

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO
AMBIENTE E RECURSOS HÍDRICOS - MEMARH

Previsão do Nível do Mar por Redes Neurais Artificiais:
Um Estudo de Caso para o Litoral Norte de São Paulo

Liziara de MelloValerio

Itajubá, Agosto de 2016.

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO
AMBIENTE E RECURSOS HÍDRICOS - MEMARH

Liziara de Mello Valerio

Previsão do Nível do Mar por Redes Neurais Artificiais:
Um Estudo de Caso para o Litoral Norte de São Paulo

Dissertação submetida ao Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos como parte dos requisitos para obtenção do Título de Mestre em Meio Ambiente e Recursos Hídricos.

Área de Concentração: Meio Ambiente e Recursos Hídricos

Orientador: Prof. Marcos Eduardo Cordeiro Bernardes, Dr.

Agosto de 2016

Itajubá

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO
AMBIENTE E RECURSOS HÍDRICOS - MEMARH

Liziara de Mello Valerio

Previsão do Nível do Mar por Redes Neurais Artificiais:
Um Estudo de Caso para o Litoral Norte de São Paulo

Dissertação aprovada por banca examinadora em 03 de agosto de 2016, conferindo ao autor o título de *Mestre em Meio Ambiente e Recursos Hídricos*.

Banca Examinadora:

Prof. Dr. Marcos Eduardo Cordeiro Bernardes
(Orientador)

Prof. Dr. Wilson Cabral de Sousa Júnior

Prof. Dr. Alessandro Luvizon Bérghamo

Prof. Dr. Arcilan Trevenzoli Assireu

Agosto de 2016

Itajubá

DEDICATÓRIA

Aos meus pais, Wagner Valerio e Maristela Aparecida de Mello Valerio
e ao meu irmão Victor Eduardo de Mello Valerio.

AGRADECIMENTOS

Agradeço, primeiramente, ao professor Dr. Marcos Eduardo Cordeiro Bernardes, amigo e orientador, por confiar em meu trabalho e aceitar me orientar e estar sempre disponível para auxiliar nas adversidades encontradas ao longo desse tempo.

Ao meu irmão e grande colaborador Me. Victor Eduardo de Mello Valerio, por sua enorme contribuição; sem você alguns obstáculos provavelmente não teriam sido superados com tamanho êxito.

Ao colega Me. Paulo Victor Lisboa pela paciência em sanar diversas dúvidas que surgiram na primeira etapa deste trabalho, além das grandiosas contribuições realizadas na mesma etapa. Ao colega mestrando Diego Felipe dos Santos e à colega doutoranda Mabel Calim Costa, pela grande ajuda na obtenção de alguns dados.

Aos demais colegas que tanto colaboraram com igual paciência e solicitude: Carolina Bernardes, Ana Carolina de Sá e Rafael Melo.

Ao professor Dr. Wilson Cabral de Sousa Júnior e demais colegas do projeto RedeLitoral, o qual me possibilitou valioso crescimento como profissional e como pessoa e apoio financeiro através da Capes.

À Universidade Estadual de São Paulo, através do Instituto Oceanográfico da USP, por fornecer os dados solicitados, registrados pelo marégrafo de Ubatuba – São Paulo.

À Universidade Federal de Itajubá e ao programa de mestrado em Meio Ambiente e Recursos Hídricos - MEMARH, na pessoa do coordenador, professor Dr. Marcelo de Paula Corrêa e aos demais professores do referido programa.

À minha amada família, especialmente aos meus pais, irmão, tio Júnior, tia Gleicilene, e primos: Miguel e sua esposa Marcela, Felipe e Bárbara, que ao longo de minha jornada estudantil e profissional deu suporte necessário para tornar esse trabalho possível, apoiou minhas escolhas, vibrou com minhas vitórias e esteve ao meu lado nos momentos difíceis. Sem vocês meus horizontes seriam infinitamente mais restritos.

Gostaria de agradecer aos, não menos importantes, amigos de toda a vida. Alguns recentes e outros de longa data, todos representados pelas pessoas dos meus grandes amigos: Kelly Junqueira (minha irmã de coração) e Danilo Rosário e dos amigos da FATEC-SP, Bruna Ferreira e Karen Monteiro. Com um ombro amigo ou um impulso de positividade vocês foram essenciais nesse processo.

Finalmente, agradeço a Capes pelo apoio financeiro.

EPÍGRAFE

“Os sonhos são as manifestações não falsificadas da atividade criativa inconsciente”.

Carl Jung

RESUMO

Prever os níveis do mar, a partir da descarga fluvial, das variáveis atmosféricas e da maré astronômica é importante para regiões costeiras onde a hidrodinâmica é caracterizada por interações extremamente complexas. O presente estudo avalia o desempenho das Redes Neurais Artificiais (RNAs) para a previsão do nível do mar no litoral norte de São Paulo. O desenvolvimento desta pesquisa decorreu em quatro etapas: levantamento teórico da utilização de RNAs para previsão de nível do mar; levantamento dos dados utilizados no modelo, visando gerar séries temporais com dados locais e aplicar o estudo à região supracitada; implementação da rede neural; análise de desempenho das redes geradas pelo *software* Statistica 13 juntamente à análise de sensibilidade das forçantes físicas mais relevantes. O período de tempo analisado compreende o período de janeiro de 2013 a julho de 2013. Foram testadas 1.000 redes neurais artificiais e escolhidas as 5 com melhor desempenho. Uma rede *ensemble* foi gerada, através da combinação destas 5 redes selecionadas que corresponderam ao tipo perceptrons de múltiplas camadas (MLP). Os resultados obtidos demonstraram que as RNAs foram eficazes no processo de predição do nível do mar para 6 horas, inclusive sob condições de valores extremos. A partir das análises de sensibilidade, verificou-se que todas as forçantes analisadas possuem influência nas oscilações do nível do mar.

Palavras-chave: RNA; MLP; análise de sensibilidade; Statistica 13; previsão de curto prazo.

ABSTRACT

Predicting sea level based on river discharge, atmospheric variables and astronomical tides is important for coastal regions where the hydrodynamic is extremely complex. This study evaluates the performance of Artificial Neural Networks (ANN) to predict the sea level at the north coast of the São Paulo, Brazil. This research was developed based on four steps: theoretical survey using ANNs to forecast sea level; survey data used in the model in order to generate time series with local data and apply the study to the aforementioned region; neural network implementation; performance analysis of networks generated by the *software* “Statistica 13” along with the sensitivity analysis of the forcing processes which are relevant in the process. The study period was from January 2013 to July 2013 where 1000 artificial neural networks were tested. Based on the model output, the 5 best ones were assessed. Then, an ensemble network was generated by combining these 5 selected networks through a multi-layered perceptrons (MLP) type. The results showed that the ANNs were effective at predicting sea levels with 6 hours in advance, including under extreme values conditions. Based on the sensitivity analysis, it is shown that all the forcing analyzed have influence on the oscillations of the sea level.

Keywords: ANN; MLP; sensitivity analysis; Statistica13; short-termforecast.

