SUAS RESPECTIVAS FUNÇÕES. ONDE x_j REPRESENTAM AS ENTRADAS, y_{in} AS SAÍDAS, w_{hj} E w_{ih} SÃO OS PESOS E g_h E g_1 SÃO AS FUNÇÕES DE ATIVAÇÃO $\varphi(v)$.



$$y_i(x) = g \left(\sum_{h=0}^H w_{ih} g \left(\sum_{j=0}^J w_{hj} x_j \right) \right) \quad \varphi(v) = \frac{1}{1 + \exp^{-av}}$$

FONTE: Adaptado de RAUBER (2014).

Matematicamente, o treinamento por *backpropagation* é a combinação do aprendizado pela regra delta e o algoritmo do gradiente descendente. Ele opera através de pares de treinamento que são formados por um vetor de entrada e um vetor de saída (alvo) da rede. Após a definição desses pares eles devem ser apresentados à camada de entrada para que percorram a RNA até que a camada de saída produza uma resposta (previsão). Essa resposta deve ser comparada com a resposta desejada através do erro quadrático calculado pela equação (8). Como base nesse erro os pesos são ajustados para minimizá-lo. Esse processo é repetido até que os erros se tornem suficientemente pequenos ou até que se alcance um número pré-definido de iterações (épocas):

$$e^2 = \sum_{i=1}^c (y_i^o - y_i^m)^2 \quad (8)$$

onde c é o número de saídas, y_i^o é a saída desejada (observado) e y_i^m é a saída da rede (modelado). A equação (8) é utilizada para o cálculo do erro de cada par de treinamento. Para calcular o erro quadrático médio a equação (9) é considerada para todo o conjunto de treinamento n :

$$EQM = \frac{1}{n} \sum_{p=1}^n e^2 \quad (9)$$


Encontrado o EQM (Erro Quadrático Médio), agora o objetivo é buscar o peso w_{min} que produza um resultado da rede com o menor EQM possível. Isso é feito pela técnica do gradiente descendente (HERTZ; KROGH; PALMER, 1991; HAGAN et al., s.d.; RAUBER, 2014), onde busca-se através de l iterações o mínimo global w_{min} , conhecendo apenas o erro e o peso w estipulado aleatoriamente no início. Usualmente, o algoritmo é empregado em redes

com mais de uma camada assim a regra deverá ser aplicada quantas vezes for necessário, de forma que compreenda todos os conjuntos de peso da RNA. Pode-se melhorar o desempenho do gradiente descendente permitindo que a taxa de aprendizagem do mesmo varie durante o treinamento. Quando essa adequação é feita, chamamos o algoritmo de gradiente descendente com aprendizado adaptativo.

Outro algoritmo sugerido para o treinamento de redes cujos problemas a serem resolvidos sejam de pequena ou média complexidade é o algoritmo de Levenberg-Marquardt, que foi desenvolvido como uma adaptação do método do gradiente descendente e do algoritmo de Gauss-Newton (MARQUARDT, 1963; HAGAN; MENHAJ, 1994; HAGAN et al., s.d.; SILVA, 1998, p. 48-89; YU; WILAMOWSKI, 2010).

A partição do conjunto de dados também é uma configuração atraente para refinar a RNA-MLP. Esse processo é realizado através da *cross-validation* (validação cruzada), ferramenta que permite a divisão do conjunto de dados em subconjuntos de estimação e de validação dos dados para treinamento. No método de partição *holdout*, utilizado neste trabalho, a quantidade dessas divisões (*folders*) é estipulada pelo modelador durante o desenvolvimento da RNA-MLP. O desempenho final será dado pela soma ponderada dos erros obtidos por cada folder. Na FIGURA 11 é apresentado um esquema do processo de validação cruzada utilizado neste trabalho.

FIGURA 11 – ESQUEMATIZAÇÃO DO MÉTODO DE VALIDAÇÃO CRUZADA.



FONTE: O autor (2018).

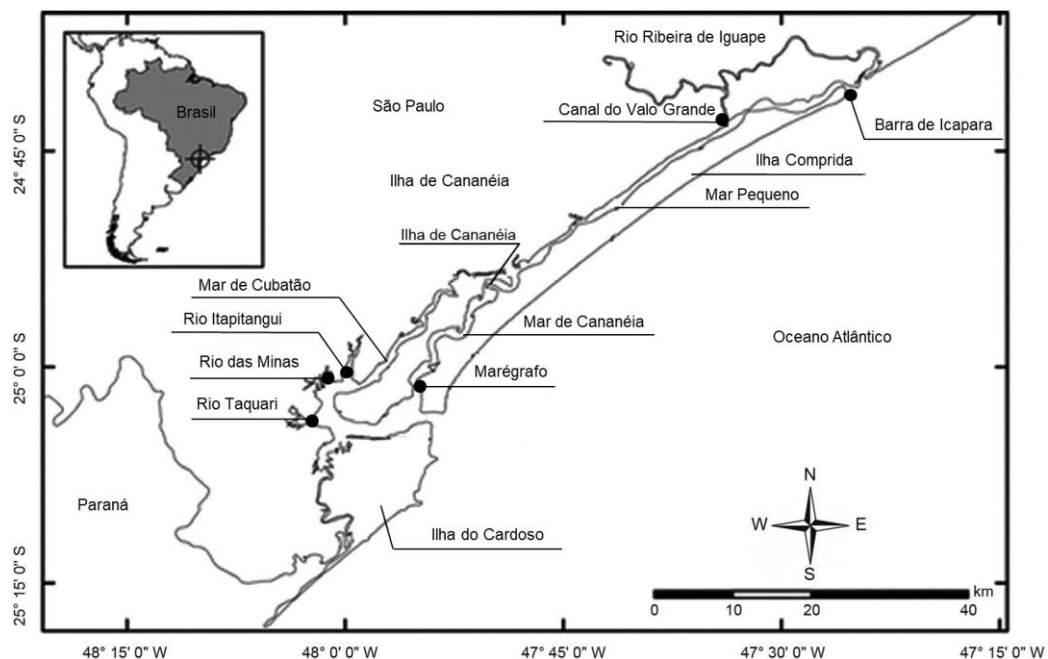
4 MATERIAIS E MÉTODOS

4.1 ESTUDO DE CASO

Com o objetivo de realizar uma previsão da maré meteorológica com maior eficiência, neste trabalho buscou-se avaliar a capacidade preditiva das Redes Neurais Artificiais (RNA) do tipo *multilayer perceptron* (MLP) utilizando dados de nível do mar provenientes da Ilha de Cananéia, no litoral sul do estado de São Paulo (Brasil) (FIGURA 12).

Desde 1950, diversos estudos na área de oceanografia e meteorologia foram desenvolvidos na região devido à instalação da Base de Pesquisa do Instituto Oceanográfico (IO) da Universidade de São Paulo (USP), indicado na FIGURA 12 pela presença do marégrafo localizado junto à base do IO-USP.

FIGURA 12 – LOCALIZAÇÃO DO SISTEMA ESTUARINO – LAGUNAR DE CANANÉIA – IGUAPE E DO MARÉGRAFO NA BASE DE PESQUISA DO INSTITUTO OCEANOGRÁFICO (IO-USP).



FONTE: Modificado de SANTOS; ROSSO (2008).

O sistema estuarino lagunar de Cananéia – Iguape, onde está incluída a Ilha de Cananéia, possui duas ligações principais com o oceano, ao norte com um canal único denominado de Mar Pequeno e ao sul com uma bifurcação formando dois canais, o Mar de Cananéia e o Mar de Cubatão. A dinâmica de circulação local é regida principalmente pela ação de ondas de maré e da descarga dos rios e, ocasionalmente, influenciada pela ação dos ventos. O principal aporte de água doce para o sistema é dado pelo rio Ribeira de Iguape, através do

canal artificial do Valo Grande, e também pelos rios Itapitangui, das Minas e Taquari. A contribuição anual total da bacia formada por esses rios foi estimada por Bonetti Filho (1997), com base no escoamento superficial, em 43 m³/s.

A maré observada na região é do tipo mista com predominância semidiurna, e média de altura de 0,81 m, sendo as médias de sizígia em torno de 1,20 m e da quadratura de 0,26 m (MESQUITA; HARARI, 1983 apud MIYAO; NISHIHARA; SARTI, 1986). A maré de vazante é mais intensa que a maré de enchente, sendo que há uma defasagem de cerca de uma hora entre a maré de enchente que chega ao sul e ao norte do estuário (LORENZETTI, 1976 apud MIYAO; NISHIHARA; SARTI, 1986). Segundo Melo Filho (2017), 72,8% da maré bruta é representada pela maré astronômica em Cananéia, os outros 27,2% são divididos entre variações sazonais, maré meteorológica e maré de vento, sendo que destas, a maré meteorológica representa 79,5% da composição total.

A onda de maré enchente, ao penetrar ao sul do sistema estuarino, se divide pelo Mar de Cananéia e de Cubatão, indo em direção norte. Quando o Mar de Cananéia encontra o Mar Pequeno, ao norte da Ilha de Cananéia, parte da onda de maré continua se propagando pelo Mar Pequeno e a outra parte retorna para sul pelo Mar de Cubatão. Ao norte do sistema estuarino, cerca de uma hora mais tarde, a onda de maré enchente entra pela Barra de Icapara e se encontra com a onda de maré que se propaga de sul para norte no Mar Pequeno, completando o processo de enchente da maré.

Desse mesmo ponto se inicia o processo da maré vazante que também se dá nas duas direções. A onda de maré vazante para norte sai pela Barra de Icapara, enquanto que a onda que se propaga para sul se soma com a onda de vazante proveniente do Mar de Cananéia. Após contornarem a Ilha de Cananéia a onda se direciona para sair do estuário através Mar de Cubatão (MALUF, 2009).

Situada ao sul do Trópico de Capricórnio a região de Cananéia possui média de temperatura de 21,2 °C, sendo que nos meses mais quentes essa média chega a 24,5 °C e nos mais frios 7,8 °C. Recebe cerca de 133,569 ly de radiação solar por ano, tendo uma variação moderada ao longo do ano, podendo apresentar até 61% a mais de radiação durante o período de verão. Esses períodos também apresentam maiores índices de precipitação, devido à temperatura do ar elevada, com correntes de convecção mais fortes o que provocam as tempestades comuns durante o verão (SCHAEFFER-NOVELLI; MESQUITA, 1990).

A média dos ventos na região é de 3,5 m/s, com incidência predominante de ventos sudoeste (SW) entre janeiro e setembro e leste (E) de outubro a dezembro. A circulação diária é bem marcada, fortemente condicionada à ação da brisa marinha (BERGAMO, 2000).

As frentes de massa tropical dominam o clima da região entre a primavera e o verão e as frentes frias, de origem polar, durante o inverno. Durante os períodos de transição são comumente identificadas massas de ar estacionárias, entre fevereiro e março, massas quentes que ocasionam alta precipitação e, entre setembro e outubro, com predominância de massas de ar frias, geralmente ocasionando alta nebulosidade e chuvas persistentes (TUNDISI; MATSUMURA-TUNDISI, 2001).

4.2 CONJUNTO E PROCESSAMENTO DE DADOS

Os dados de nível relativo do mar foram coletados por um marégrafo do tipo A.OTT da Base de Pesquisa do Instituto Oceanográfico (IO) da Universidade de São Paulo (USP). Situado na Ilha de Cananéia à 25° 01' 01,31'' S e 47° 55' 07,14'' W (FIGURA 12), o marégrafo possui registros desde 1955. A série de dados utilizada neste trabalho possui dados até 2006. Entretanto, considerando o período onde dados meteorológicos (velocidade e direção do vento e pressão atmosférica) e dados de nível do mar era concomitante, somente dados horários entre 2002 e 2006 foram utilizados, totalizando 1521 dias.

Os dados de pressão atmosférica e vento não estavam disponíveis para a região de Cananéia em um período que se sobrepunha aos dados de maré, dessa forma optou-se por utilizar as séries meteorológicas da estação de Pontal do Sul em Pontal do Paraná, distante em 75 km do marégrafo situado em Cananéia. O Complexo Estuarino de Paranaguá (CEP) está localizado ao sul do sistema de Cananéia-Iguape e é interligado a ele por um canal interior situado a oeste da Ilha do Cardoso até a Baía de Pinheiros (ao norte do CEP).

Oliveira (2004) realizou o mesmo procedimento e em seu trabalho pode ser encontrada uma comparação de séries maregráficas de Paranaguá e Cananéia, dos anos de 1997 a 1999, indicando alta correlação (93,26%) entre o comportamento do nível médio do mar nas duas regiões. Entretanto, Meena e Agrawal (2015) destacam que o uso de dados de uma estação distante à região para onde será realizada a previsão pela RNA-MLP pode prejudicar os resultados obtidos pela rede. Segundo os autores a estação de coleta dos dados deve ser


próxima, a uma distância aproximada de 20 a 30 km do local da previsão evitando uma distância maior de 100 km.

Apesar do sistema estuarino lagunar de Cananéia–Iguape–Paranaguá estar interconectado e os fenômenos atmosféricos ocorrerem, em geral, em maiores escalas espaciais, a distância entre o marégrafo situado em Cananéia e a estação meteorológica em Pontal do Sul supera em cerca de 50 km a distância indicada por Meena e Agrawal (2015), podendo ser motivo de equívoco durante o treinamento da RNA-MLP. Nesse cenário, optou-se também por realizar testes utilizando um conjunto de dados proveniente de uma reanálise disponibilizada pelo *National Centers for Environmental Prediction (NCEP) Climate Forecast System Reanalysis (CFSR)*, cujo ponto mais próximo do marégrafo está a 16 km. O NCEP CFSR disponibiliza, de 1979 a 2009, séries históricas globais de dados dos sistemas atmosférico, oceânico, terrestre e de gelo marinho acoplados, através da sobreposição de registros obtidos *in situ* e via satélite com modelagens de previsão curta (até 6h). Estudos preliminares apontam o NCEP CFSR como superior na qualidade dos dados em relação ao seu equivalente mais antigo, o NCEP/NCAR (SAHA et al, 2010).

4.2.1 Processamento dos dados de nível do mar

A série temporal dos dados de nível do mar de Cananéia pode ser conferida na FIGURA 13. Observa-se no gráfico, no trecho indicado em azul, uma redução significativa na variabilidade dos dados. Nesse período, entre outubro de 2005 e maio de 2006, não haviam registros da altura do nível do mar e o período foi completado somente com dados de previsão da maré astronômica, por isso a redução da variabilidade, já que essa previsão exclui as oscilações de origem meteorológica.

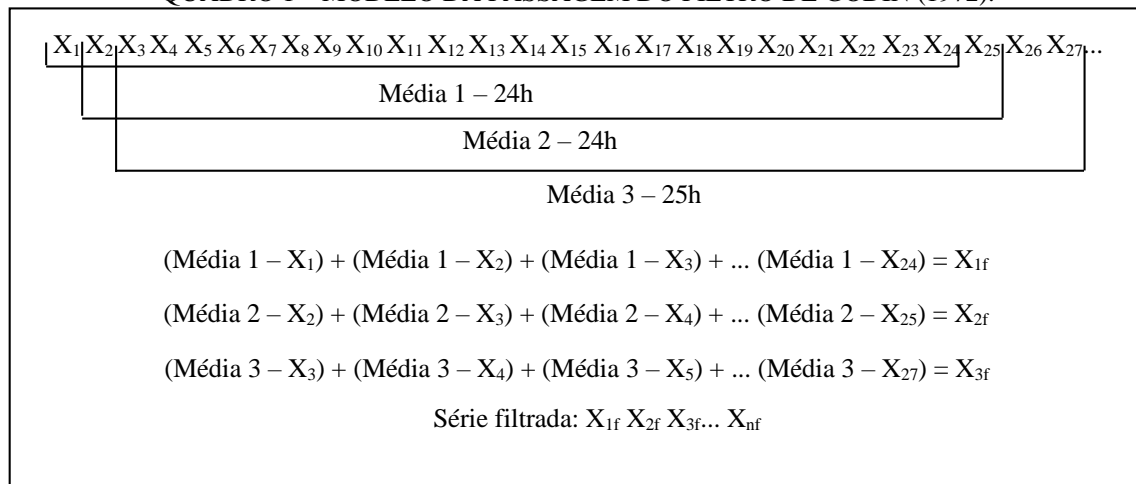
FIGURA 13 – SÉRIE TEMPORAL DA OSCILAÇÃO DO NÍVEL DO MAR NA BASE DE CANANÉIA. EM DESTAQUE, O PERÍODO ENTRE OUTUBRO DE 2005 E MAIO DE 2006 QUE FOI INTERPOLADO COM DADOS DE MARÉ ASTRONÔMICA.