LISTA DE FIGURAS

Figura 1 - Delimitação do mar territorial, da ZEE e da PC do Brasil	24
Figura 2 - Distribuição das forças de tração horizontal na superfície da Terra.	27
Figura 3 - Oscilação do ciclo de maré de sizígia e quadratura associado às fases de lua cheia, lua nova, quarto crescente e quarto minguante e as respectivas influências nas variações de amplitudes no nível do mar.	30
Figura 4 - Espiral de Ekman e o transporte resultante do processo.....	32
Figura 5 - Dinâmica de Ekman em regiões oceânicas no hemisfério sul	33
Figura 6 - Escalas espacial e temporal de fenômenos atmosféricos e oceanográficos	36
Figura 7 - Escala espaço-temporal das perturbações do nível do mar geradas pela influência: a) do vento local; b) de oscilações de alta frequência (frequências < 3 ciclos por dia - cpd); e c) de oscilações de baixa frequência (frequências > 3 cpd).	37
Figura 8 - Gráficos de dispersão de dados simulados e dados observados, usando (a) RNAs (ANN), (b) modelo hidrodinâmico 2D vertical, e (c) o modelo hidrodinâmico 3D, para a Ponte Taipei (fase de treinamento).	42
Figura 9 - Gráficos de dispersão de dados simulados e dados observados, usando (a)RNAs, (b) modelo hidrodinâmico 2D verticais, e (c) o modelo hidrodinâmico 3D, para a Ponte Taipei (fase de teste).	43
Figura 10 - Representação em diagrama em blocos do sistema nervoso	45
Figura 11 - Representação esquemática de um neurônio biológico	46
Figura 12 - Modelo não-linear de um neurônio.....	47
Figura 13 - Perceptron de múltiplas camadas.....	52
Figura 14 – Esquema de propagação do sinal de entrada e a retropropagação do erro.....	57
Figura 15 – Pontos de mínimo global (1) e mínimo local (2).	59
Figura 16 - Estratégias de treinamento de redes neurais do tipo MLP.....	60
Figura 17 - Rede de camada única.....	62
Figura 18 - Esquema representativo de conexão <i>Feedforward</i>	63

Figura 19 - Localização da área de estudo	64
Figura 20 - Gráfico de evolução populacional em mil habitantes de Caraguatatuba entre 1990 a 2010	65
Figura 21 - Gráfico de evolução populacional em mil habitantes de Ubatuba entre 1990 a 2010	66
Figura 22 - Gráfico de evolução populacional em mil habitantes de São Sebastião entre 1990 a 2010	66
Figura 23 - Gráfico de evolução populacional em mil habitantes de Ilhabela entre 1990 a 2010	67
Figura 24 - Unidade de Gerenciamento de Recursos Hídricos do Litoral Norte – UGRHI-3, que compreende os municípios de Ubatuba, Caraguatatuba, São Sebastião e Ilhabela. Escala 1:1.000.000	68
Figura 25 - Drenagem na Bacia do Rio Juqueriquerê, Caraguatatuba, SP	69
Figura 26 - Zona de Convergência do Atlântico Sul em 26 de janeiro de 2004. Imagem Infravermelho Goes-12	71
Figura 27 - Maré prevista (em metros) para o Porto de São Sebastião – São Paulo para os dias 05 e 06 de janeiro de 2015	72
Figura 28 - Fases de uma implementação de modelagem	74
Figura 29 - Fluxograma do trabalho	75
Figura 30 - Localização das coletas de dados	79
Figura 31 – Série de nível do mar registrada pelo marégrafo IOUSP e série de nível do mar gerada após aplicação do filtro de Lanczos	84
Figura 32- Série temporal de dados de maré astronômica gerada após interpolação dos dados de maré astronômica disponibilizados pela Marinha do Brasil.	87
Figura 33 - Estatística descritiva dos dados de maré astronômica (valores em metros)	91
Figura 34 - Estatística descritiva dos dados de nível do mar (valores em metros)	92
Figura 35 - Estatística descritiva dos dados da componente u do vento (valores em m/s)	93
Figura 36 - Estatística descritiva dos dados da componente v do vento (valores em m/s)	94

Figura 37 - Estatística descritiva dos dados de Pressão Atmosférica de Superfície (valores em hPa).....	95
Figura 38 - Estatística descritiva dos dados de vazão (valores em m ³ /s)	96
Figura 39 - Arquitetura da RNA.....	97
Figura 40 - Gráfico <i>boxplot</i> . Comparação entre o nível do mar observado e o nível do mar estimado pela rede <i>ensemble</i>	103
Figura 41- Gráfico de linha da rede <i>ensemble</i> ; comportamento do nível do mar observado e comportamento do nível do mar estimado (dados em metros).....	104
Figura 42 - Gráfico de dispersão da rede <i>ensemble</i>	105

LISTA DE TABELAS

Tabela 1 - Fontes de obtenção dos dados	78
Tabela 2 - Descritivo do ponto de coleta de dados de cota do Rio Camburu.....	79
Tabela 3 - Constantes harmônicas das constituintes de marés de Cananéia e de Ubatuba calculadas a partir de registros horários do ano de 1978 e utilizadas para a filtragem numérica da série de nível do mar do litoral norte de São Paulo. As colunas apresentam: primeira coluna – nome da constituinte; segunda – a frequência angular; na terceira – a frequência angular em hertz, na quarta – a amplitude; na quinta – o desvio padrão da amplitude; na sexta – o ângulo de fase; na sétima – o ângulo de fase em relação ao meridiano de <i>Greenwich</i> (Inglaterra) e, na oitava – o desvio padrão do ângulo de fase da componente. Todas as constantes foram determinadas com intervalos de intervalos de confiança estatística de 95%	83
Tabela 4- Comparativo entre as vazões médias mensais (utilizadas no presente trabalho) e vazões levantadas nas campanhas hidrológicas do estudo de Boulomytis <i>et al.</i> (2014). A linha cinza mais escura corresponde à campanha realizada no período chuvoso no sudeste. O dado em vermelho corresponde a um valor anômalo.....	85
Tabela 5–Composição dos neurônios por camadas das redes neurais artificiais e ciclos para obtenção de convergência.....	98
Tabela 6–Valores de erro por processo de modelagem - SOS (fornecido pelo modelo) e valores de erro RMSE (calculado), em metros.....	99
Tabela 7 - Correlação entre nível do mar previsto e observado	99
Tabela 8 - Funções de ativação nas camadas ocultas e nas camadas de saída das redes selecionadas.....	100
Tabela 9 - Composição dos neurônios por camadas das redes neurais artificiais e ciclos para obtenção de convergência, utilizando-se a série de nível do mar bruto (sem aplicação do processo de filtragem numérica).....	100
Tabela 10 - Valores de erro por processo de modelagem - SOS (fornecido pelo modelo) e valores de erro RMSE (calculado), em metros, utilizando-se a série de nível do mar bruto (sem aplicação do processo de filtragem numérica).....	101

Tabela 11 - Correlação entre nível do mar previsto e observado, utilizando-se a série de nível do mar bruto (sem aplicação do processo de filtragem numérica)	102
Tabela 12 – Valores de erro RMSE (calculado), em metros, nas fases de treinamento, teste e validação, para a rede <i>ensemble</i>	103
Tabela 13 - Análise de sensibilidade das forçantes utilizadas no processo de modelagem. As forçantes definidas como “-6” e “-12” correspondem as forçantes defasadas em 6 e 12 horas, respectivamente, em relação à precisão do nível do mar para 6 horas	106