FONTE: O autor (2018).

Os dados de nível do mar passaram por um controle de qualidade anterior ao trabalho que consistiu na extração de valores espúrios e preenchimento de dados faltantes. Assim, para o presente trabalho apenas foi realizada a extração da maré meteorológica dos registros da maré observada. Essa extração foi realizada através da aplicação do filtro proposto por Godin em 1972 (QUADRO 1) aplicado através do programa FILTERS. O filtro consiste na aplicação de três médias móveis sucessivas ao longo da série de observações. A primeira média móvel é obtida das médias das 24 primeiras observações e avançando de hora em hora até o final. O mesmo procedimento é repetido uma segunda vez e, finalmente, o último procedimento é semelhante, mas com a última média móvel de 25 horas. Assim, durante a aplicação das médias móveis para a série em questão, foram perdidos o primeiro e os dois últimos dias da série de dados. A soma das diferenças entre as médias móveis aplicadas e o registro observado será a maré meteorológica (FRANCO, 2009). Apenas para fins de teste, o filtro foi aplicado de quatro formas distintas e os resultados foram comparados.

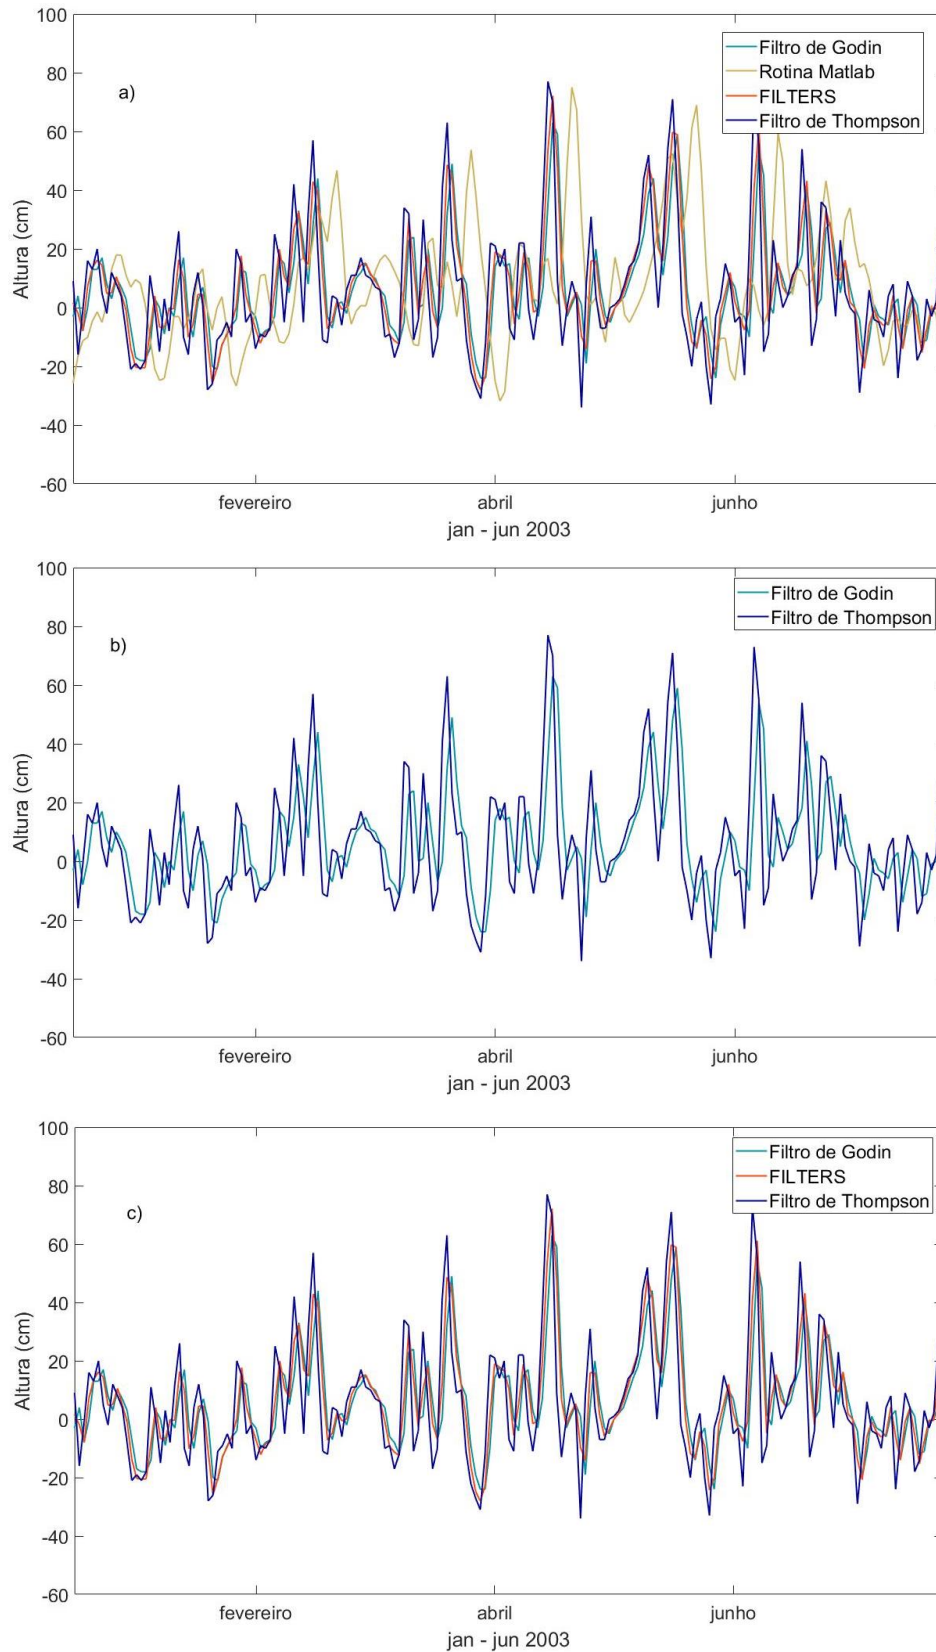
QUADRO 1 – MODELO DA PASSAGEM DO FILTRO DE GODIN (1972).



FONTE: O autor (2018).

Uma rotina do Matlab foi elaborada com base no mesmo princípio do filtro de Godin, entretanto a série filtrada apresentou uma diferença de fase em relação aos demais filtros aplicados (FIGURA 14). Os resultados obtidos através do programa PACMARÉ, pelos filtros Thompson (1983) e Godin (1972), foram bastante similares entre si, assim como com o programa FILTERS desenvolvido por Eduardo Marone (1989). A comparação pode ser visualizada nas FIGURA 14.

FIGURA 14 – COMPARAÇÃO ENTRE AS SÉRIES DE MARÉ METEOROLÓGICA EXTRAÍDAS PELOS DIFERENTES PROGRAMAS. EM a) A COMPARAÇÃO ENTRE TODOS OS MÉTODOS; EM b) OS FILTROS DO PACMARÉ E, EM c) OS FILTROS DO PACMARE E O PROGRAMA DE FILTERS.



FONTE: O autor (2018).

Com base nas comparações apresentadas na FIGURA 14, optou-se neste trabalho por utilizar o filtro de Godin, aplicado através do programa FILTERS. Apesar do programa escolhido e o PACMARÉ apresentarem valores similares, o PACMARÉ não apresenta a série horária filtrada, apenas as médias diárias, o que inviabilizaria seu uso na RNA proposta.

As constantes harmônicas dos componentes de maré extraídas do conjunto de dados, são apresentadas na TABELA 2. A tabela apresenta as amplitudes e fases das principais componentes, obtidas pelo método de Franco e Rock (1971), através do programa PACMARÉ. A tabela completa das componentes pode ser consultada no APÊNDICE I, tabela 1.

Os períodos predominantes de maré astronômica em Cananéia consistem de longo período, diurno, semidiurno, terdiurno e quaterdiurno, o que confere com o encontrado por Miyao e Harari (1989) em um estudo preliminar das componentes harmônicas da região estuarina de Cananéia. Mais detalhes podem ser encontrados no mesmo trabalho acima citado.

TABELA 2 – COMPONENTES HARMÔNICAS PRINCIPAIS DE CANANÉIA E SUAS RESPECTIVAS AMPLITUDES E FASES.

Símbolo	Amplitude H (cm)	Fase local (graus)
Espécie: Longo período		
Sa	2,84	55,72
Espécie: Diurna		
Q ₁	3,06	49,11
ρ ₁	0,43	51,94
O ₁	9,84	73,14
P ₁	2,55	134,93
S ₁	1,61	108,75
K ₁	6,37	133,23
Espécie: Semidiurna		
2N ₂	2,01	130,15
μ ₂	2,29	132,44
N ₂	5,47	140,03
M ₂	36,7	69,71
λ ₂	0,54	10,3
L ₂	1,4	69,43
S ₂	23,8	73,17
R ₂	0,65	113,54
K ₂	7,51	64,02

Espécie: Terdiurna		
M ₃	7,01	200,38
Espécie: Quaterdiurna		
M ₄	5,9	156,29

FONTE: o autor (2018).

4.2.2 Processamento dos dados meteorológicos

Como mencionado anteriormente, os dados meteorológicos utilizados neste trabalho foram obtidos em duas fontes distintas: os dados da estação meteorológica de Pontal do Sul (25°34'26,41"S e 48°20'58,74"O), que consistiam em dados de velocidade (VEL em m/s) e direção do vento (DIR em °) e pressão atmosférica (P em mb) e os dados de reanálise do NCEP CFSR (25°01'01,31"S e 47°55'07,14"O), que consistiam em dados de velocidade do vento (m/s), pressão atmosférica (mb) e taxa de variação da temperatura do ar (°C) e precipitação (m/s). Para ambos os conjuntos de dados os tratamentos foram realizados nos softwares Matlab (versões R2017a e R2007b) e Excel (versão 2016) e consistiu em eliminar dados espúrios, identificar e interpolar dados faltantes.

Na TABELA 3a são mostrados os dados estatísticos das séries da estação meteorológica de Pontal do Sul e do marégrafo de Cananéia. Mais de 99% dos dados puderam ser utilizados nesse trabalho, sem necessidade de manipulação dos mesmos. Nos casos de dados espúrios ou faltantes estes foram substituídos pelos valores médios entre os horários adjacentes. Na TABELA 3b as mesmas estatísticas são apresentadas para os dados do NCEP.

TABELA 3a – DADOS ESTATÍSTICOS DA SÉRIE TEMPORAL DE NÍVEL DO MAR, VENTO E PRESSÃO ATMOSFÉRICA DA ESTAÇÃO DE PONTAL DO SUL. NRM – NÍVEL RELATIVO DO MAR; NM – NÍVEL MÉDIO (AO REDOR DE ZERO); VEL – VELOCIDADE DO VENTO EM METROS POR SEGUNDO; DIR – DIREÇÃO DO VENTO EM GRAUS; E P – PRESSÃO ATMOSFÉRICA MEDIDA EM MILIBARES. * DADOS DE NÍVEL DO MAR DISPONÍVEIS PARA TREINAMENTO DA RNA.

	NRM (cm)	NM (cm)	VEL (m/s)	DIR (graus)	P (mb)
Mín	58,5	-111	0	0	998,28
Máx	319,4	149,9	15,18	360	1034,7
Média	182,47	12,97	3,49	176,97	1016,89
Mediana	182,2	12,7	3,02	171,43	1016,8
Desvio padrão	39,44	39,44	2,29	94,95	5,31
Desvio médio	32,16	32,16	1,84	80,26	4,32
% dados disponíveis (% utilizada na RNA)	100,00% (84,02%*)	100,00% (84,02%*)	99,35%	99,35%	99,34%

TABELA 3b – DADOS ESTATÍSTICOS DA SÉRIE TEMPORAL DA VELOCIDADE DO VENTO, TAXA DE PRECIPITAÇÃO, TAXA DE VARIAÇÃO DA TEMPERATURA DO AR E PRESSÃO ATMOSFÉRICA DO NCEP. VEL – VELOCIDADE DO VENTO EM METROS POR SEGUNDO; PRECIPITAÇÃO EM METROS POR SEGUNDO; TEMPERATURA DO AR EM GRAUS CÉLSIUS; E P – PRESSÃO ATMOSFÉRICA MEDIDA EM MILIBARES.

	VEL (m/s)	Precipitação	Temperatura do ar (°C)	P (mb)
Mín	32,000	0,02	0,022	813,605
Máx	32,02	0,02	0,062	813,860
Média	32,005	0,02	0,043	813,729
Mediana	32,005	0,02	0,043	813,727
Desvio padrão	0,003	$1,1466 \times 10^{-10}$	0,006	0,03964
Desvio médio	0,002	$5,8105 \times 10^{-11}$	0,005	0,03217
% dados disponíveis (% utilizada na RNA)	100,00%	100,00%	100,00%	100,00%

FONTE: O autor (2018).

Para análise e descrição da climatologia local, foram calculadas as componentes zonal e meridional do vento (u e v , respectivamente) através das equações 10a e 10b. Os dados de reanálise já possuíam as componentes e a tensão de cisalhamento (ou estresse) do vento disponibilizados.

$$u = -|W| \times \text{seno} \left[\frac{\pi}{180} \times \text{dir}(\text{graus}) \right] \quad (10a)$$

$$v = -|W| \times \text{cos} \left[\frac{\pi}{180} \times \text{dir}(\text{graus}) \right] \quad (10b)$$

onde W é o módulo da velocidade do vento e dir é a direção em graus. Em alguns dos testes realizados foram utilizadas as componentes perpendicular e paralela do vento (u' e v') em relação a orientação da costa na região de Cananéia. Como parte da maré meteorológica é explicada pelo transporte de Ekman, é importante considerar que em alguns casos a componente meridional do vento (v) não coincide com o vento que é paralelo à costa, já que a orientação da costa varia de região para região. Para o cálculo das componentes u' e v' foram utilizadas as equações 10a e 10b porém considerando, nos dados brutos de direção do vento, os eixos N-S e L-O rotacionados em 50° no sentido horário devido à orientação da costa sul de São Paulo. Também foi calculada a tensão de cisalhamento do vento, em N/m^2 usando as equações 11a e 11b:

$$Tx = \rho C_D |W| u \quad (11a)$$

$$Ty = \rho C_D |W| v \quad (11b)$$

onde ρ é a densidade do ar ($1,2 \text{ kg/m}^3$) e C_D é o coeficiente de arrasto do vento na superfície, definido da seguinte forma:

$$\begin{array}{ll}
 W \leq 1 & C_D = 0.00218 \\
 1 < W \leq 3 & C_D = (0.62 + 1.56/W) * 0.001 \\
 3 < W < 10 & C_D = (0.49 + 0.065 * W) * 0.001
 \end{array}$$

Antes de iniciar o treinamento da RNA-MLP, os dados do período entre outubro de 2005 e maio de 2006 foram desconsiderados, por conta da série maregráfica ser apenas de dados astronômicos. Também foram desconsiderados o primeiro e os dois últimos dias de observações, devido à perda de dados de nível do mar durante a passagem do filtro de Godin. Com intuito de evitar que uma variável receba maior importância do que outra durante o treinamento, todos os dados passaram por uma normalização antes de serem apresentados à RNA-MLP, para que os mesmos assumam valores dentro do intervalo entre -1 e 1 .

4.3 TREINAMENTO E IMPLEMENTAÇÃO DA RNA-MLP

Após o processamento dos conjuntos de dados (4.2), os dados da estação meteorológica de Pontal do Sul de pressão atmosférica, velocidade e direção do vento, bem como suas componentes zonal e meridional (u e v) e a maré astronômica foram apresentados à RNA-MLP com dois intervalos distintos de 1h e 24h como variáveis preditoras da maré meteorológica. Esse conjunto de dados e combinação das variáveis de entrada (preditoras) foi utilizado para os testes preliminares e definição das melhores arquiteturas da RNA-MLP.

A RNA-MLP foi elaborada por Daiane Gracieli Faller, para aplicação em Matlab, e descrita especificamente para o objetivo desejado. As configurações testadas são apresentadas na TABELA 4. Os *folders* indicam a quantidade de subconjuntos utilizados para treinamento e validação do modelo. As épocas correspondem a quantidade de iterações utilizadas como critério de parada da RNA-MLP para cada configuração testada. Mais detalhes das demais configurações apresentadas na tabela podem ser consultadas na revisão bibliográfica (3.2).

TABELA 4 – CONFIGURAÇÕES PARA TESTE DA RNA-MLP UTILIZADAS.

	Quantidade	Especificação
Intervalos de tempo	2	1h e 24h
Folders	3	3, 7 e 10
Épocas	6	100, 200, 300, 500, 1000 e 1500
Camadas	2	1 e 2
Neurônios 1ª camada	6	5, 10, 15, 20, 25 e 30
Neurônios 2ª camada	6	5, 10, 15, 20, 25 e 30
Função de ativação	3	Log sigmoide (logsig), tangente sigmoide (tansig) e linear (purelin)
Função de treinamento	3	Levenberg-Marquardt (lm), gradiente descendente (gd) e gradiente descendente com aprendizado adaptativo (gda)
Total de RNAs testadas	23328	

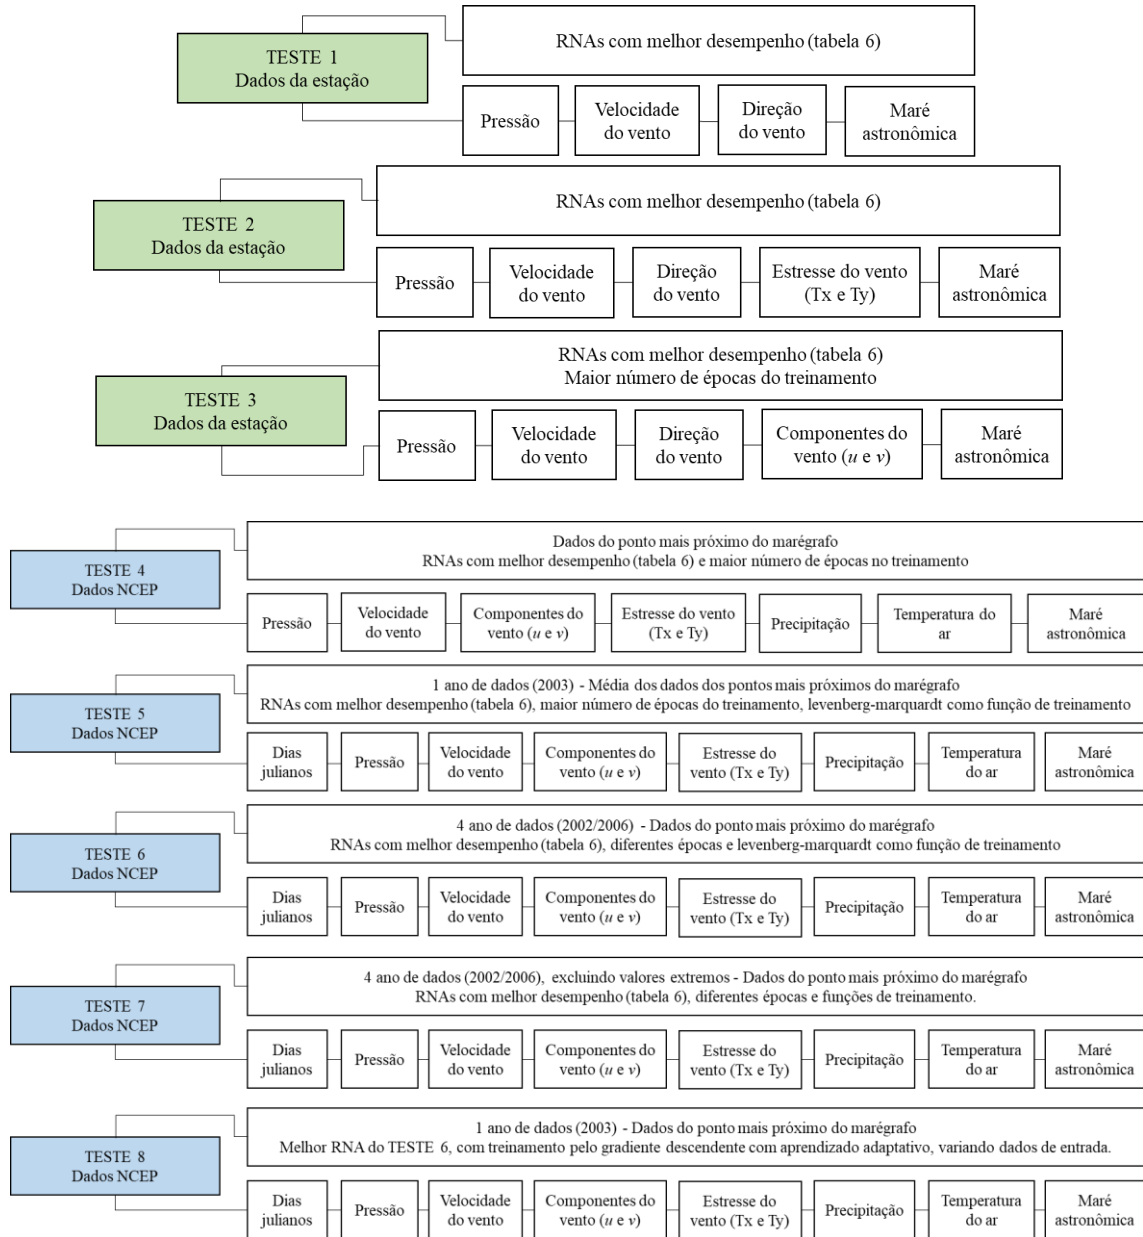
FONTE: O autor (2018).

Para cada arquitetura testada calculou-se o erro médio absoluto (*mean absolute error* – MAE), a raiz quadrada do erro quadrático médio (*root mean square error* – RMSE) e o coeficiente de correlação de Pearson (R). Também foram utilizados para análise dos resultados a diferença entre os valores previstos (y_i^m) e observados (y_i^o) e o coeficiente de correlação entre eles.

Os resultados obtidos do treinamento das 23328 RNA-MLP são apresentados e discutidos no item 5.2. Esses resultados foram utilizados para seleção das melhores arquiteturas e para o delineamento dos testes finais.

Variações na arquitetura e nas configurações da RNA-MLP não apresentaram melhoras significativas na previsão. Foram testadas arquiteturas de RNA-MLP com mais de 2 camadas, diferentes funções de ativação para cada uma delas e dois tipos diferentes de normalização dos dados. Optou-se, então, por testar diferentes combinações de dados de entrada, como mostra o QUADRO 2. No mesmo, os testes estão separados em dois conjuntos: os testes realizados com os dados da estação meteorológica de Pontal do Sul, em verde, e os testes realizados com os dados de reanálise do NCEP CFSR, em azul. O quadro apresenta apenas os testes que apresentaram melhoras em algum dos parâmetros acima utilizados (MAE, RMSE ou R).

QUADRO 2 – ESQUEMATIZAÇÃO DOS TESTES REALIZADOS COM AS MELHORES ARQUITETURAS DA RNA-MLP. OS TESTES DE 1 À 3 FORAM REALIZADOS COM OS DADOS DE ENTRADA DA ESTAÇÃO METEOROLÓGICA DE PONTAL DO SUL (75 KM DE CANANÉIA) E OS TESTES 4 À 8 COM OS DADOS DE REANÁLISE NCEP CFSR.



FONTE: o autor (2018).

Todos os procedimentos realizados durante o processamento dos dados, até o delineamento dos testes finais é apresentado resumidamente no QUADRO 3.

QUADRO 3 – RESUMOS DAS METODOLOGIAS UTILIZADAS NESTE TRABALHO. OS ITENS EM VERDE FORAM REALIZADOS NO EXCEL, EM AZUL NO PACMARÉ E EM VERMELHO NO MATLAB. O ITEM (h) FOI APLICADO EM MAIS DE UM PROGRAMA, COMO DESCRITO NO ITEM 4.2.1.

<p>Etapa 1: Processamento dos dados</p> <p>a) Identificação de dados espúrios ou faltantes por análise gráfica.</p> <p>b) Remoção de dados espúrios usando a ferramenta de filtro.</p> <p>c) Substituição de dados faltantes ou espúrios pela média entre horários adjacentes.</p> <p>d) Seleção do período de dados a serem utilizados (nov. 2002 – dez. 2006).</p> <p>e) Dados estatísticos da série temporal (mín., máx., média, mediana, desvios e % de dados disponíveis).</p> <p>f) Extração das componentes harmônicas de Cananéia (método de Franco e Rock, 1971).</p> <p>g) Extração da MM (filtro passa baixa de Thompson (1983) e Godin (1972)).</p> <p>h) Comparação e análise gráfica das séries temporais de NRM e MM.</p> <p>i) Comparação gráfica entre as MM extraídas pelos diferentes filtros.</p> <p>j) Seleção de variável, período e do ponto mais próximo do marégrafo para download dos dados do NCEP.</p> <p>k) Análise de dados meteorocanográficos</p> <p style="padding-left: 40px;">Precipitação e temperatura: análise gráfica;</p> <p style="padding-left: 40px;">Pressão: máx. e mín. por estação e comparação dados ESTAÇÃO X NCEP;</p> <p style="padding-left: 40px;">Vento: cálculo de u, v e tensão de cisalhamento do vento;</p> $U = - v \times \text{seno} \left[\frac{\pi}{180} \times \text{dir}(\text{graus}) \right] \quad V = - v \times \text{cos} \left[\frac{\pi}{180} \times \text{dir}(\text{graus}) \right]$ $Tx = \rho C_D v U \quad Ty = \rho C_D v V$ <p style="padding-left: 40px;">Maré: autocorrelação da maré meteorológica (função <i>autocorr</i>)</p> <p style="padding-left: 40px;">Correlação de Pearson entre os dados meteorocanográficos</p> <p>Etapa 2: Rede Neural Artificial</p> <p>a) Elaboração das planilhas com os dados de 1h, 6h, 12h, 24h, 48h.</p> <p>b) Definição dos dados da estação de entrada: pressão, velocidade e direção do vento, u e v e maré astronômica.</p> <p>c) Definição dos dados do NCEP de entrada: pressão, velocidade do vento, u e v, T_x e T_y, precipitação, temperatura do ar e maré astronômica.</p> <p>d) Definição da saída desejada: maré observada (MM + Maré Astron.).</p> <p>e) Normalização dos dados (-1 e 1).</p> <p>f) Particionamento dos dados, usando validação cruzada (3, 7 e 10).</p> <p>g) Definição dos parâmetros da RNA (TABELA 4).</p> <p>h) Cálculo dos valores de erro (<i>MAE</i> e <i>RMSE</i>).</p> <p>i) Análise e discussão dos resultados.</p>
--

FONTE: O autor (2018).

5 RESULTADOS E DISCUSSÃO

O presente item é subdividido em função das diferentes análises realizadas. Em 5.1 são apresentadas as análises das séries temporais de nível do mar e meteorológicas. No subitem


5.2 os resultados obtidos nos testes preliminares são apresentados e discutidos. E em 5.3 são apresentados e discutidos os resultados das simulações das melhores RNA-MLP obtidas.

5.1 ANÁLISE DAS SÉRIES TEMPORAIS

A série de dados da maré meteorológica extraída pelo filtro de Godin (1971) é apresentada na FIGURA 15 em comparação com os dados do nível médio observado. Vale ressaltar a eficiência do filtro no período entre outubro de 2005 e maio de 2006, onde a série foi completada com dados apenas da maré astronômica e o filtro identificou com clareza o período em questão.

As maiores alturas observadas da maré meteorológica foram entre 70 e 75 cm, nos meses de abril de 2003 e abril de 2005. A média das alturas foi de - 0,21 cm, excluindo o período com ausência de dados meteorológicos. O desvio padrão de toda a série foi igual a $\pm 18,52$ cm.

FIGURA 15 – SÉRIE TEMPORAL DAS OSCILAÇÕES DO NÍVEL DO MAR E DA MARÉ METEOROLÓGICA EXTRAÍDA ATRAVÉS DO FILTRO DE GODIN PELO PROGRAMA FILTERS.




FONTE: O autor (2018).

Para a série de maré meteorológica também foi calculada a função de autocorrelação (FIGURA 16), usando a função de autocorrelação simples (ACF) do MatLab. A função de autocorrelação permitiu observar a correlação existente entre as observações sucessivas para

um determinado período de tempo, análise que forneceu suporte para a definição dos intervalos de tempo a serem testados na RNA-MLP. A autocorrelação da maré meteorológica em 6, 12, 18 e 24h foi de 98,41%, 92,56%, 83,13% e 71,21%, respectivamente.

FIGURA 16 – AUTOCORRELAÇÃO DA MARÉ METEOROLÓGICA. PARA 6h DE 98,41%, 12h DE 92,56%, 18h DE 83,13% E 24h DE 71,21%.