LISTA DE ABREVIATURAS E SIGLAS

- ANA – Agência Nacional das Águas
- ANN – *Artificial Neural Networks*
- ANS – *Automated Network Search*
- BFGS – Método de Broyden-Fletcher-Goldfarb-Shanno
- BM – Baixa-mar (ou maré baixa)
- CHM – Centro de Hidrografia da Marinha
- CNUDM – Convenção das Nações Unidas sobre o Direito do Mar
- DAEE – Departamento de Águas e Energia Elétrica
- DHN – Diretoria de Hidrografia e Navegação
- IBGE – Instituto Brasileiro de Geografia e Estatística
- INPH – Instituto de Pesquisas Hidroviárias
- IOUSP – Instituto Oceanográfico da Universidade de São Paulo
- IQA – Índice de qualidade da água
- LMS – Mínimo quadrado médio
- MA – Maré astronômica
- MK3 – Componente terdiurna de águas rasas
- MLP – *Multilayer perceptron* (Perceptron de múltipla camada)
- NM – Nível do mar
- NMM – Nível médio do mar
- PC – Plataforma continental
- PCG – Plataforma continental geográfica
- PCJ – Plataforma continental jurídica
- PM – Preamar (ou maré alta)
- PS – Pressão atmosférica em superfície
- Q – Vazão fluvial
- RBF – *Radial basis function* (rede de função de base radial)
- RMSE – *Root Mean Squared Error*
- RNA – Rede neural artificial
- SIGAM – Sistema Integrado de Gestão Ambiental
- SOS – *Sum of Squares* (Soma dos Quadrados dos Erros)
- UGRHI – Unidade de Gerenciamento de Recursos Hídricos

VLSI – *Very-large-scale-integration*

V_u – Componente zonal do vento

V_v – Componente meridional do vento

ZEE – Zona Econômica Exclusiva

SUMÁRIO

1 INTRODUÇÃO.....	18
1.1 Justificativa	19
1.2 Objetivos	20
2 REVISÃO DE LITERATURA	21
2.1 Zonas costeiras.....	21
2.2 Vazão fluvial.....	25
2.3 Marés	26
2.3.1 Marés Astronômicas	26
2.3.1.1 Período da maré	28
2.3.1.2 Amplitude de maré - maré de sizígia e maré de quadratura	28
2.3.1.3 Tipos de Marés Astronômicas	29
2.3.2 Marés Meteorológicas.....	31
2.4 Nível do Mar	34
2.4.1 Efeitos do vento na variação do nível médio do mar.....	38
2.4.2 Efeitos da pressão atmosférica no nível médio do mar	38
2.5 Fundamentos das Redes Neurais Artificiais	39
2.5.1 Características gerais de uma RNA	44
2.5.2 Cérebro humano, o neurônio biológico e o modelo de um neurônio artificial.....	45
2.5.3 Tipos de função de ativação.....	49
2.5.4 Perceptrons de camada única	52
2.5.5 Perceptrons de múltiplas camadas (MLP)	52
2.5.6 Rede de Função de Base Radial (RBF)	54
2.5.7 Processo de aprendizagem.....	55
2.5.8 Análise de sensibilidade.....	61

2.5.9 Tipos de arquitetura de redes neurais	62
3 DESCRIÇÃO DA ÁREA DE ESTUDO	64
4 MODELO PROPOSTO	73
4.1 Método de Pesquisa	73
4.1.1 Definição metodológica do trabalho.....	73
4.1.2 Fluxograma	75
4.2 Amostragem.....	76
4.2.1 Definição das forçantes influentes no nível do mar.....	76
4.2.2 Dados Utilizados.....	77
4.2.3 Pré-processamento dos dados	81
4.2.3.1 Filtragem numérica da série de nível do mar.....	81
4.2.3.2 Geração dos dados de vazão	85
4.2.3.3 Interpolação dos dados de maré astronômica	86
4.3 Programação das RNAs	87
4.3.1 Definição da rede neural	88
4.3.2 Processo de aprendizagem	88
5 DISCUSSÃO DE RESULTADOS.....	90
5.1 Estatística descritiva dos dados.....	90
5.2 Modelo de previsão estimado	97
5.2.1 Arquitetura de redes neurais artificiais selecionadas	98
5.2.1.1 Modelo gerado utilizando-se a série de nível do mar bruto.....	100
5.2.2 Aglutinação das arquiteturas de rede e desempenho de previsão	102
5.3 Análise de sensibilidade.....	106
6 CONSIDERAÇÕES FINAIS	109
6.1 Conclusões	109
6.2 Sugestões para trabalhos futuros.....	111
7 REFERÊNCIAS	112

1 INTRODUÇÃO

Grande parte da população mundial vive numa estreita faixa adjacente à costa. Grande parte da ocupação e desenvolvimento humano se deu a partir das margens de estuários, devido às condições geográficas favoráveis oferecendo águas abrigadas margeadas por extensas planícies costeiras (SCHETTINI, 2002). Contudo, devido ao contínuo e desordenado crescimento da população humana ao seu redor, cada vez mais os ambientes costeiros vêm sofrendo impactos advindos de diferentes tipos de atividades, tais como aterros hidráulicos, despejo de efluentes domésticos e industriais, retificação de canais com dragagens para implementação de atividades portuárias, entre outros (SCHETTINI, 2002). Além disso, a vulnerabilidade dessas regiões tem relação tanto com as atividades antrópicas quanto à imprevisibilidade de eventos climáticos extremos como chuvas intensas, vendavais e furacões, marés meteorológicas e grandes secas, que representam fenômenos com grande poder de destruição.

O Painel Intergovernamental das Mudanças Climáticas - IPCC (2001) define como mudança climática qualquer variação no clima ao longo do tempo, que tenha origem natural ou que seja resultado da atividade humana. Evidências observacionais de todos os continentes e da maioria dos oceanos mostram que muitos sistemas naturais estão sendo afetados pelas mudanças climáticas regionais, particularmente nos aumentos de temperatura. Para o final do século XXI, os modelos climáticos globais preveem um aumento no nível global do mar entre 0,18 m e 0,59 m, com uma elevada variabilidade regional (CHUST *et al.*, 2010 *apud* SANTOS *et al.*, 2012). Além da elevação do nível do mar, a maior frequência dos eventos climáticos extremos resulta na redução da estabilidade geográfica da linha costeira.

Por fim, a elevação das águas compromete a drenagem das cidades costeiras dificultando a dispersão dos efluentes urbanos e, como consequência, o aumento da poluição das águas. Outros processos hidrológicos dessas regiões poderão ser afetados, como por exemplo, o aumento do risco de inundação, a aceleração da erosão costeira, o deslocamento das zonas úmidas em direção aos continentes e o aumento das inundações associadas às tempestades; estas, por sua vez, poderão atingir as populações locais e os ecossistemas naturais, bem como provocar o avanço da cunha salina para o interior do território (SANTOS *et al.*, 2012).

É reconhecida e inegável a necessidade e urgência de criarem-se mecanismos que procurem harmonizar o desenvolvimento econômico e social com a preservação dos valores e recursos naturais das zonas costeiras.

1.1 Justificativa

A suscetibilidade e fragilidade às quais as regiões costeiras estão submetidas confirmam a necessidade de estudos que possibilitem o embasamento para tomada de decisões por parte dos órgãos responsáveis pelo gerenciamento ambiental dos referidos locais. Porém, a literatura para a região de estudo é escassa sendo encontrados alguns poucos estudos, tais como Boulomytis e Alves (2011), que realizaram uma análise multi-temporal da expansão urbana na bacia do rio Juqueriquerê; Arasaki *et al.* (2011) que estudaram os eventos extremos de inundação e erosão induzidos por mudanças climáticas no rio Juqueriquerê; Carvalho *et al.* (2013), que fazem uma comparação entre os índices de qualidade da água (IQA) dos estuários dos rios Itamambuca (Ubatuba) e Juqueriquerê; o estudo de Silva (2013) que trata de nutrientes no estuário do rio Juqueriquerê; Tschoke *et al.* (2013), que estabeleceram uma correlação do viés pelo modelo de transformação de potência das previsões de precipitações do modelo ETA/CPTEC para a referida bacia; Valentim *et al.* (2013) que analisaram as variações físicas de baixa frequência na zona costeira de Ubatuba; Sakai *et al.* (2013) que estabeleceram uma metodologia de avaliação de eventos extremos na planície costeira do litoral norte de São Paulo; o estudo de Vieira e Sousa Jr. (2013) que fizeram uma avaliação dos efeitos da ampliação da infraestrutura associada ao pré-sal sobre o consumo de água no município de Caraguatatuba/SP; entre outros.