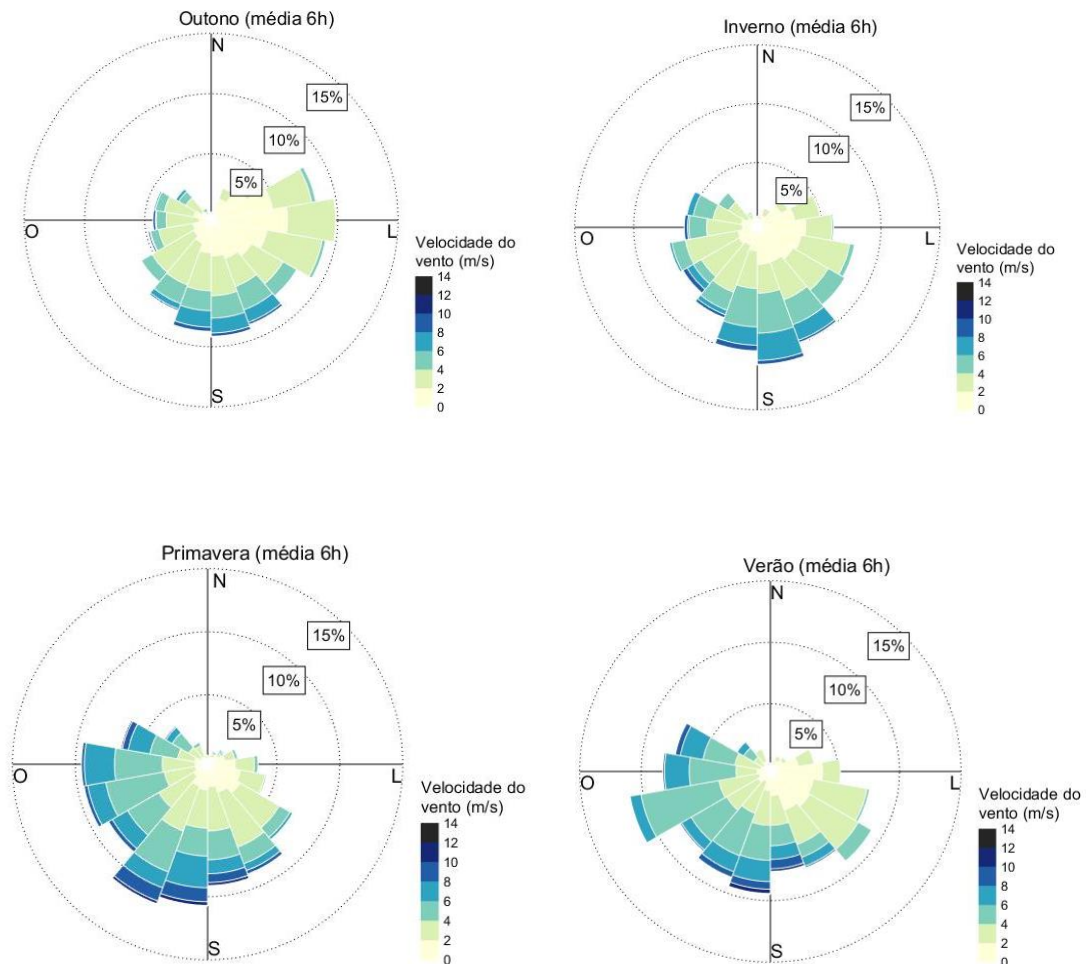


FONTE: O autor (2018).

A climatologia local a partir da análise dos dados meteorológicos é apresentada a seguir.

Os ventos observados na região para o período considerado neste trabalho apresentaram predominância de incidência de sul durante todo o ano, com intensidade média anual igual à 3,49 m/s ($\pm 0,299$ m/s), que corrobora com o descrito por Bergamo (2000). Entre as estações, no outono há a predominância de ventos de sudeste, com intensidade máxima de 13 m/s e mínima de 0,3 m/s e média de 2,82 m/s ($\pm 0,279$ m/s). Durante o inverno a predominância é de ventos sul, com intensidade máxima de 12 m/s e mínima de 0,09 m/s, sendo a média de 3,20 m/s ($\pm 0,333$). A primavera apresenta ventos alternados entre sul e sudoeste, com intensidade máxima de 14 m/s, mínima de 0,10 m/s e média de 4,12 m/s ($\pm 0,158$). Por fim, no verão a intensidade máxima registrada foi de 15 m/s e a mínima de 0,15 m/s, a média da estação foi de 3,75 m/s ($\pm 0,065$) e a predominância foi de ventos sul/ sudoeste. Todas as estatísticas aqui apresentadas são provenientes dos dados da estação meteorológica de Pontal do Sul, equivalentes ao período entre novembro de 2002 e dezembro de 2006, incluindo eventos extremos. A climatologia para as médias de 6h do conjunto de dados pode ser observada na FIGURA 17.

FIGURA 17 – CLIMATOLOGIA DE VENTOS PARA A REGIÃO ESTUARINO-LAGUNAR DE CANANÉIA – IGUAPE, ENTRE NOVEMBRO DE 2002 E DEZEMBRO DE 2006. AS ROSAS DOS VENTOS APRESENTAM AS MÉDIAS DE 6H NOS PERÍODOS DE a) OUTONO; b) INVERNO; c) PRIMAVERA; d) VERÃO.




FONTE: O autor (2018).

Foram comparados os dados de pressão atmosférica da estação meteorológica de Pontal do Sul e dos dados de reanálise do NCEP. Na FIGURA 18 é possível observar a sazonalidade marcada pelas estações do ano para ambos os conjuntos. A média dos dados da estação foi igual à 1016,78 mb ($\pm 5,320$ mb), sendo a média para os períodos de verão de 1013 mb ($\pm 0,937$ mb) e de inverno 1020 mb ($\pm 1,235$ mb). Ainda para esse conjunto, as médias do outono e primavera foram iguais a 1018 mb ($\pm 0,254$ mb) e 1014 mb ($\pm 0,718$ mb), respectivamente. Para os dados do NCEP, a média foi igual à 1000,099 mb ($\pm 0,040$ mb), sendo que a variação entre as estações foi bastante reduzida. Nos meses de verão a média foi de

1000,07 mb ($\pm 0,006$ mb) e nos meses de inverno de 1000,131 mb ($\pm 0,011$ mb). No outono e primavera as médias foram de 1000,096 mb ($\pm 0,016$ mb) e 1000,098 ($\pm 0,018$ mb), respectivamente.


FIGURA 18 – SÉRIE TEMPORAL DA ESTAÇÃO METEOROLÓGICA DE PONTAL DO SUL (EM PRETO) E DO NCEP (EM AZUL) DOS DADOS DE PRESSÃO ATMOSFÉRICA PARA TODO O PERÍODO ANALISADO.



FONTE: O autor (2018).

As taxas de temperatura do ar e precipitação, disponibilizadas pelo NCEP, corroboram com o padrão da região já descrito por outros autores (SCHAEFFER-NOVELLI; MESQUITA, 1990). Os períodos com maior precipitação, no geral, coincidiram com os de maior temperatura, nas estações de verão. Esses padrões estão apresentados na FIGURA 19.

FIGURA 19 – TAXAS DE VARIAÇÃO DA TEMPERATURA DO AR (EM PRETO) E DE PRECIPITAÇÃO (EM AZUL) PELOS DADOS DE REANÁLISE DO NCEP.



FONTE: O autor (2018).

Através da função de correlação do Matlab foram calculados os coeficientes de correlação linear de Pearson para as variáveis nível médio do mar, pressão atmosférica, velocidade e direção do vento, componentes do vento u e v , tensão de cisalhamento do vento (T_x e T_y), precipitação, temperatura do ar e maré meteorológica e podem ser conferidos na TABELA 5, focado apenas no nível médio e na maré meteorológica. A análise dos coeficientes de correlação pode ser um indicador de quais variáveis possuem maior peso nas alterações da altura do nível do mar, podendo ser uma ferramenta útil na determinação de quais variáveis utilizar como entrada no modelo de previsão (BILGILI; SAHIN; YASAR, 2007).

Em relação ao conjunto de dados utilizados, as correlações encontradas foram baixas e isso pode ser explicado pela não linearidade dos processos de interação entre o oceano e a atmosfera. Esses coeficientes foram determinantes na escolha das variáveis para os testes de sensibilidade da RNA-MLP aos dados.

TABELA 5 – COEFICIENTES DE CORRELAÇÃO LINEAR DE PEARSON ENTRE AS SÉRIES MAREGRÁFICAS E METEOROLÓGICAS DE PONTAL DO SUL E NCEP.

	Nível médio	Maré meteorológica
Nível médio	1	0,433933
Velocidade do vento	0,11528	0,178005
Velocidade do vento (NCEP)	0,0724	0,2516
Direção do vento	0,041791	0,159822
Pressão Atmosférica	0,023599	-0,01924
Pressão Atmosférica (NCEP)	0,0853	-0,0683

Temperatura do ar (NCEP)	- 0,0616	- 0,1106
Precipitação (NCEP)	0,0753	0,1404
u	0,06988	0,25812
v	0,24018	0,40015
u (NCEP)	0,0735	0,2469
v (NCEP)	0,1767	0,3602
Tx	-0,06822	-0,23812
Ty	-0,2243	-0,39256
Tx (NCEP)	0,1018	0,2627
Ty (NCEP)	0,1772	0,3773
Maré meteorológica	0,433933	1

FONTE: O autor (2018).

5.2 TESTES PRELIMINARES

Os primeiros resultados obtidos para as arquiteturas treinadas com os intervalos de 1h e 24h são apresentados e discutidos nesse item. Esses testes correspondem às 23328 arquiteturas diferentes de RNA-MLP cujo intuito do treinamento era identificar as melhores combinações de componentes para, caso necessário, realizar novos testes.

Os dados de entrada utilizados foram pressão atmosférica, velocidade e direção do vento, componentes zonal e meridional (u e v), obtidos através dos dados da estação meteorológica em Pontal do Sul, e a maré astronômica. Para fins de análise, foram selecionadas as 3 arquiteturas de RNA-MLP que apresentaram melhor desempenho para cada intervalo de tempo utilizado (tabelas 6 e 7), totalizando 6 testes distintos.

Os erros médios absolutos (*MAE*) foram similares nas 6 melhores arquiteturas, entre 11,2 cm e 11,6 cm para as previsões com intervalo de 1h e, entre 9,1 cm e 9,6 cm para as previsões diárias (intervalo de 24h). O erro quadrático médio (*RMSE*) também apresentou baixa variação entre as arquiteturas para ambos os períodos, apresentando valores em torno de 0,27 cm para as previsões horárias e 0,45 cm para as previsões diárias. Filippo et al. (2012), com um conjunto de entradas bastante similares ao utilizado nesses primeiros testes, também em uma RNA-MLP, obteve com sua melhor arquitetura um MAE igual à 13,90 cm e o coeficiente de correlação entre a série predita e observada igual à 0,9128. Apesar do erro da RNA-MLP no presente trabalho ter sido menor, a correlação dos resultados obtidos pela melhor arquitetura foi consideravelmente inferior, igual a 0,653.

As arquiteturas de RNA-MLP com melhor desempenho foram as que possuíam duas camadas ocultas e, no geral, com mais neurônios na primeira e poucos na segunda camada. Isso indica que para essa variabilidade de dados, a RNA-MLP identifica o padrão dos mesmos já na primeira camada de neurônios, necessitando de poucos neurônios na segunda camada para obter bons resultados. Um padrão similar também foi encontrado nos testes feitos por Imani, You e Kou (2014). No trabalho citado, os autores obtiveram a melhor arquitetura para previsão do nível do mar Cáspio também com duas camadas ocultas, sendo a primeira com 16 e a segunda com 8 neurônios.

Testes foram realizados com uma terceira camada oculta, mas os resultados foram bastante inferiores aos aqui apresentados. A partição dos dados em 10 *folders* foi a mais recorrente entre as melhores arquiteturas (ver também 5.3), apesar da divisão dos dados em 3 *folders* também ter aparecido entre elas. O maior número de épocas (ou iterações) foi recorrente nas arquiteturas com melhor desempenho. Testes extras aumentando o número de épocas serão apresentados e discutidos em 5.3.

As funções de ativação log sigmóide (*logsig*) e tangente sigmóide (*tansig*) foram as que apresentaram melhores resultados nas arquiteturas testadas, sendo que a tangente sigmóide apareceu mais vezes entre os melhores desempenhos (4 em um total de 6). Já em relação à função de treinamento, todas as melhores arquiteturas apresentaram como treinamento a função do gradiente descendente com aprendizado adaptativo.

TABELA 6 – RNA-MLP COM MELHOR DESEMPENHO, COM BASE NA ANÁLISE DO ERRO MÉDIO ABSOLUTO (*MAE*), DO ERRO QUADRÁTICO MÉDIO (*RMSE*) E DO COEFICIENTE DE CORRELAÇÃO (*R*) PARA INTERVALO DE 1H.

Folders	Épocas	Nº de camadas	Nº de neurônios na 1ª camada	Nº de neurônios na 2ª camada	Função de ativação	Função de treinamento	MAE (cm)	RMSE (cm)	R
10	1500	2	15	5	logsig	traingda	11,289	0,270	0,652
10	1000	2	5	5	tansig	traingda	11,454	0,274	0,653
3	1500	2	30	10	logsig	traingda	11,539	0,273	0,649

FONTE: O autor (2018).

TABELA 7 – RNA-MLP COM MELHOR DESEMPENHO, COM BASE NA ANÁLISE DO ERRO MÉDIO ABSOLUTO (*MAE*), DO ERRO QUADRÁTICO MÉDIO (*RMSE*) E DO COEFICIENTE DE CORRELAÇÃO (*R*) PARA O INTERVALO DE 24H.

Folders	Épocas	Nº de camadas	Nº de neurônios na 1ª camada	Nº de neurônios na 2ª camada	Função de ativação	Função de treinamento	MAE (cm)	RMSE (cm)	R
10	1500	2	25	5	tansig	traingda	9,134	0,452	0,633
3	1500	2	15	15	tansig	traingda	9,322	0,448	0,628

10	1000	2	10	10	tansig	traingda	9,529	0,453	0,632
----	------	---	----	----	--------	----------	-------	-------	-------

FONTE: O autor (2018).

As tabelas 8 e 9 mostram as arquiteturas com o pior desempenho dentre os treinamentos realizados. Apareceram nesses treinamentos a função de ativação tangente sigmóide e log sigmóide assim como nos melhores, mas também a função linear (*purelin*) que não apresentou bons resultados em nenhuma arquitetura testada. Os três algoritmos de treinamento apareceram também com os piores desempenhos, incluindo o gradiente descendente com aprendizado adaptativo que estava entre os melhores nas tabelas anteriores (6 e 7). Foram recorrentes nessas arquiteturas as partições dos dados em 3 *folders*, aparecendo também os de 7 e 10 em menor quantidade (1 de cada em 6 arquiteturas) e as arquiteturas com apenas uma camada, que não estavam presentes nos melhores desempenhos. O número de épocas, no geral, foi reduzido nessas arquiteturas, mas nos dois casos com maior número de épocas (1000) os erros foram significativamente maiores (*MAE* iguais à 441,18 cm e 377,11 cm e *RMSE* iguais à 278,31 cm e 160,74 cm, como pode ser conferido nas tabelas 8 e 9, respectivamente).

TABELA 8 – RNA-MLP COM PIOR DESEMPENHO, COM BASE NA ANÁLISE DO ERRO MÉDIO ABSOLUTO (*MAE*), DO ERRO QUADRÁTICO MÉDIO (*RMSE*) E DO COEFICIENTE DE CORRELAÇÃO (R) PARA O INTERVALO DE 1H.

Folders	Épocas	Nº de camadas	Nº de neurônios na 1ª camada	Nº de neurônios na 2ª camada	Função de ativação	Função de treinamento	MAE (cm)	RMSE (cm)	R
10	1000	1	5	-	logsig	trainlm	441,18	278,31	-0,0001
3	200	2	20	5	purelin	traingd	23,125	0,5707	-0,0073
3	200	2	5	20	tansig	traingd	21,859	0,5309	0,0005

FONTE: O autor (2018).

TABELA 9 – RNA-MLP COM PIOR DESEMPENHO, COM BASE NA ANÁLISE DO ERRO MÉDIO ABSOLUTO (*MAE*), DO ERRO QUADRÁTICO MÉDIO (*RMSE*), E DO COEFICIENTE DE CORRELAÇÃO (R) PARA O INTERVALO DE 24H.

Folders	Épocas	Nº de camadas	Nº de neurônios na 1ª camada	Nº de neurônios na 2ª camada	Função de ativação	Função de treinamento	MAE (cm)	RMSE (cm)	R
7	1000	1	10	-	logsig	trainlm	377,11	160,74	0,01
3	500	1	25	-	tansig	trainlm	72,112	14,805	-0,013
3	100	2	25	25	purelin	traingda	23,033	2,0682	0,001

FONTE: O autor (2018).

Para facilitar a referência entre as arquiteturas das RNA-MLP testadas, doravante será utilizada a nomenclatura:

“*nºfolders_époacas_nºcamadas_nºneurônios1ªcamada_nºneurônios2ªcamada_função deativação_funçãodetreinamento*”,

por exemplo, 10_1000_2_5_5_tansig_traingda, no caso da melhor arquitetura apresentada na TABELA 6.