Neste sentido, o presente estudo apresenta um modelo de previsão de curto prazo do nível do mar para o litoral norte paulista, através da abordagem de Redes Neurais Artificiais.

1.2 Objetivos

O presente estudo tem por objetivo contribuir para a compreensão da variação do nível do mar, em escala temporal de 6 horas, a partir de Redes Neurais Artificiais (RNAs), no litoral norte de São Paulo.

Objetivos específicos:

Implementar, testar e validar o uso de redes neurais artificiais na previsão do nível do mar na região de estudo;

Analisar a influência relativa de forçantes atmosféricas, oceanográficas e continentais sobre o nível do mar na região de estudo.

2 REVISÃO DE LITERATURA

A previsão de nível do mar em regiões costeiras, realizada através de redes neurais artificiais envolve alguns conceitos que serão definidos de forma sucinta neste capítulo; que se divide em cinco seções: zonas costeiras, vazão fluvial, marés, nível do mar e fundamentos de redes neurais artificiais.

2.1 Zonas costeiras

Não existe um sistema internacional rígido para a definição de zonas costeiras. Isso, entre outras razões, porque mesmo as características físicas da zona costeira são extremamente dinâmicas. A definição de zona costeira conforme o Plano Nacional de Gerenciamento Costeiro II – PNGCII – infere que é o espaço geográfico onde ocorre a interação entre ar, mar e terra, incluindo seus recursos ambientais, abrangendo as seguintes faixas:

- Faixa marítima – se estende mar afora, distando 12 milhas náuticas (pouco mais de 22 km) das Linhas de base estabelecidas de acordo com a Convenção das Nações Unidas sobre o Direito do Mar (CNUDM), compreendendo a totalidade do Mar Territorial;
- Faixa terrestre – que corresponde à faixa do continente formada pelos municípios que sofrem influência direta dos fenômenos ocorrentes na zona costeira.

Portanto, a zona costeira é influenciada por agentes oceânicos, atmosféricos e continentais. Algumas formas de interação entre oceano e atmosfera trazem consequências para o meio biótico e algumas atividades humanas, como por exemplo, vórtices da Corrente do Brasil influenciam localmente a geração e a propagação de ondas, bem como a qualidade das massas d'água na plataforma continental (NEVES e MUEHE, 2008). Correspondem a áreas sob significativo estresse ambiental em nível mundial e estão submetidas a forte pressão por intensas formas de uso do solo. Atualmente, as áreas costeiras abrigam 45% da população humana e 75% das megalópoles com mais de 10 milhões de habitantes (MAGALHÃES, 2012).

De acordo com o Ministério do Meio Ambiente, a zona costeira do Brasil se estende, na sua porção terrestre, por mais de 8.500 km e abrange 17 estados (mais de 400 municípios), do Norte equatorial ao Sul temperado do país. A Zona Marinha tem início na região costeira e compreende a plataforma continental marinha e a Zona Econômica Exclusiva – ZEE.

A Convenção das Nações Unidas sobre o Direito do Mar, assinada pelo Brasil em 10 de dezembro de 1982 e, posteriormente, ratificada em 22 de dezembro de 1988 – introduz e/ou consagra os conceitos de mar territorial, zona econômica exclusiva e plataforma continental, aplicáveis a espaços oceânicos próprios (SOUZA, 1999), tal como:

Mar territorial: Nos termos da CNUDM (PARTE I – artigos 2 a 5),

Todo Estado tem o direito de fixar a largura do seu mar territorial até um limite que não ultrapasse 12 milhas náuticas, medidas a partir de linhas de base determinadas de conformidade com a presente Convenção (1 mn = 1.852 metros). No mar territorial, a soberania do Estado estende-se ao espaço aéreo sobrejacente ao mar territorial, bem como ao leito e ao subsolo deste mar.

Segundo Souza (1999), o mar territorial possui 12 mn, com a vigência da Lei nº 8.617.

Zona Econômica Exclusiva: Nos termos da CNUDM (Parte V – artigos 55 a 57),

A zona econômica exclusiva é uma zona situada além do mar territorial e a este adjacente, sujeita ao regime jurídico específico estabelecido na presente Parte, segundo o qual os direitos e a jurisdição do Estado costeiro e os direitos e liberdades dos demais Estados são regidos pelas disposições pertinentes da presente Convenção. Na zona econômica exclusiva, o Estado costeiro tem direitos de soberania para fins de exploração e aproveitamento, conservação e gestão dos recursos naturais, vivos ou não vivos das águas sobrejacentes ao leito do mar, do leito do mar e seu subsolo, e no que se refere a outras atividades com vista à exploração e aproveitamento da zona para fins econômicos, como a produção de energia a partir da água, das correntes e dos ventos. A zona econômica exclusiva não se estenderá além de 200 milhas marítimas das linhas de base a partir das quais se mede a largura do mar territorial.

Conforme o Ministério do Meio Ambiente a ZEE brasileira compreende uma área de 3,5 milhões de quilômetros quadrados.

Plataforma continental – PC: Nos termos da CNUDM (Parte VI – artigos 76 e 77),

A plataforma continental de um Estado costeiro compreende o leito e o subsolo das áreas submarinas que se estendem além do seu mar

territorial, em toda a extensão do prolongamento natural do seu território terrestre, até ao bordo exterior da margem continental, ou até uma distância de 200 milhas marítimas das linhas de base a partir das quais se mede a largura do mar territorial, nos casos em que o bordo exterior da margem continental não atinja essa distância. A margem continental compreende o prolongamento submerso da massa terrestre do Estado costeiro e é constituída pelo leito e subsolo da plataforma continental, pelo talude e pela elevação continental. Não compreende nem os grandes fundos oceânicos, com as suas cristas oceânicas, nem o seu subsolo. Os pontos fixos que constituem a linha dos limites exteriores da plataforma continental no leito do mar, traçada de conformidade com as sub-álneas i) e ii) da alínea a) do parágrafo 4º, devem estar situadas a uma distância que não exceda 350 milhas marítimas da linha de base a partir da qual se mede a largura do mar territorial ou a uma distância que não exceda 100 milhas marítimas da isóbata de 2500 metros, que é uma linha que une profundidades de 2.500 metros. O Estado costeiro exerce direitos de soberania sobre a plataforma continental para efeitos de exploração e aproveitamento dos seus recursos naturais.

De acordo com Souza (1999) a plataforma continental jurídica – PCJ de um Estado costeiro pode englobar as feições fisiográficas conhecidas como plataforma, talude continental (escarpa do relevo submarino que mergulha do limite da PCG para os fundos ou abismos oceânicos – planície abissal) e elevação continentais (que corresponde à região do relevo submarino, relativamente plana e de pequena declividade que une o talude continental à planície abissal, que une o talude continental à planície abissal), e, em algumas circunstâncias, inclusive regiões da planície abissal.

A Figura 1 ilustra as regiões brasileiras de mar territorial, ZEE e PC.