5.3 DESEMPENHO DA RNA-MLP NAS SIMULAÇÕES DA MARÉ METEOROLÓGICA

Após análise dos resultados obtidos pelos testes preliminares, optou-se pelo delineamento de novos testes com objetivo de melhorar o desempenho da RNA-MLP, utilizando como parâmetros o erro médio (MAE), erro quadrático médio (RMSE) e coeficiente de correlação (R). Um resumo dos testes realizados pode ser encontrado no QUADRO 2.

Nos testes 1, 2 e 3 foram utilizados os dados da estação meteorológica de Pontal do Sul nas arquiteturas da RNA-MLP que apresentaram melhor desempenho (tabelas 6 e 7). Apesar da melhora significativa dos testes 2 e 3, ou seja, quando acrescentada a tensão de cisalhamento do vento (T_x e T_y) e as componentes zonal e meridional do vento (u e v), respectivamente, o *MAE* ainda foi mais alto que nos testes anteriores (cerca de 2 cm). Quando comparado à melhor RNA-MLP dos testes preliminares (10_1000_2_5_5_tansig_traingda), o acréscimo da tensão do vento como variável de entrada aumentou o coeficiente de correlação de 0,653 para 0,882 e reduziu o *RMSE* de 0,274 cm para 0,097 cm. Oliveira et al. (2007) e Oliveira et al. (2009), apesar das estimativas realizadas em diferentes intervalos de tempo, também obtiveram bons resultados com um conjunto de entradas que inclui as tensões do vento (T_x e T_y), a pressão atmosférica e a velocidade do vento. Os coeficientes de correlação do estudo citado foram próximos de 0,99 e a análise de sensibilidade indicou as tensões zonal e meridional do vento (T_x e T_y) como mais relevantes para a RNA-MLP.

A inclusão das componentes u e v no teste 3 resultou em um coeficiente de correlação de 0,903 entre os valores preditos e observados, e a uma redução do *RMSE* de 0,274 cm para 0,195 cm (TABELA 11). A substituição das componentes u (norte-sul) e v (leste-oeste) pelas componentes paralelas (u' , nordeste-sudoeste) e perpendicular (v' , sudeste-noroeste) à costa na região do estudo não influenciou no desempenho da RNA-MLP (TABELA 10).

TABELA 10 – COMPARAÇÃO DOS RESULTADOS DA RNA-MLP QUANDO SUBMETIDAS AO TREINAMENTO COM COMPONENTES NORTE-SUL, LESTE-OESTE (u e v) E AS COMPONENTES PARALELA E PERPENDICULAR À COSTA.

	Folders	Épocas	Nº de camadas	Nº de neurônios na 1ª camada	Nº de neurônios na 2ª camada	Função de ativação	Função de treinamento	MAE (cm)	RMSE (cm)	R
u e v	10	2000	2	25	5	tansig	traingda	13,475	0,1896	0,8986
u' e v'	10	2000	2	25	5	tansig	traingda	13,605	0,1893	0,8983

FONTE: O autor (2018).

Os testes 4 a 8, utilizando os dados de reanálise do NCEP, no geral, mostraram melhor desempenho que os dados da estação meteorológica de Pontal do Sul. A proximidade da fonte de dados meteorológicos do local da previsão pode ter influenciado nesses resultados, como apontado por Meena e Agrawal (2015). Entretanto, no trabalho de Oliveira et al. (2007), na mesma região de estudo, os dados do NCEP também apresentaram os melhores resultados para previsão da maré meteorológica.

O teste 8 teve como objetivo fazer uma análise preliminar da sensibilidade da RNA-MLP aos dados de entrada, pois a escolha adequada desses dados é determinante para o sucesso da previsão (IMANI; YOU; KOU, 2014). Para testar a influência de cada variável no desempenho da RNA-MLP, foram organizadas 9 diferentes combinações de entrada, que podem ser consultadas no quadro 1 do APÊNDICE II junto da tabela 1, com seus respectivos resultados.

O acréscimo da temperatura do ar e da precipitação como entradas da RNA-MLP foram opções para incrementar o modelo em questão, mas não ofereceram melhora significativa na previsão. No trabalho desenvolvido por Filippo et al. (2012) a maré astronômica foi a variável de entrada mais importante, seguida da componente zonal do vento (u) e da pressão atmosférica. No presente trabalho, pela análise prévia de sensibilidade da RNA-MLP, a maré astronômica também foi mais importante variável de entrada, seguida das componentes zonal e meridional (u e v) e dos dias julianos. A tensão de cisalhamento do vento aparece no trabalho de Oliveira et al. (2007) como a variável mais importante, mas para as previsões aqui realizadas essa variável não teve influência significativa.

Na TABELA 11 podem ser conferidas as melhores arquiteturas de RNA-MLP de cada teste, com seus respectivos *MAE*, *RMSE* e *R*. Os mesmos parâmetros para cada combinação de entrada do teste 8 podem ser conferidos na tabela 1 no APÊNDICE II.

TABELA 11 – VALORES DE ERRO E COEFICIENTE DE CORRELAÇÃO (R) DAS MELHORES RNA-MLP DE CADA TESTE. OS TESTES DE 1 À 3 FORAM ARQUITETURAS TESTADAS COM OS DADOS DA ESTAÇÃO METEOROLÓGICA EM PONTAL DO SUL E OS TESTES DE 4 À 8 COM OS DADOS DE REANÁLISE DO NCEP. MAIS DETALHES DA CONFIGURAÇÃO DE CADA TESTE PODEM SER CONFERIDOS NO QUADRO 2.

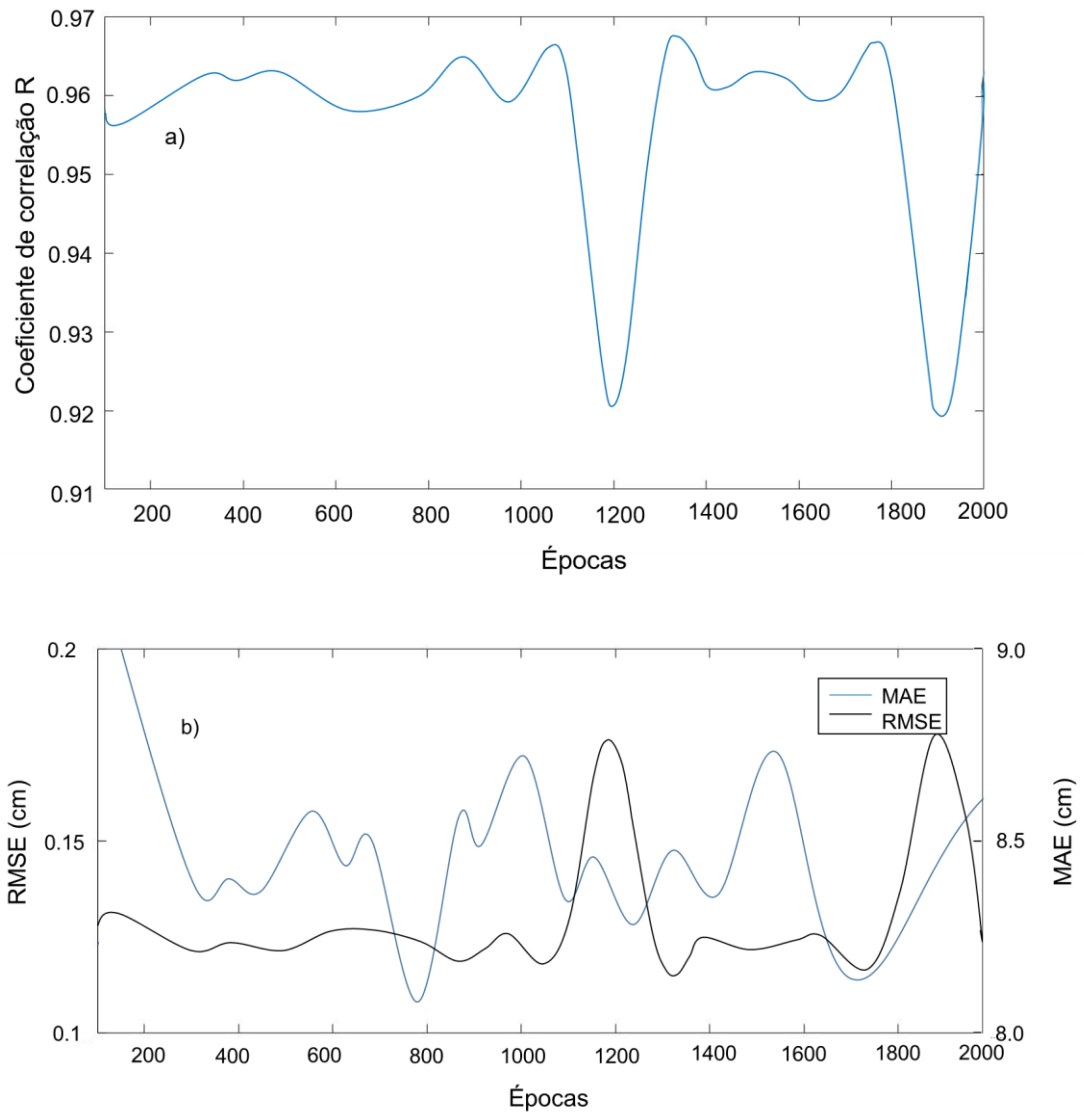
Teste	Folders	Épocas	Nº de camadas	Nº de neurônios na 1ª camada	Nº de neurônios na 2ª camada	Função de ativação	Função de treinamento	MAE	RMSE	R
1	10	2000	2	25	5	tansig	traingda	11,343	0,273	0,658
2	10	1500	2	30	5	logsig	traingda	13,717	0,097	0,882
3	10	2500	2	10	10	tansig	traingda	13,674	0,195	0,903
4	10	2500	2	10	10	tansig	traingda	12,082	0,082	0,918
5	10	2000	2	25	5	tansig	trainlm	8,324	0,118	0,963
6	10	1000	2	30	5	tansig	trainlm	8,812	0,062	0,954
7	10	2000	2	25	5	tansig	trainlm	8,876	0,062	0,953
8	10	2000	2	25	5	tansig	traingda	12,610	0,173	0,916

FONTE: o autor (2018).

Para acompanhar o desempenho da RNA-MLP (FIGURA 20) foi realizado um teste de evolução do erro com base na quantidade de épocas utilizadas para o melhor modelo encontrado (teste 5). Ao contrário do observado no trabalho de Oliveira et al (2007), a evolução dos erros não apresentou um padrão crescente ou decrescente com o aumento das épocas. O coeficiente de correlação e o RMSE apresentaram padrões similares de evolução. Os menores coeficientes de correlação foram 0,9206 e 0,9205 para 1200 e 1500 épocas, respectivamente, enquanto que os maiores RMSE foram iguais à 0,174 cm para as mesmas épocas. As melhores correlações, iguais à 0,9624 e 0,9630, foram para 1300 e 2000 épocas, respectivamente. A evolução do coeficiente de correlação entre as épocas pode ser observada na FIGURA 20a. Na FIGURA 20b pode-se observar a evolução dos erros (*MAE* e *RMSE*). O *MAE* não apresentou padrão similar aos demais parâmetros, mas obteve seus menores valores nas arquiteturas com 800 e 1700 épocas iguais à 8,032 cm e 8,21 cm, respectivamente.

Apesar da pouca diferença de erro entre as épocas, procurou-se conciliar, na escolha da melhor RNA, os menores erros e o maior coeficiente de correlação entre os dados previstos e observados.

FIGURA 20 – GRÁFICO DE EVOLUÇÃO DOS ERROS (a) E DO COEFICIENTE DE CORRELAÇÃO (R) (b), DURANTE O TREINAMENTO DA RNA-MLP DO TESTE 5.



FONTE: O autor (2018).


Em outros trabalhos similares, a função de treinamento de Levenberg-Marquardt apresentou resultados bastante satisfatórios (SHIRI et al, 2011; MEENA; AGRAWAL, 2015), por esse motivo, decidiu-se realizar os testes com os dados do NCEP também com essa função. O teste resultou no desempenho mais satisfatório obtido neste trabalho, utilizando os dados do NCEP com uma série horária para o período de 1 ano (teste 5 - 10_2000_2_25_5_tansig_trainlm). Sertel, Cigizoglu e Sanli (2008), com uma configuração de rede bastante similar à utilizada no teste 5, obtiveram resultados inferiores ao obtido no presente trabalho. O melhor modelo proposto pelos autores obteve uma correlação de 0,71 entre os valores previstos e observados, e um RMSE igual a 7,1 cm. Como apresentado na tabela 11, o teste 5 mostrou um RMSE igual a 0,118 cm e um coeficiente de correlação igual a 0,963, um

aumento de 0,25 do obtido por Sertel, Cigizoglu e Sanli (2008). O resultado também supera o obtido por Filippo et al. (2012) em 0,05 (0,9128 - 0,963) para a mesma região de estudo (Cananéia, São Paulo).

Considerando a arquitetura da RNA-MLP, o resultado obtido através do teste 5 (10_2000_2_25_5_tansig_trainlm) também pode ser comparado ao obtido por Imani, You e Kou (2014) que utilizaram RNA-MLP com duas camadas ocultas. No trabalho citado, os melhores resultados apresentaram coeficiente de correlação igual a 0,93 e RMSE próximo de 4 cm (3,9 e 4,2 cm).

A FIGURA 21 apresenta uma comparação entre os resultados previstos pela RNA-MLP no teste 5 (10_2000_2_25_5_tansig_trainlm) e os resultados observados, com enfoque no período de uma semana (168h).

FIGURA 21 - COMPARAÇÃO ENTRE OS VALORES PREVISTOS E OBSERVADOS PARA O PERÍODO DE 168H, COM OS DADOS DO NCEP (TESTE 5 - 10_2000_2_25_5_tansig_trainlm).




FONTE: O autor (2018).

Os resultados das previsões foram analisados com base no resíduo entre os valores preditos e observados. A média dos resíduos para o teste 5 (10_2000_2_25_5_tansig_trainlm) foi de $-0,159$ cm, a mediana igual à $-0,376$ cm e o desvio padrão $\pm 11,033$ cm. Na FIGURA 22 podem ser conferidas essas estatísticas, acompanhada do histograma com a distribuição dos resíduos. Também são apresentadas nas figuras 23 e 24 os mesmos parâmetros para os testes 6 e 7, respectivamente (ver TABELA 11). Para o teste 6 (10_1000_2_30_5_tansig_trainlm) a média dos resíduos foi igual à $0,143$ cm, a mediana $-0,775$ e o desvio padrão $\pm 13,7$ cm. Já para o teste 7 (10_1000_2_25_5_tansig_trainlm) a média foi igual à $-0,076$ cm, a mediana $-0,925$ cm e o desvio padrão $\pm 13,6$ cm. Nos três testes as médias e as medianas não coincidiram


apesar da proximidade, o que indica uma não normalidade na distribuição dos resíduos. Essa distribuição pode ser conferida junto aos gráficos de resíduo para cada teste (FIGURA 22, 23 e 24).

FIGURA 22 – GRÁFICO DOS RESÍDUOS (DIFERENÇA ENTRE O OBSERVADO E O PREVISTO) DA PREVISÃO GERADA PELA ARQUITETURA DA RNA-MLP UTILIZADA NO TESTE 5. ACOMPANHAM O GRÁFICO A MÉDIA, MEDIANA E DESVIO PADRÃO DOS RESÍDUOS E DISTRIBUIÇÃO DOS MESMOS NO HISTOGRAMA À DIREITA.




FONTE: O autor (2018).