Figura 1 - Delimitação do mar territorial, da ZEE e da PC do Brasil

Fonte: Adaptado de Ministério do Meio Ambiente

Segundo o Ministério do Meio Ambiente, o litoral brasileiro é composto por águas frias (sul e sudeste) e águas quentes (norte e nordeste). Assim, os sistemas ambientais costeiros no Brasil são extraordinariamente diversos, com uma grande variedade de ecossistemas que incluem manguezais (berçários de diversas espécies marinhas e de água

doce), recifes de corais (os mais diversos habitats marinhos do mundo), dunas, restingas, praias arenosas, costões rochosos, lagoas, estuários e marismas.

No que tange às mudanças climáticas, as zonas costeiras são suscetíveis aos seus efeitos nos diversos agentes ambientais dos três grandes sistemas anteriormente citados (ar, mar e terra). Com relação aos efeitos do aquecimento global, pode-se observar que esses afetam as zonas costeiras, com a elevação do nível médio do mar (e efeitos que incluem a diminuição da faixa de areia de praias, recuo da linha de costa, problemas de macrodrenagem em águas interiores e o aumento da intrusão salina em corpos d'água costeiros), aumento de extremos climáticos e alterações no clima de ventos e ondas, que atuam de forma sinérgica, ampliando os impactos no ambiente costeiro quando comparados aos efeitos isolados (SANTOS, 2012). Para Neves e Muehe (2008), o aquecimento de áreas costeiras traz consequências diversas para a circulação hidrodinâmica, bem como para a fauna e flora das águas mais rasas. Isto se faz particularmente mais grave por conta dos parâmetros de dimensionamento dos emissários submarinos de esgoto, com risco potencial do aumento da poluição aquática.

2.2 Vazão fluvial

Segundo Neves e Muehe (2008), alterações no regime hidrológico raramente são levadas em consideração em estudos na zona costeira, assim como ações de gerenciamento de recursos hídricos raramente incluem os trechos estuarinos em seu escopo. De acordo com Miranda *et al.* (2002), “estuários são ambientes de transição entre o continente e o oceano, onde rios encontram o mar, resultando na diluição mensurável da água salgada”. Em bacias hidrográficas com escalas geográficas menores, é possível quantificar e estabelecer relações de causa e efeito entre as intervenções continentais e as respostas da zona costeira (NEVES E MUEHE, 2008). Sklar e Browder (1998) afirmam que a água doce é um elemento essencial aos estuários e a forçante hidrodinâmica que mais afeta a estrutura e a função dos ambientes de transição da costa.

O aporte fluvial implica em consequências nas esferas físicas, químicas e biológicas, tais como circulação estuarina, formação do gradiente de salinidade, transporte de sedimentos, fornecimento de nutrientes, produção de pescados e, por exemplo, efeitos negativos como:

transporte de componentes tóxicos, poluentes e organismos patogênicos, vindos de bacias hidrográficas adjacentes (POWELL *et al.*, 2002).

Desta forma, a redução das vazões pode resultar em maior extensão da intrusão salina, em aumento do tempo de residência do estuário, em redução da carga de sedimentos e de material dissolvido e em potencial formação de zona de turbidez máxima. Caso contrário, com o aumento das vazões, pode haver elevação da estratificação da coluna d'água, deslocamento da zona estuarina em direção ao mar, aumento do aporte de nutrientes ao estuário e um domínio da circulação gravitacional na circulação residual (SKLAR e BROWDER, 1998 *apud* GENZ *et al.*, 2008).

De acordo com Genz *et al.* (2008), a obtenção de relações entre vazão, a penetração da cunha salina e a relação desta com os recursos estuarinos implica em avaliações temporais e espaciais, com grande esforço de coleta de dados, devido aos vários cenários possíveis de altura de maré e vazões fluviais. Estabelecer a dependência dos estuários e outros ambientes costeiros em relação às vazões fluviais, bem como propor mecanismos de regulação, implica em levar o gerenciamento dos recursos hídricos até o limite marinho da bacia hidrográfica.

2.3 Marés

Aos movimentos regulares de água a partir da ascensão vertical e queda do nível do mar, e os movimentos de vai e vem das correntes de água dá-se o nome de maré. A explicação científica de maré só foi possível após a formulação da Lei da Gravitação Universal em 1687, por Isaac Newton, que possibilitou o desenvolvimento da Teoria das Marés (OLIVEIRA, 2004).

2.3.1 Marés Astronômicas

As marés astronômicas são fenômenos ondulatórios do nível d'água, caracterizados pela previsibilidade, devido às forças gravitacionais causadas pela posição relativa entre Terra, Sol e Lua (CARTACHO, 2013). A força geradora de maré corresponde à diferença entre a força de atração exercida sobre um ponto e a força de atração dirigida ao centro da Terra ou pela força centrífuga associada ao movimento do sistema Terra-Astro em torno do

centro de massa deste sistema. Quando uma força geradora de maré, em um determinado ponto da superfície da Terra, é decomposta em vertical e horizontal (Figura 2), o segundo componente é responsável pelo movimento oscilatório das marés (força de tração) enquanto que o componente vertical produz pequenas alterações no peso de um corpo e pode, assim, ser desprezada (PUGH, 1987).




Figura 2 - Distribuição das forças de tração horizontal na superfície da Terra.

Fonte: Oliveira (2004)

A periodicidade, a intensidade e a amplitude das marés não são homogêneas em todos os pontos da superfície da Terra (OLIVEIRA, 2004).

A força geradora de maré lunar é muito maior que a solar, devido à menor distância desta com a Terra, pois a Lei da Gravitação Universal determina que a atração entre dois corpos varie de acordo com o produto de suas massas e com o inverso do quadrado da distância entre eles. No caso do sistema Terra-Lua-Sol, a influência da Lua será maior devido à menor distância da Terra, embora a massa do Sol seja milhões de vezes maior que a massa da Lua (MIGUENS, 1996). As marés são, portanto, movimentos oscilatórios que podem ser decompostos em movimentos harmônicos simples e expressos em equações matemáticas. Pode ser traduzida pela soma das componentes harmônicas e expressa pela seguinte equação (UAISSONE, 2004):

$$\eta(t) = \sum A_n \cos(\sigma_n t - g_n) \quad (1)$$

Onde:

A_n (m) – amplitude = velocidade angular (°/hora)

g_n – fase (°) = obtida através de argumentos astronômicos

Três características podem ser consideradas as principais da maré: período da maré, amplitude da maré (sizígia ou quadratura) e o tipo de maré.

2.3.1.1 Período da maré

Quando o movimento oscilatório da água do mar atinge sua maior cota, dá-se o nome de Preamar (PM) ou maré alta e quando este movimento atinge a menor cota, denomina-se Baixa-mar (BM) ou maré baixa. O período da maré corresponde ao tempo em que ocorrem duas preamares (baixa-mares) consecutivas. A Terra gira em torno de seu eixo, de Oeste para Leste e completa uma rotação completa com relação à Lua a cada aproximadamente 24 horas e 50 minutos que é o período conhecido como dia lunar. Ademais, como resultado da inclinação do eixo da Terra, as preamares e as baixa-mares sucessivas não são normalmente de níveis iguais (MIGUENS, 1996).

O intervalo lunitidal é o tempo decorrido entre a passagem meridiana da Lua e a preamar ou baixa-mar. Este intervalo varia devido à interrupção da propagação da onda de maré pelos continentes e pela resistência do fundo oceânico, à medida que a onda se propaga para águas pouco profundas e pode corresponder de minutos a horas. Este é importante na análise e previsão de marés e na determinação de correções para cada zona de marés (Manual de Hidrografia – *Internacional Hydrographic Organization*, 2005).