FIGURA 23 – GRÁFICO DOS RESÍDUOS (DIFERENÇA ENTRE O OBSERVADO E O PREVISTO) DA PREVISÃO GERADA PELA ARQUITETURA DA RNA-MLP UTILIZADA NO TESTE 6. ACOMPANHAM O GRÁFICO A MÉDIA, MEDIANA E DESVIO PADRÃO DOS RESÍDUOS E DISTRIBUIÇÃO DOS MESMOS NO HISTOGRAMA À DIREITA.



FONTE: O autor (2018).

FIGURA 24 – GRÁFICO DOS RESÍDUOS (DIFERENÇA ENTRE O OBSERVADO E O PREVISTO) DA PREVISÃO GERADA PELA ARQUITETURA DA RNA-MLP UTILIZADA NO TESTE 7. ACOMPANHAM O GRÁFICO A MÉDIA, MEDIANA E DESVIO PADRÃO DOS RESÍDUOS E DISTRIBUIÇÃO DOS MESMOS NO HISTOGRAMA À DIREITA.




FONTE: O autor (2018).

Observou-se nos testes 6 e 7, com resíduo indicados nas figuras 23 e 24, uma certa modulação a cada 4 ou 5 meses. Acredita-se que seja devido à partição dos dados em 10 folders, e que a mesma não estaria ocorrendo aleatoriamente devido à entrada dos dias julianos como uma variável. Decidiu-se testar as mesmas arquiteturas de RNA-MLP sem os dias julianos como uma entrada. Com a retirada dos mesmos o coeficiente de correlação caiu de 0,954 para

0,9384 no teste 6 e de 0,953 para 0,9379 no teste 7. Nos novos testes a modulação dos dados não ficou evidente nos resíduos (ver figuras 25 e 26).


A inserção dos dias julianos como uma entrada na RNA-MLP pode auxiliar na identificação de eventos cíclicos e sazonais. Apesar de não ser comum em trabalhos para previsão do nível do mar, essa variável é mais frequentemente utilizada em trabalhos de sensoriamento remoto que envolvam RNAs (AHER; ADINARAYANA; GORANTIWAR, 2011; LUIZ, 2014).

FIGURA 25 – GRÁFICO DOS RESÍDUOS (DIFERENÇA ENTRE O OBSERVADO E O PREVISTO) DA PREVISÃO GERADA PELA MESMA ARQUITETURA DA RNA-MLP UTILIZADA NO TESTE 6, ENTRETANTO SEM OS DIAS JULIANOS COMO DADOS DE ENTRADA. ACOMPANHAM O GRÁFICO A MÉDIA, MEDIANA E DESVIO PADRÃO DOS RESÍDUOS E DISTRIBUIÇÃO DOS MESMOS NO HISTOGRAMA À DIREITA.



FONTE: O autor (2018).

FIGURA 26 – GRÁFICO DOS RESÍDUOS (DIFERENÇA ENTRE O OBSERVADO E O PREVISTO) DA PREVISÃO GERADA PELA MESMA ARQUITETURA DA RNA-MLP UTILIZADA NO TESTE 7, ENTRETANTO SEM OS DIAS JULIANOS COMO DADOS DE ENTRADA. ACOMPANHAM O GRÁFICO A MÉDIA, MEDIANA E DESVIO PADRÃO DOS RESÍDUOS E DISTRIBUIÇÃO DOS MESMOS NO HISTOGRAMA À DIREITA.




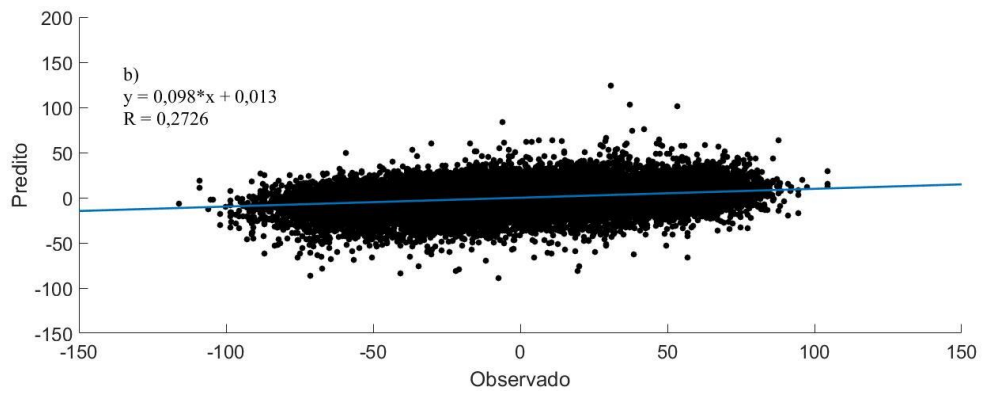

FONTE: O autor (2018).


Com a obtenção dessas melhores RNA-MLP para os testes 6 e 7, aplicou-se a elas os dados com intervalos de tempo maiores, já que à princípio elas teriam reagido melhor à uma menor quantidade de dados. O teste 5, mesmo com os bons resultados, quando submetido aos dados com maior intervalo de tempo, apresentou queda de até 80% na correlação entre os dados observados e previstos (o gráfico pode ser consultado no APÊNDICE III, FIGURA 5).

A FIGURA 27 apresenta a correlação entre os valores preditos e observados através do gráfico de dispersão para cada intervalo de tempo (1h, 6h, 12h, 24h e 48h). O ajuste dos dados foi melhor para o intervalo horário (1h) e, em nenhum dos demais intervalos, a correlação foi maior de 0,5. Essa queda pode ser explicada pela redução dos dados, mas também pela possibilidade de maiores intervalos de tempo mascararem pequenas variabilidades que interferem na previsão.

Em outros trabalhos também é comum observar uma queda dos coeficientes de correlação entre os valores preditos e observados usando séries de dados com maior intervalo de tempo (MAKARYNSKYY et al., 2004; OLIVEIRA et al., 2007; SHIRI et al., 2011), entretanto em nenhum dos citados essa queda foi tão significativa quanto a obtida no presente trabalho. Como a variação do coeficiente de correlação não seguiu nenhum padrão (redução e/ou aumento conforme aumento e/ou redução dos intervalos de tempo), não se pode afirmar o motivo do mal desempenho da RNA-MLP nesses resultados.

FIGURA 27 – GRÁFICOS DE DISPERSÃO ENTRE OS VALORES PREDITOS E OBSERVADOS PARA OS INTERVALOS DE a) 1H, b) 6H, c) 12H, d) 24H e d) 48H PARA TESTE 6.

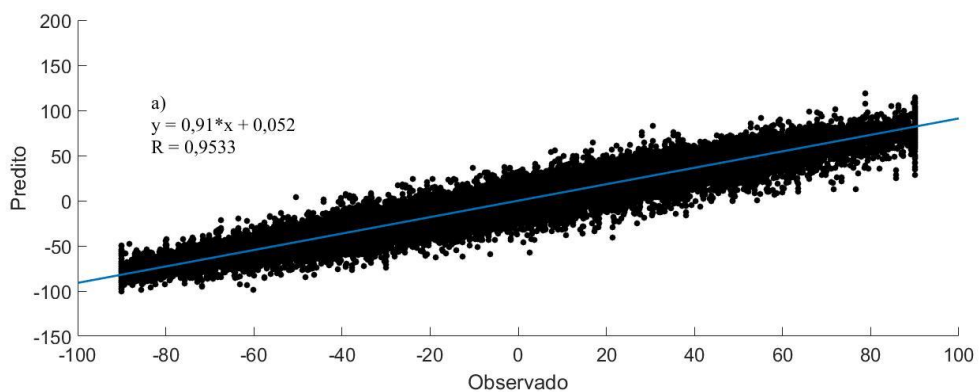


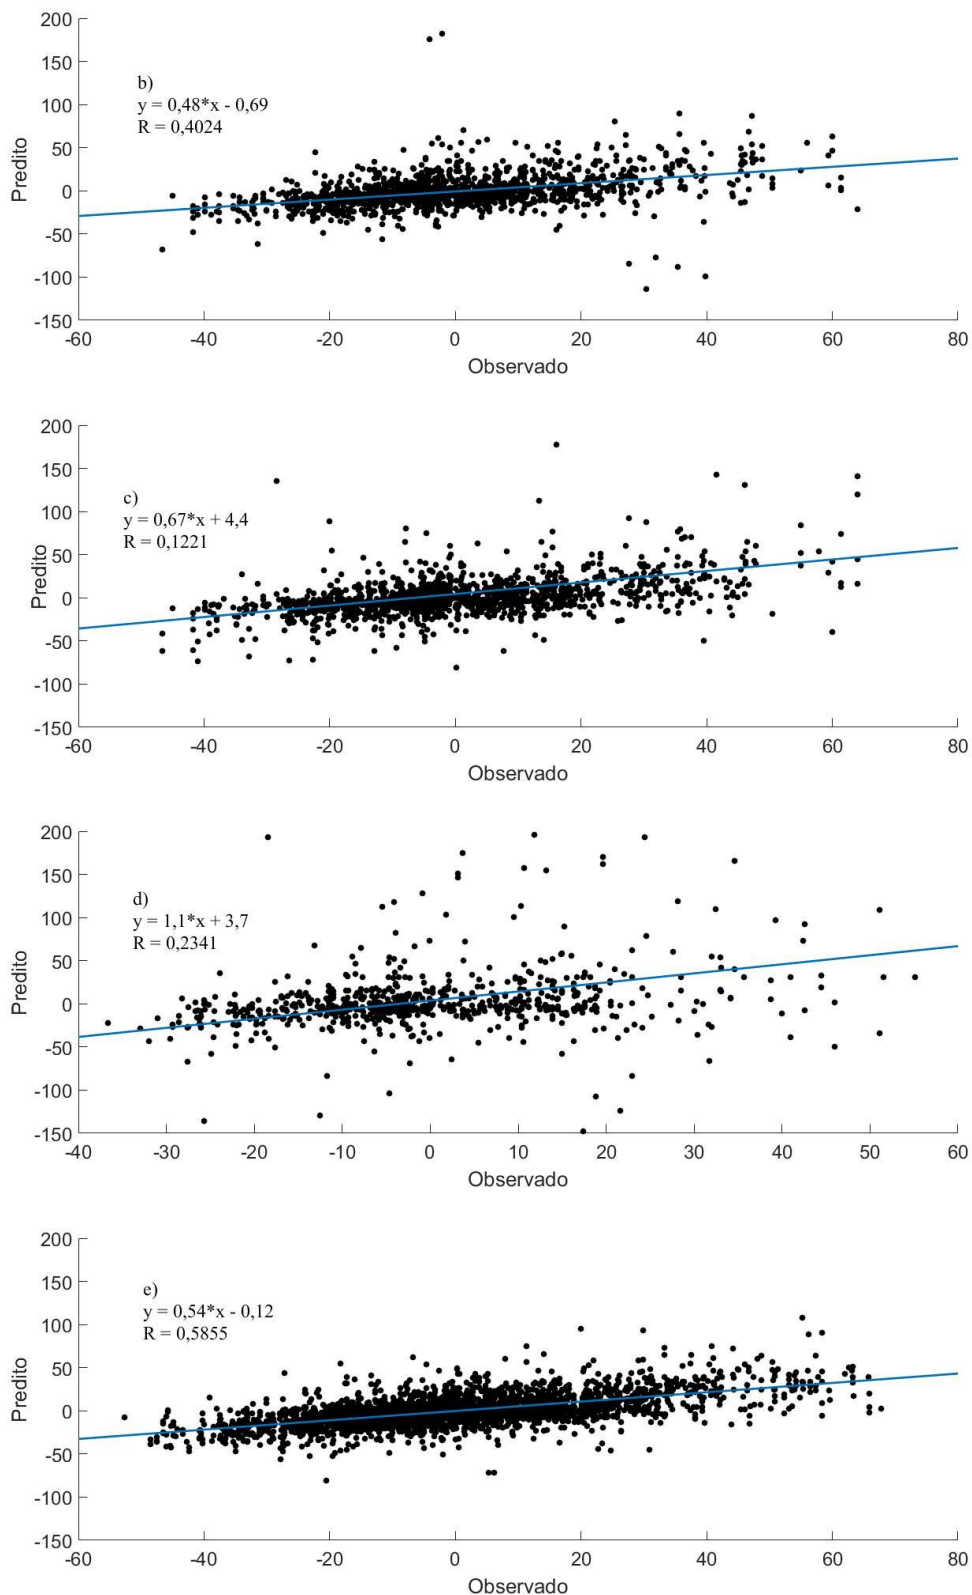


FONTE: O autor (2018).

O mesmo caso se repete para o teste 7. Na FIGURA 28, os mesmos gráficos e respectivos coeficientes de correlação podem ser observados. Na FIGURA 28 os limites dos valores observados ficaram bem definidos entre -90 cm e 90 cm, por conta da retirada de valores extremos, acima desse intervalo para realizar o teste em questão. A retirada desses extremos não auxiliou na melhora da previsão horária e não há indícios de interferência também nos demais intervalos de tempo.

FIGURA 28 – GRÁFICOS DE DISPERSÃO ENTRE OS VALORES PREDITOS E OBSERVADOS PARA OS INTERVALOS DE a) 1H, b) 6H, c) 12H, d) 24H e d) 48H PARA TESTE 7.






FONTE: O autor (2018).

De todos os intervalos considerados, sendo alguns testes realizados com até 72h (resultados não apresentados), a RNA-MLP lidou melhor com o intervalo de 1h para as estimativas. Apesar de o objetivo inicial contemplar todos os mesmos testes para todos os

intervalos de tempo (1h, 6h, 12h, 24h e 48h), o mesmo não se realizou por conta do esforço computacional e do tempo necessário para se rodarem 58320 modelos. Como visto nos resultados preliminares (5.2), as melhores arquiteturas para o intervalo horário não coincidiram com as melhores para o intervalo diário (24h) e, portanto, é possível que as melhores arquiteturas para os intervalos de 6, 12 e 48h também diferenciem entre si.

A melhor previsão obtida através das simulações da RNA-MLP (teste 5 - 10_2000_2_25_5_tansig_trainlm) apresentou uma melhora de 9,3% no coeficiente de correlação em relação a previsão por meio da análise harmônica do PACMARE (FIGURA 29). Outros trabalhos usando uma metodologia similar com a RNA-MLP também apontaram melhoras na previsão. You e Seo (2009) obtiveram uma melhora de 8% na previsão em relação à análise harmônica e Filippo et al. (2012) apontou uma redução de 14% da margem de erro na previsão obtida pela RNA para a mesma região de estudo (Cananéia).


FIGURA 29 – COMPARAÇÃO ENTRE O NÍVEL MÉDIO PREVISTO PELO MÉTODO DE ANÁLISE HARMÔNICA E PELA RNA-MLP DO TESTE 5 (10_2000_2_25_5_tansig_trainlm).



FONTE: O autor (2018).

Em relação à melhora no tempo, no geral a previsão pelo método harmônico (maré astronômica) e pela RNA-MLP não apresentaram defasagem em relação ao observado. Na FIGURA 30 estão indicados 3 pontos em que as previsões da maré astronômica indicaram uma defasagem equivalente à - 3h do observado e da previsão pela RNA-MLP.

FIGURA 30 – COMPARAÇÃO ENTRE O NÍVEL MÉDIO PREVISTO PELO MÉTODO DE ANÁLISE HARMÔNICA (MARÉ ASTRONÔMICA), EM PRETO, O NÍVEL PREVISTO PELA RNA-MLP DO TESTE 5 (10_2000_2_25_5_tansig_trainlm), EM AMARELO, E O NÍVEL MÉDIO OBSERVADO, EM AZUL. OS RETÂNGULOS INDICAM PONTOS ONDE A PREVISÃO DA MARÉ METEOROLÓGICA APRESENTA DEFASAGEM DA PREVISÃO DA RNA-MLP E DO REGISTRO OBSERVADO.



FONTE: O autor (2018).