2.3.1.2 Amplitude de maré - maré de sizígia e maré de quadratura

As forças de atração da Lua e do Sol se somam duas vezes em cada intervalo de tempo entre duas conjunções ou oposições da Lua, cujo valor, em dias médios, é 29,531 dias. Durante o período de Lua Nova e o período de Lua Cheia acontecem as maiores variações entre preamares e baixa-mares consecutivas; a esse evento denomina-se maré de sizígia. Por ocasião das fases Quarto Crescente e Quarto Minguante da Lua, acontecem as menores variações entre preamares e baixa-mares consecutivas e são chamados de eventos de maré de quadratura. Em outras palavras, em marés de sizígia há uma maior variação do nível de água do que quando comparado à maré de quadratura. Consequentemente, durante marés de sizígia, intensificam-se as correntes de maré, assim como a capacidade de mistura em ambientes estuarinos causada por esse fenômeno.

A amplitude das marés (a diferença de nível entre a preamar e a baixa-mar) é um elemento modelador da linha de costa, em função das velocidades de correntes a ela associadas. Estas correntes de marés são significativas no transporte sedimentar costeiro

especialmente onde a variação da maré é expressiva. No Brasil, amplitudes superiores a 4 metros (macromarés) ocorrem no estado do Maranhão, em parte do Pará (ex: Salinópolis) e em alguns lugares no Amapá, como por exemplo Igarapé do Inferno, na Ilha de Maracá, na Barra Norte e no litoral sul do Cabo Norte (ex: Santana). Nestes locais as correntes de marés possuem maior capacidade de modificar a morfologia da linha de costa e da plataforma continental interna. O restante do litoral e alguns trechos do litoral da Bahia e Sergipe apresentam mesomarés com amplitudes entre 2 e 4 metros ou micromarés, com amplitudes inferiores a 2 metros (TESSLER e GOYA, 2005).

Outros termos são definidos em razão da diferença entre uma preamar e baixa-mar consecutivas, tais como:

- Maré enchente: processo de subida do nível do mar devido ao efeito das marés astronômicas.
- Maré vazante: processo de descida do nível do mar devido ao efeito das marés astronômicas.

2.3.1.3 Tipos de Marés Astronômicas

Pode-se definir tipo de maré como a forma característica de subida e descida da maré, tal como representado pela curva de maré. Apesar da curva de maré de qualquer local particular diferir em alguns aspectos da curva de maré de outro qualquer lugar, as curvas de maré podem ser agrupadas em três grandes classes ou tipos: semidiurno, diurno e misto (Manual de Hidrografia – *Internacional Hydrographic Organization*, 2005), conforme ilustrado na Figura 3.

Devido ao fato de 1 dia lunar ter aproximadamente 24 horas 50 minutos, em oposição ao dia solar de 24 horas, as marés não ocorrem todos os dias à mesma hora num mesmo local. Assim (MIGUENS, 1996):

- Maré semidiurna - apresenta duas PM e duas BM no período de 1 dia lunar, sendo o intervalo de tempo entre uma PM e a BM consecutiva de pouco mais de 6 horas. O padrão semidiurno, entretanto, vai variar em diversos locais da Terra, em virtude dos efeitos de massas terrestres, latitude do lugar, águas restritas, fricção (atrito), viscosidade do meio líquido e do efeito de Coriolis (uma força aparente que atua sobre

fluidos geofísicos em movimento na superfície terrestre, causada pela rotação da Terra);

- Marés diurnas - constituem um padrão no qual ocorrem apenas uma PM e uma BM a cada dia lunar. Geralmente os níveis de duas PM ou BM sucessivas não variam muito;
- Marés mistas - constituem um tipo de maré na qual as oscilações diurnas e semidiurnas são ambas importantes, sendo a maré caracterizada por grandes diferenças de altura entre duas PM ou duas BM consecutivas. Há, normalmente, 2 PM e 2 BM a cada dia, mas ocasionalmente a maré pode tornar-se diurna (MIGUENS, 1996). Ademais, em outros locais a maré apresenta sempre duas PM e duas BM diariamente, mas com desigualdades. Este tipo de maré é classificado como maré semidiurna com desigualdades diurnas, ou maré de desigualdades diurnas.

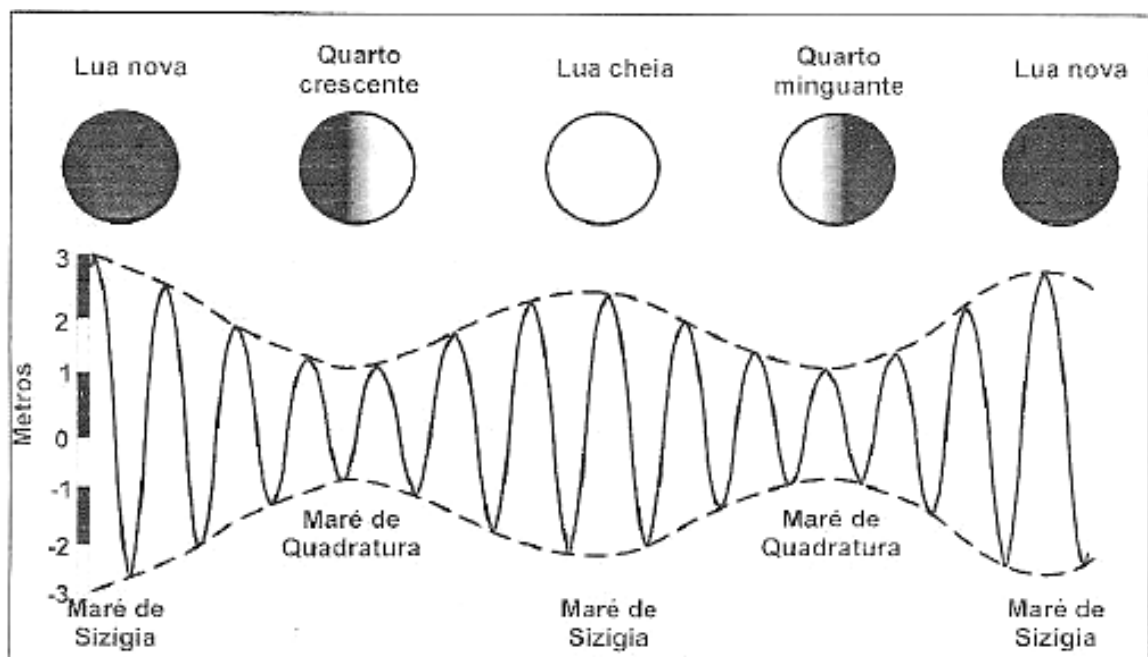


Figura 3 - Oscilação do ciclo de maré de sizígia e quadratura associado às fases de lua cheia, lua nova, quarto crescente e quarto minguante e as respectivas influências nas variações de amplitudes no nível do mar.

Fonte: Lentini (2007)

2.3.2 Marés Meteorológicas

A presença de perturbações de origem meteorológica é detectada através das variações encontradas no nível médio do mar, as quais são identificadas a partir dos registros de alturas do nível da água (OLIVEIRA, 2004), culminando em níveis mais baixos ou mais altos do que os previstos nas tábuas de maré, que levam em consideração apenas o comportamento determinístico e previsível da maré astronômica (VALENTIM, 2012). Essas perturbações são denominadas de maré meteorológica, e estão associadas, principalmente, aos efeitos da variação da pressão atmosférica interagindo no nível do mar, conhecido como barômetro invertido, segundo o princípio de Torricelli e ao efeito da tensão do vento, associado ao mecanismo de transporte de Ekman (OLIVEIRA, 2004).

Segundo Alfredini e Arasaki (2009), as condições meteorológicas podem alterar consideravelmente a altura e horário de uma determinada maré. O efeito combinado de ventos contra a costa com baixas pressões atmosféricas corresponde às marés meteorológicas positivas, também evidenciadas durante ressacas. O efeito oposto é conhecido como maré meteorológica negativa. As marés meteorológicas possuem períodos da ordem de alguns dias. Especialmente, as pistas de atuação do vento associadas aos casos mais extremos de sobre-elevação, possuem extensão da ordem de centenas de quilômetros (CAMPOS *et al.*, 2010).

De acordo com Neves e Muehe (2008), em 2004 ocorreu na costa de Santa Catarina, Brasil, uma intensificação da maré meteorológica devido à associação com um ciclone extratropical, que numa situação única atingiu a força de um furacão, batizado de “Catarina”. Na ocasião, a previsão fornecida pelos modelos numéricos foi subestimada, calculando uma elevação em torno de 12 cm. Ainda conforme estes autores, ao longo da PC brasileira, a propagação de ciclones extratropicais de Sul para Norte, produz empilhamentos de água junto à costa ou excita a formação de ondas de plataforma que se propagam no mesmo sentido.

Assim, deve-se definir o conceito de espiral de Ekman, que pode ser entendido como: entre a direção dos ventos e as correntes marítimas por eles induzidas, existe um ângulo de aproximadamente 45° em superfície, que aumenta progressivamente em profundidade, à medida que o atrito entre as partículas de água aumenta (Figura 4).




Figura 4 - Espiral de Ekman e o transporte resultante do processo

Fonte: Adaptado de Thrurman (1996)

Na superfície, a velocidade resultante da corrente é direcionada à direita (90°) do vento no hemisfério norte, e para a esquerda no hemisfério sul. Assim, o transporte de Ekman corresponde a uma consequência do fenômeno de rotação da Terra sobre seu próprio eixo quando associado ao escoamento permanente de um fluido na presença de tensões. Não é necessário que o transporte de Ekman seja em direções opostas para gerar divergência – rebaixamento do nível da água – ou convergência – elevação. Esses processos de divergência ou convergência definem a dinâmica de Ekman (Figura 5).

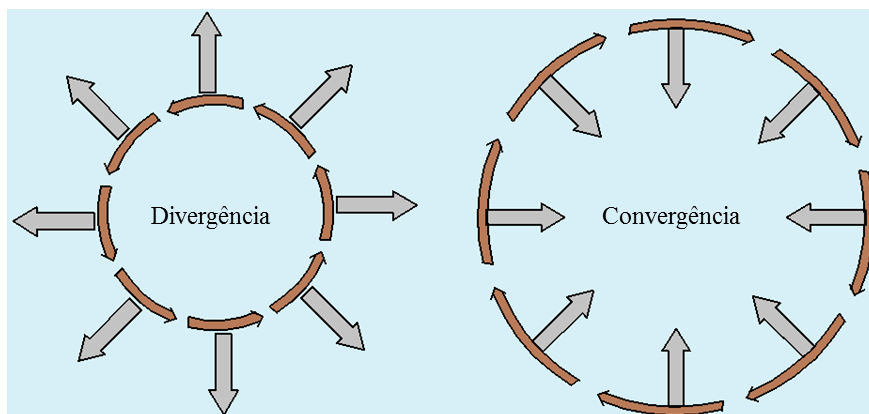


Figura 5 - Dinâmica de Ekman em regiões oceânicas no hemisfério sul

De acordo com Stewart (2008), a fórmula de Ekman mais utilizada relaciona a tensão do vento com: velocidade em superfície, coeficiente de arrasto e densidade do ar (Eq. 2):

$$T = \rho_{ar} C_d U_{10}^2 \quad (2)$$

Onde:

ρ_{ar} = densidade do ar (aproximadamente 1,22 Kg/m³);

C_d = coeficiente de rugosidade da superfície do mar;

U_{10} = velocidade do vento medida a uma altura de 10 m

O transporte de Ekman é responsável por fenômenos como a ressurgência em Cabo Frio (RJ), o empilhamento de água junto à costa bloqueando o escoamento de rios, a inundação de lagoas costeiras prejudicando a drenagem pluvial, entre outros efeitos. No caso de conjunção da elevação do nível do mar e ocorrência de ondas mais altas, as ressacas, as praias ficam expostas a mudanças morfológicas que resultam no recuo da linha de costa (NEVES e MUEHE, 2008).

2.4 Nível do Mar

A percepção imobilista do nível do mar foi deposta durante as décadas de 1970-80, através da percepção de que o nível do mar estava se elevando, a uma taxa que poderia se acelerar no futuro. Entretanto, foi descoberto que, em determinadas áreas costeiras o nível do mar estava se reduzindo, como consequência mecânica da movimentação ascendente da crosta terrestre, aliviada da carga de espessas camadas de gelo após o fim da última era glacial (NEVES, 2005). Assim, sabe-se que o nível do mar é continuamente modificado positiva (para cima) ou negativamente (para baixo), em diversas escalas espaço-temporais, por ondas nos oceanos, pela atmosfera, por movimentos tectônicos etc.

Ele pode se elevar extraordinariamente causando inundações na costa, quando tempestades severas atuam sobre águas litorâneas se sobrepõem a períodos de máxima variação da maré astronômica (sizígia), especialmente nas preamares ou marés altas. Regiões costeiras com baixo relevo e densamente povoadas podem vir a sofrer desastres na presença de anomalias oceânicas. Por outro lado, grandes oscilações negativas do nível médio do mar são altamente indesejáveis para a navegação de grande porte, pois procedimentos de acesso e atracação ficam mais difíceis e arriscados, por vezes impossibilitando as operações (CAMPOS *et al.*, 2010).

O nível médio do mar (NMM) pode ser analisado como um nível médio estático, em torno do qual a maré oscila, ou como um nível médio dinâmico, onde, a partir do nível do mar observado, são filtradas as perturbações de “alta” frequência (MENEZES, 2007). É uma grandeza sujeita à várias forçantes, tais como, as consideradas principais: astronômicas, meteorológicas, ondas, deflúvios, precipitações, evaporação, salinidade, temperatura, correntes marítimas, geotectonismo e ação antrópica (KALIL, 1999).

Conforme Tessler e Goya (2005), a Regra de Bruun de 1962 propõe que a elevação ou diminuição do nível relativo do mar modifica o equilíbrio de uma zona litorânea. Se ocorrer uma elevação do nível, da escala de tempo secular à geológica, toda a linha de costa estará submetida à ação de processos erosivos até que um novo perfil de equilíbrio seja atingido. As principais perturbações encontradas em registros de nível do mar, em escala temporal, conforme Neves e Muehe (2008) são:

- a) Para 10^1 a 10^2 minutos (minutos a horas) - oscilações curtas de cunho meteorológico (de “alta” frequência);
- b) Para 10^2 a 10^3 minutos (minutos a horas) - oscilações associadas à maré astronômica;
- c) Para 10^4 minutos (dias) - oscilações de “baixa” frequência de cunho “maré meteorológica”
- d) Para 10^5 minutos (meses) - sazonais e intra-anuais;
- e) Para 10^6 minutos ou mais (anos ou mais) - variações de longo termo.