Como uma metodologia de tentativa e erro, outros experimentos foram realizados ao longo do trabalho, mas apenas alguns modelos foram selecionados para análise e discussão. Alguns gráficos provenientes desses experimentos podem ser conferidos no APÊNDICE III. Essa metodologia é, também, o diferencial do presente trabalho, onde mais de 23 mil arquiteturas de RNA-MLP foram testadas, outros trabalhos similares utilizaram 32 (FILIPPO et al., 2012) e 1000 (VALERIO, 2016) arquiteturas. Os resultados aqui apresentados e discutidos reafirmam a importância do acréscimo das variáveis meteorológicas para o sucesso das previsões do nível do mar. O uso da RNA-MLP para previsão do nível do mar também se mostrou satisfatório para a região de Cananéia assim como já apontado por outros trabalhos (OLIVEIRA et al., 2007; FILIPPO et al., 2012).

6 CONCLUSÃO

O presente trabalho teve como objetivo avaliar a efetividade da RNA-MLP para previsão das flutuações do nível do mar em Cananéia, São Paulo, através de uma metodologia exaustiva de tentativa e erro para encontrar a melhor arquitetura de rede e método de treinamento. No geral, as RNA-MLP testadas apresentaram um desempenho satisfatório e os resultados obtidos foram sendo aperfeiçoados ao longo do desenvolvimento do trabalho.

Uma das vantagens pelas quais as RNAs são conhecidas é a sua capacidade de aprendizagem mesmo com poucos dados para treinamento. Observou-se que para esse trabalho, apesar do melhor resultado ter surgido de um treinamento com apenas um ano de observações (8760 dados), a RNA-MLP também lidou muito bem com uma série temporal maior (4 anos).

O melhor modelo testado nesse trabalho apresentou uma melhora de 9,3 % na previsão do nível do mar em relação à previsão da maré astronômica obtida pelo PACMARE. Filippo et al. (2012) com um modelo de RNA-MLP similar obteve uma melhora de 14% em relação à previsão pelo método harmônico para mesma região, no período de fevereiro a dezembro de 1982. A correlação entre os dados previstos e observados no trabalho citado foi de 0,91, enquanto no presente trabalho a melhor previsão obteve correlação de 0,96.

Esses resultados são bons indicadores para em trabalhos futuros aperfeiçoar essa RNA-MLP com enfoque nas previsões futuras da maré meteorológica. Outra sugestão para trabalhos futuros é realização de uma análise aprofundada da sensibilidade da RNA-MLP aos conjuntos de dados de entradas, que foi abordado brevemente no presente trabalho.

Outra consideração importante foi a melhora observada ao utilizar os dados do NCEP. Oliveira et al. (2007) já haviam constatado a melhora da previsão com dados da mesma fonte, em comparação aos dados de uma estação na superfície, mas também devemos considerar no presente trabalho a proximidade maior da fonte de dados do NCEP (16 km), quando comparada aos dados da estação em Pontal do Sul (75 km).

Fica evidente no contexto de desenvolvimento deste trabalho, a escassez e/ou dificuldade no acesso de dados meteoceanográficos na costa brasileira e, em alguns casos, como a qualidade dos mesmos pode reduzir as oportunidades de pesquisa e desenvolvimento tecnológico nas ciências do mar. Com as certas adaptações, para cada região de estudo, a RNA-MLP também pode vir a ser uma alternativa, nesses casos, para preenchimento de lacunas em séries temporais.

Como próximos passos do presente estudo esperamos utilizar a mesma RNA-MLP para previsões futuras das flutuações do nível do mar em Cananéia. Além disso, ampliar a área de estudo para analisar os efeitos remotos da ação do vento e das variações de pressão na geração da maré meteorológica na região. Com isso pretendemos mapear quais influências são mais significativas para o complexo estuarino lagunar de Cananéia e refinar as previsões utilizando as RNA-MLP.

REFERÊNCIAS

AHER, P. D.; ADINARAYANA, J.; GORANTIWAR, S. D. Remote sensing and artificial neural network in spatial assessment of fair temperature in a semi-arid watershed.

International Journal of Earth Sciences and Engineering, v. 4, n. 6, p. 351-354, 2011.

AUGUSTO, E. **Ministério do Meio Ambiente**. Brasília, 2018. Disponível em:

<<http://www.mma.gov.br/informma/item/14686-noticia-acom-2018-03-2912.html>>. Acesso em: 3 set. 2018.

BARRETO, J. M. Introdução as Redes Neurais Artificiais. In: **V Escola Regional de Informática. Sociedade Brasileira de Computação**, 2002, Regional Sul: Santa Maria, Florianópolis, Maringá: UFSC – Departamento de Informática e Estatística, 2002. 57 f.

BECKER, S. Unsupervised Learning Procedures for Neural Network. **The International Journal Of Neural Systems**, v. 1 & 2, p. 17-33, 1991.

BERGAMO, A. L. **Características da hidrografia, circulação e transporte de sal: Barra de Cananéia, sul do mar de Cananéia e baía do Trapandé**. 2000. 254 f. Dissertação (Mestrado em Oceanografia Física) – Instituto Oceanográfico da Universidade de São Paulo, Universidade de São Paulo, São Paulo, 2000.

BILGILI, M.; SAHIN, B.; YASAR, A. Application of artificial neural networks for the wind speed prediction of target station using reference stations data. **Renewable Energ**, Elsevier Science Ltd, v. 32, n. 14, p. 2350-2360, 2007.

BONETTI FILHO, J.; MIRANDA, L. B. de. Estimativa da descarga de água doce no sistema estuarino-lagunar de Cananéia-Iguape. **Revista Brasileira de Oceanografia**, São Paulo, v. 45, n. 1 & 2, p. 89-94, 1997.

BROWN, J.; COLLING, A.; PARK, D.; PHILLIPS, J.; ROTHERY, D.; WRIGHT, J. The Action of Wind on Surface Waters. In: _____. **Ocean Circulation**. Pergamon Press in association with The Open University, 1989. p. 33-37.

CAMARGO, R. de; HARARI, J. Marés. In: CASTELLO, J. P.; KRUG, L. C. **Introdução às Ciências do Mar**. Pelotas: Editora Textos, 2015. p. 226-255.

COMISIÓN ECONÓMICA PARA AMÉRICA LATINA Y EL CARIBE (CEPAL). **The effects of climate change in the coastal areas of Latin America and the Caribbean: Impacts**. Santiago, Chile: 2015. Disponível em: <<https://repositorio.cepal.org/handle/11362/37955>>. Acesso em: 4 set. 2018.

COELHO, A. de L. **Método de previsão de maré oceânica, utilizando análise harmônica em séries de 18,69 anos**. 2016. 114 f. Dissertação (Mestrado em Engenharia Civil - Recursos Hídricos, Energéticos e Ambientais) - Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Universidade Estadual de Campinas, Campinas, São Paulo, 2016.

DEDECKER, A. P.; GOETHALS, P. L. M.; PAUW, N. de. Comparison of artificial neural network (ann) model development methods for prediction of macroinvertebrate communities in the Zwalm River Basin in Flanders, Belgium. **The Scientific World Journal**, v. 2, p. 96-104, 2002.

DEO, M. C. Artificial neural networks in coastal and ocean engineering. **Indian Journal of Geo-Marine Science**, v. 39, n. 4, p. 589-596, 2010.

FILIPPO, A.; TORRES JÚNIOR, A. R.; KJERFVE, B.; MONAT, A. Application of Artificial Neural Network (ANN) to improve forecasting of sea level. **Ocean & Coastal Management**, v. 55, p. 101-110, 2012.

FOREMAN, M. G. G.; CHERNIAWSKY, J. Y.; BALLANTYNE, V. A. Versatile Harmonic Tidal Analysis: Improvements and Applications. **Journal of Atmospheric and Oceanic Technology**, v. 26, p. 806-817, 2009.

FORTES, C. J. E. M.; REIS, M. T.; POSEIRO, P.; CAPITÃO, R.; SANTOS, J. A.; PINHEIRO, L. P.; RODRIGUES, A.; SABINO, A.; RODRIGUES, M. C.; RAPOSEIRO, P.; FERREIRA, J. C.; SILVA, C.; SIMÕES, A.; AZEVEDO, E. B. O projeto HIDRALERTA. Sistema de previsão e alerta de inundações em zonas costeiras e portuárias. In: Jornadas Portuguesas de Engenharia Costeira e Portuária, 8ª, 2013, Lisboa. *Proceeding*. Disponível em: <https://www.researchgate.net/publication/272025958_Sistema_de_Previsao_e_Alerta_de_Inundacoes_em_Zonas_Costeiras_e_Portuarias_-_O_Projeto_Hidralerta>. Acesso em: 20 set. 2018.

FRANCO, A. dos S. **Marés: Fundamentos, Análise e Previsão**. 2. ed. Niterói, RJ: D.H.N, 2009.

FRANCO, A. dos S.; ROCK, N. J. The Fast Fourier Transform and its application to tidal oscillations. **Boletim do Instituto Oceanográfico**, São Paulo, v. 20, n. 1, p. 145-199, 1971.

GHORBANI, M. A.; KHATIBI, R.; AYTEK, A.; MAKARYNSKYY, O.; SHIRI, J. Sea water level forecasting using genetic programming and comparing the performance with Artificial Neural Networks. **Computers & Geosciences**, v. 36, p. 620-627, 2010.

GUIMARÃES, M. R. F.; MARONE, E. **Oceanografia física com ênfase em ambientes estuarinos**. 1996.

GODIN, G. **The analysis of tides**. Toronto, Canadá: University of Toronto, 1972.

GODIN, G. **Tides**. Ottawa, Ontario: Anadyomene Edition, 1988.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989-993, 1994.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M.; DE JESÚS, O. **Neural network design**. 2. ed. Disponível em: < <http://hagan.okstate.edu/NNDesign.pdf> >. Acesso em: 20 set. 2018.

HAYKIN, S. **Neural Network: A comprehensive foundation**. 2. ed. Ontário, Canadá: bookman. 2001.

HERTZ, J.; KROGH, A.; PALMER, R. G. **Introduction to the theory of neural computation**. 1. ed. Taylor & Francis Group LLC, 1991.

IMANI, M.; YOU, R. J.; KUO, C. Y. Caspian sea level prediction using satellite altimetry by artificial neural networks. **International Journal of Environmental Science and Technology**, Springer, v. 11, p. 1035-1042, 2014.

INSTITUTO HIDROGRAFICO DA MARINHA DE PORTUGAL. Glossário Científico: Marés. Disponível em: < <http://www.hidrografico.pt/glossario-cientifico-mares.php> >. Acesso em: 07 jul. 2018.

Informações sobre Marés. **Centro de Hidrografia da Marinha do Brasil**. Disponível em: < <https://www.marinha.mil.br/chm/chm/pagina-basica/informacoes-sobre-mares> >. Acesso em: 07 jul. 2018.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59-69, 1982.

LEE, T. L. Back-propagation neural network for long-term tidal predictions. **Ocean Engineering**, v. 31, p. 225-238, 2004.

LEE, T. L.; JENG, D. S. Application of artificial neural networks in tide-forecasting. **Ocean Engineering**, v. 29, p. 1003-1022, 2002.

LEE, T. L.; TSAI, C. P.; JENG, D. S.; SHIEH, R. J. Neural network for the prediction and supplement of tidal record in Taichung Harbor, Taiwan. **Advances in Engineering Software**, v. 33, p. 329-338, 2002.

LEK, S.; GUÉGAN, J. F. Artificial neural networks as a tool in ecological modelling, an introduction. **Ecological Modelling**, Elsevier Science Ltd, v. 120, p. 65-73, 1999.

LOESCH, C.; SARI, S. T. **Redes Neurais Artificiais: Fundamentos e Modelos**. Blumenau, SC: Ed. Da FURB, 1996.

LUIZ, E. W. **Desenvolvimento de metodologias para estimativas de cobertura de nuvens**. 74 f. Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

MAKARYNSKY, O.; MAKARYNSKA, D.; KUHN, M.; FEATHERSTONE, W. E. Predicting sea level variations with artificial neural networks at Hillarys Boat Harbour, Western Australia. **Estuarine, Coastal and Shelf Science**, Elsevier Science Ltd, v. 61, p. 351-360, 2004.

MALUF, J. C. C. **Estudo dos metais traço (zinco, cádmio e chumbo) em duas regiões do complexo estuarino – lagunar de Cananéia – Iguape (SP) sob diferentes pressões antrópicas**. 126 f. Dissertação (Mestrado em Ciências, área de Oceanografia Química e Geológica) – Instituto Oceanográfico, Universidade de São Paulo, São Paulo, 2009. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/21/21133/tde-02082011-111452/en.php>>. Acesso em: 07 de jun. 2017.

MARONE, E. **FILTERS**. 1989.

MARONE, E. **Processamento e análise de dados de maré: discurso dos métodos: uma aplicação aos registros maregráficos e meteorológicos do litoral Sul-Leste de Buenos Aires**,

Argentina (38°03' S a 39°23' S). 232 f. Tese (Doutorado em Ciências) – Instituto Oceanográfico da Universidade de São Paulo, Universidade de São Paulo, São Paulo, 1991.

MARONE, E.; MESQUITA, A. R. de; On non-linear analysis of tidal observations. **Continental Shelf Research**, Elsevier Science Ltd, v. 14, n. 6, p. 577-588, 1994.

MARONE, E. “Radiational tides” as non linear effects: bispectral interpretation. **Continental Shelf Research**, Elsevier Science Ltd, v. 16, n. 8, p. 1117-1126, 1996.

MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431-441, 1963.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MEENA, B. L.; AGRAWAL, J. D. Tidal level forecasting using ANN. **Procedia Engineering**, Elsevier Science Ltd, v. 116, p. 607-614, 2015.

MELO FILHO, E. **Maré meteorológica na costa brasileira**. 2016. 328 f. Tese (Professor Titular de Engenharia Civil Costeira e Portuária) – Escola de Engenharia, Universidade Federal do Rio Grande, Porto Alegre, 2017.

MIYAO, S. Y.; HARARI, J. Estudo preliminar da maré e das correntes de maré da região estuarina de Cananéia (25°S-48°W). **Boletim do Instituto Oceanográfico**, São Paulo, v. 37, n. 2, p. 107-123, 1989.

MIYAO, S. Y.; NISHIHARA, J.; SARTI, C. C. Características físicas e químicas do sistema estuarino-lagunar de Cananéia-Iguape. **Boletim do Instituto Oceanográfico**, São Paulo, v. 34, p. 23-36, 1986.

MUNK, W. H.; CARTWRIGHT, D. E. Tidal spectroscopy and prediction. **Royal Society**, London, v. 259, n. 1105, p. 533-581, 1966.

NUNES, A. L. **Determinação das marés meteorológicas na região da Baía do Espírito Santo e sua influência na drenagem de águas continentais**. 2007. 131 f. Dissertação (Mestrado em Engenharia Ambiental, Gestão em Águas Interiores e Costeiras) - Universidade Federal do Espírito Santo, Vitória, 2007.

OLIVEIRA, M. M. F. de. **Redes Neurais Artificiais na predição de maré meteorológica em Paranaguá - PR**. 2004. 149 f. Tese (Mestrado em Ciências em Engenharia Civil) - COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2004.

OLIVEIRA, M. M. F. de; EBECKEN, N. F. F.; SANTOS, I. de A.; NEVES, C. F.; CALOBA, L. P.; OLIVEIRA, J. L. F. de. Modelagem da maré meteorológica utilizando redes neurais artificiais: Uma aplicação para a Baía de Paranaguá - PR, parte 2: dados meteorológicos de reanálise do NCEP/NCAR. **Revista Brasileira de Meteorologia**, v. 22, n. 1, p. 53-62, 2007.

OLIVEIRA, M. M. F. de; EBECKEN, N. F. F.; OLIVEIRA, J. L. F. de; SANTOS, I. de A. Neural Network Model to Predict a Storm Surge. **Journal of applied Meteorology and Climatology**, v. 48, p. 143-155, 2009.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU). **ONU declara Década da Oceanografia em 2021-2030**. 2017. Disponível em: < <https://nacoesunidas.org/onu-declara-decada-da-oceanografia-em-2021-2030/>>. Acesso em: 3 set. 2018.

PASINI, A. Neural network modeling in climate change studies. In: Haupt S.E., Pasini A., Marzban C. (eds). **Artificial Intelligence Methods in the Environmental Sciences**. Springer, Dordrecht, 2009. p. 235-254.

PATIL, K.; DEO, M. C. Prediction of daily sea surface temperature using eficiente neural networks. **Ocean Dynamics**, Springer-Verlag Berlin Heidelberg, não p., 2017.

PLATAFORMA AGENDA 2030. Disponível em: < <http://www.agenda2030.org.br/ods/14/>>. Acesso em: 3 set. 2018.

POSEIRO, P.; FORTES, C. J. E. M.; REIS, M. T.; REIS, R. Utilização conjunta de ferramentas neuronais e SIG na avaliação da inundação do Porto e Baía da Praia da Vitória. **Territorium**, v. 25, n. 1, p. 39-46, 2018.

PUGH, D. T. **Tides, Surges and Mean Sea-Level**. Swindon, UK: John Wiley & Sons Ltd, 1996.

PUGH, D. T.; WOODWORTH, P. **Sea-Level Science: Understanding Tides, Surges, Tsunamis and Mean Sea-Level Changes**. Cambridge, UK: Cambridge University Press, 2014.

RAUBER, T. W. **Redes Neurais Artificiais**. Disponível em: <
https://www.researchgate.net/publication/228686464_Redex_neurais_artificiais >. Acesso em:
 30 jul. 2018.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 387-408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagation errors. **Nature**, v. 323, n. 9, p. 533-536, 1986.

SAHA, S.; MOORTHY, S.; PAN, H.; WU, X.; WANG, J.; NADIGA, S.; TRIPP, P.; KISTLER, R.; WOOLLEN, J.; BEHRINGER, D.; LIU, H.; STOKES, D.; GRUMBINE, R.; GAYNO, G.; WANG, J.; HOU, Y.; CHUANG, H.; JUANG, H. H.; SELA, J.; IREDELL, M.; TREADON, R.; KLEIST, D.; VAN DELST, P.; KEYSER, D.; DERBER, J.; EK, M.; MENG, J.; WEI, H.; YANG, R.; LORD, S.; VAN DEN DOOL, H.; KUMAR, A.; WANG, W.; LONG, C.; CHELLIAH, M.; XUE, Y.; HUANG, B.; SCHEMM, J.; EBISUZAKI, W.; LIN, R.; XIE, P.; CHEN, M.; ZHOU, S.; HIGGINS, W.; ZOU, C.; LIU, Q.; CHEN, Y.; HAN, Y.; CUCURULL, L.; REYNOLDS, R.W.; RUTLEDGE, G.; GOLDBERG, M. The NCEP Climate Forecast System Reanalysis. **Bulletin American Meteorological Society**, v. 91, p. 1015-1058, 2010.

SANTOS, M. C. de O.; ROSSO, S. Social organization of marine Tucuxi dolphins, *Sotalia guianensis*, in the Cananeia Estuary of southeastern Brazil. **Journal of Mammalogy**, v. 89, n. 2, p. 347-355, 2008.

SCHAEFFER- NOVELLI, Y.; MESQUITA, H. de. S. L. The Cananéia Lagoon Estuarine System, São Paulo, Brazil. **Estuaries**, v.13, 2, p. 193-203, 1990.

SERTEL, E.; CIGIZOGLU, H. K.; SANLI, D. U. Estimating daily mean sea level heights using artificial neural networks. **Journal of Coastal Research**, Florida, v. 24, n. 3, p. 727-734, 2008.

SHIRI, J.; MAKARYNSKY, O.; KISI, O.; DIERICKX, W.; FARD, A. F. Prediction of short-term operational water levels using an adaptive neuro-fuzzy inference system. **Journal of Waterway, Port, Coastal, and Ocean Engineering**, v. 137, p. 344-354, 2011.

SILVA, L. N. de C. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais**. 1998. 248 f. Tese (Mestrado em Engenharia de Computação e Automação Industrial) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, São Paulo, 1998.

TABACH, E. E.; LANCELOT, L.; SHAHROUR, I.; NAJJAR, Y. Use of artificial neural network simulation metamodelling to assess groundwater contamination in a road project. **Mathematical and Computer Modelling**, Elsevier Science Ltd, v. 45, p. 766-776, 2007.

TALLEY, L. D.; PICKARD, G. L.; EMERY, W. J.; SWIFT, J. H. **Descriptive Physical Oceanography: An Introduction**. 6. ed. Kidlington, UK: Elsevier, 2011.

THOMPSON, R. O. R. Y. Low-Pass Filters to suppress inertial and Tidal Frequencies. **Journal of Physical Oceanography**, Australia, v.13, p. 1077-1083, June 1983.

THURMAN, H. V. **Introductory Oceanography**. 7. ed. New York: Macmillan Publication Company, 1994.

Tides and Currents Glossary. **Tides & Currents - NOAA**. Disponível em: <<https://tidesandcurrents.noaa.gov/glossary.html>>. Acesso em: 07 jul. 2018.

TSAI, C. P.; LEE, T. L. Back-Propagation Neural Network in Tidal-Level Forecasting. **Journal of Waterway, Port, Coastal, and Ocean Engineering**, v. 125, p. 195-202, 1999.

TUNDISI, J. G.; MATSUMURA-TUNDISI, T. The lagoon region and estuary ecosystem of Cananéia, Brazil. In: SEELIGER, U.; KJERFVE, B. (Eds.). **Coastal Marine Ecosystems of Latin America**. New York: Springer, 2001. p. 119-130.

VALERIO, L. de M. **Previsão do nível do mar por redes neurais artificiais: um estudo de caso para o litoral norte de São Paulo**. 2016. 117 f. Dissertação (Mestrado em Meio Ambiente e Recursos Hídricos) – Programa de Pós-graduação em Meio Ambiente e Recursos Hídricos, Universidade Federal de Itajubá (UNIFEI), Itajubá, 2016.

ZUBEN, F. J. V. **Redes Neurais Aplicadas ao Controle de Máquina de Indução**. 1993. 244 f. Tese (Mestrado em Engenharia de Computação e Automação Industrial) – Faculdade de Engenharia Elétrica e de Computação (FEEC), Universidade Estadual de Campinas (Unicamp), São Paulo, 1993.

YOU, S. H.; SEO, JW. Storm surge prediction using an artificial neural network model and cluster analysis. **Natural Hazards**. Springer, v. 51, p. 97-114, 2009.

YU, H.; WILAMOWSKI, B. M. **Levenberg-Marquardt Training**. Industrial Eletronics Handbook, v. 5, p.1-16, 2011.

**APÊNDICE I - COMPONENTES HARMÔNICAS DE CANANÉIA E SUAS
RESPECTIVAS AMPLITUDES E FASES.**

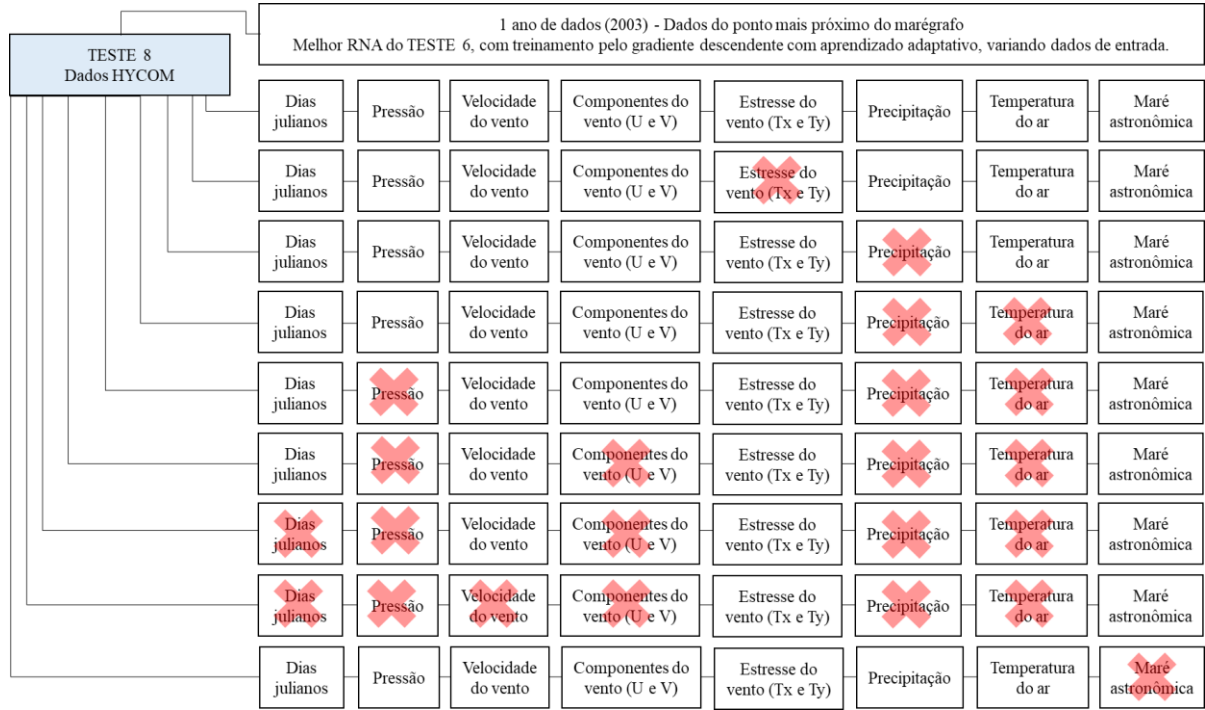
TABELA 1 – COMPONENTES HARMÔNICAS DE CANANÉIA E SUAS RESPECTIVAS AMPLITUDES E FASES.

Símbolo	Amplitude H (cm)	Fase local (graus)	Símbolo	Amplitude H (cm)	Fase local (graus)
Q1	3,06	49,11	N4	0,83	62,43
r1	0,43	51,94	3MS4	0,52	55,23
O1	9,84	73,14	MN4	3,11	105,25
P1	2,55	134,93	M(NU)4	0,67	117,97
S1	1,61	108,75	M4	5,9	156,29
K1	6,37	133,23	2MKT4	0,19	212
2N2	2,01	130,15	3MN4	0,7	14,65
m2	2,29	132,44	MS4	3,06	266,16
N2	5,47	140,03	MK4	1	263,96
NU2	0,63	152,96	SL4	0,24	309,05
OP2	0,73	3,5	MNO5	0,19	332,26
MTS2	1,01	28,61	2MO5	0,3	21,69
M2	36,7	69,71	MNK5	0,3	350,44
MKS2	0,68	138,09	2MK5	0,25	95,3
l2	0,54	10,3	MSM5	0,31	329,81
L2	1,4	69,43	2NM6	0,1	186,95
S2	23,8	73,17	M6	0,22	163,77
R2	0,65	113,54	MSN6	0,1	301,49
K2	7,51	64,02	4MN6	0,1	327,42
KJ2	0,83	248,04	2MS6	0,53	175,04
2SM2	1,35	244,55	2MK6	0,17	171,61
NO3	0,97	324,4	2SM6	0,28	202,65
MO3	3,38	358,56	MSK6	0,19	200,01
2MP3	0,73	22,87	MSNK7	0,2	158,3
SQ3	0,46	64,87	2M2N8	0,15	12,66
M3	7,01	200,38	3MN8	0,17	79,11
SO3	1,95	118,38	M8	0,13	151,29
MK3	2,6	87,59	2MSN8	0,13	194,46
2MQ3	0,45	232,51	3MS8	0,21	269,06
SP3	1,31	270,97	2M2S8	0,1	334,32
S3	1,78	274,34	4MS10	0,16	188
SK3	1,83	264,81	Sa	2,84	55,72

FONTE: O autor (2018).

APÊNDICE II – ANÁLISE PRELIMINAR DE SENSIBILIDADE

QUADRO 1 – ESQUEMATIZAÇÃO DAS DIFERENTES COMBINAÇÕES DE VARIÁVEIS DE ENTRADA NO TESTE 8, UTILIZANDO A ARQUITETURA DE RNA-MLP 10_2000_2_25_5_tansig_traingda.



FONTE: O autor (2018).


TABELA 1 – ANÁLISE DOS RESULTADOS DO TESTE 8, COM DIFERENTES COMBINAÇÕES DE ENTRADA

TESTE	MAE	RMSE	R
8.1	12,610	0,173	0,916
8.2	12,596	0,171	0,918
8.3	12,497	0,171	0,917
8.4	12,696	0,174	0,918
8.5	13,054	0,178	0,911
8.6	13,611	0,189	0,901
8.7	13,528	0,186	0,905
8.8	12,596	0,171	0,918
8.9	31,022	0,405	0,326

FONTE: O autor (2018).


APÊNDICE III – GRÁFICOS

FIGURA 1 - COMPARAÇÃO ENTRE OS VALORES PREVISTOS E OBSERVADOS PARA O PIOR MODELO OBTIDO (10_1000_1_5_logsig_trainlm, ver tabela 8).




FONTE: O autor (2018).

FIGURA 2 – COMPARAÇÃO ENTRE OS VALORES PREVISTOS E OBSERVADOS PARA O PERÍODO DE UM ANO, COM OS DADOS DO NCEP (TESTE 5).




FONTE: O autor (2018).

FIGURA 3 – COMPARAÇÃO ENTRE OS VALORES PREVISTOS E OBSERVADOS PARA O PERÍODO DE QUATRO ANOS, COM OS DADOS DO NCEP (TESTE 6).




FONTE: O autor (2018).

FIGURA 4 – COMPARAÇÃO ENTRE OS VALORES PREVISTOS E OBSERVADOS PARA O PERÍODO DE QUATRO ANOS, COM OS DADOS DO NCEP, SEM OS VALORES EXTREMOS DO NÍVEL DO MAR (TESTE 7).




FONTE: O autor (2018).

FIGURA 5 – GRÁFICO DE DISPERSÃO DOS RESULTADOS OBTIDOS ATRAVÉS DO TESTE 5 (10_2000_2_25_tansig_trainlm) USANDO DADOS DO NCEP, COM INTERVALO DE 24H.




FONTE: O autor (2018).

FIGURA 6 – GRÁFICO DE DISPERSÃO DOS RESULTADOS OBTIDOS ATRAVÉS DE UM DOS TESTES INICIAIS (RESULTADOS PRELIMINARES – 7_500_2_20_15_purelin_trainlm) USANDO DADOS DA ESTAÇÃO, COM INTERVALO DE 1H.




FONTE: O autor (2018).

FIGURA 7 – GRÁFICO DE DISPERSÃO DOS RESULTADOS OBTIDOS ATRAVÉS DE UM DOS TESTES INICIAIS (RESULTADOS PRELIMINARES – 7_1000_2_20_5_tansig_traingd) USANDO DADOS DA ESTAÇÃO, COM INTERVALO DE 24H.



FONTE: O autor (2018).

FIGURA 8 – GRÁFICO DE COMPARAÇÃO ENTRE OS VALORES PREDITOS ATRAVÉS DO MÉTODO HARMÔNICO DE FRANCO E ROCK (1971) E ATRAVÉS DA MELHOR RNA-MLP OBTIDA NESTE TRABALHO (TESTE 5 - 10_2000_2_25_tansig_trainlm).



FONTE: O autor (2018).