Para o caso das oscilações curtas de cunho meteorológico (de “alta” frequência), da ordem de minutos a horas (a), os autores citam como possíveis consequências a indução da ressonância em recintos portuários, produzindo fortes correntes, acarretando em danos a embarcações. Para as oscilações de “baixa” frequência decorrentes de “marés meteorológicas” (c) os autores afirmam que estas estão diretamente vinculados a efeitos meteorológicos associados à ocorrência de ressacas. No caso dos fenômenos sazonais e intra-anuais (d) ocorre influência de fatores climáticos; já as variações de longo prazo (e) há influência de fatores tectônicos e geológicos. O presente estudo enquadra-se nos fenômenos de curto prazo, da ordem de horas. A Figura 6 apresenta um esquema para a divisão das escalas dos fenômenos atmosféricos e oceanográficos proposta por Menezes (2007), como adaptação da classificação de Orlanski (1975).




Figura 6 - Escalas espacial e temporal de fenômenos atmosféricos e oceanográficos

Fonte: Menezes (2007)

Para Valentim (2012), a variabilidade espaço-temporal desses fenômenos meteoclimatológicos se dá desde a microescala atmosférica (escala espacial de 1 a 100 m, e tempo de vida de 1s a 2 h) até fenômenos que possuem abrangência global, e são observados de maneira quase que permanente. Entretanto, diante das diferentes características físico-químicas do oceano e da atmosfera, as dimensões dos fenômenos são distintas. Nota-se que há sobreposições entre as escalas dos fenômenos, porém as dimensões são comuns apenas na escala temporal. Verifica-se que a mesma nomenclatura foi usada para classificar as escalas oceânicas e atmosféricas, porém, os limites da escala espacial e temporal são distintos. A Figura 7 apresenta as influências de várias forçantes na geração de perturbações do nível do mar em forma de ondas.




Figura 7 - Escala espaço-temporal das perturbações do nível do mar geradas pela influência: a) do vento local; b) de oscilações de alta frequência (frequências < 3 ciclos por dia - cpd); e c) de oscilações de baixa frequência (frequências > 3 cpd).

Fonte: Miranda *et al.* (2002)

Medições sistemáticas têm sido feitas pela Marinha do Brasil, por meio de sua Diretoria de Hidrografia e Navegação (DHN) e, mais recentemente, pelo Centro Hidrográfico da Marinha (CHM), pelo Instituto de Pesquisas Hidroviárias (INPH), órgão vinculado à extinta Portobras e atualmente vinculado à Cia. Docas do Rio de Janeiro, pelo Instituto Oceanográfico da Universidade de São Paulo (IOUSP), pelo Instituto Brasileiro de Geografia e Estatística (IBGE). A falta de informações históricas sobre o nível do mar potencializa a grande vulnerabilidade do Brasil a mudanças do nível relativo do mar, posto que sequer pode-

se garantir se a variabilidade observada é um fenômeno local, regional ou global. (NEVES e MUEHE, 2008).

2.4.1 Efeitos do vento na variação do nível médio do mar

A atuação dos ventos nos oceanos (através da fricção deste com a superfície marinha) provoca distúrbios sob a forma de ondas e correntes. Na interface ar-mar, o cisalhamento friccional gera, inicialmente, a movimentação de massas d'água na direção do vento, causando a transferência da quantidade de movimento (energia) entre o oceano e a atmosfera (*momentum*); um processo muito complexo (PUGH, 1996).

As possíveis oscilações no nível médio do mar oriundas das forçantes atmosféricas podem ser provocadas por fenômenos locais ou de efeito remoto. Para a análise da influência do vento sobre o NMM, é fundamental avaliar quatro fatores principais: a orientação em relação à costa; a magnitude (grandeza) desse vento; a permanência (tempo) de atuação no meio e a pista (*fetch*) de atuação (VALENTIM, 2012). De um modo geral, desde que o efeito de rotação terrestre possa ser desprezado, pode-se afirmar que a ação do vento se traduz numa subida do nível do mar no sentido para onde sopra o vento. Um vento forte soprando para terra induz elevação do nível do mar e, conseqüentemente, alturas de água maiores do que as previstas. Fenômeno inverso ocorre quando o vento sopra da terra para o mar (TESSLER E GOYA, 2005).

Para o estado de São Paulo, que possui orientação de linha de costa basicamente nordeste-sudoeste, os ventos paralelos à costa com componentes de sul-sudoeste causam empilhamento na água ao longo da costa, enquanto os de nordeste retiram a água da costa (VALENTIM, 2012).

2.4.2 Efeitos da pressão atmosférica no nível médio do mar

Quanto maior a pressão atmosférica sobre a superfície do mar, maior o rebaixamento nesta e vice-versa. Segundo Oliveira (2004), as variações da pressão atmosférica provocam alterações inversamente proporcionais no nível do mar, em escalas de tempo que vão de horas a dias.

De acordo com Pugh (1987) a relação da resposta do nível do mar aos efeitos da pressão pode ser escrita da seguinte forma:

$$\textit{resposta do nível do mar} = \frac{\textit{resposta estática do nível do mar}}{(1-C_A^2/gD)} \quad (3)$$

Onde:

C_A = velocidade de propagação do distúrbio;

g = aceleração da gravidade;

D = profundidade constante da água.

Para a variação da pressão é estacionária, $C_A = 0$, têm-se uma resposta estática. O termo C_A^2/gD é a razão entre a velocidade do distúrbio e a velocidade de uma onda livre progressiva. Como C_A aumenta a partir de zero a resposta é amplificada. Se os dois termos são iguais, a resposta é teoricamente infinita, porém isso é compensado através do atrito em situações reais (OLIVEIRA, 2004).

Taborda e Dias (1992) compararam graficamente a sobre-elevação do nível do mar com a pressão atmosférica para o período de 1978 e 1981, para as localidades de Viana Castelo, Porto – Pedra Rubas, Lisboa – Instituto Geofísico, Sines e Faro. Afirmaram que apesar da diferença no intervalo de amostragem, há uma concordância confirmada pelo valor do coeficiente de correlação encontrado entre estas duas grandezas: 0,86 a 0,91 para o temporal de 1978 e 0,58 a 0,89 para o temporal de 1981.

2.5 Fundamentos das Redes Neurais Artificiais

O cérebro humano é um computador, ou um sistema de processamento de informação altamente complexo, não linear e paralelo. Ou seja, que desenvolve múltiplas tarefas simultaneamente e que tem a capacidade de organizar seus neurônios possibilitando a realização de processos muito mais rapidamente do que qualquer computador digital existente. No momento do nascimento, o cérebro tem uma grande estrutura e a habilidade de desenvolver suas próprias regras através do que chamamos de experiências, que vão sendo

acumuladas com o tempo (HAYKIN, 2001). Desta forma, seria de grande valor para os avanços científicos se fosse possível a compreensão deste sistema gerando, portanto, métodos que modelassem os processos de percepção e cognição humanos. Em 1943, surgiram os primeiros modelos matemáticos baseados no comportamento das células nervosas biológicas.

Os autores MacCulloche Pitts, em seu trabalho “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, forneceram elementos computacionais, os quais são abstrações das propriedades dos neurônios e suas respectivas conexões (OLIVEIRA, 2004). Portanto, podemos definir Redes Neurais Artificiais (RNAs ou ANNs – *Artificial Neural Networks*) como uma técnica projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples denominadas neurônios ou unidades de processamento (HAYKIN, 2001).

Em *Redes Neurais - Princípios e Práticas*, Haykin (2001) cita um breve histórico do caminho percorrido pelo desenvolvimento das RNAs, tais como:

- James (1890), no livro *Psychology*, descreveu as principais ideias a respeito da psicologia científica na compreensão futura dos aspectos neuronais;
- Hebb (1949), no livro *The Organization of Behavior*, apresentou pela primeira vez, uma regra de aprendizagem fisiológica para a modificação sináptica, conhecida como postulado de aprendizagem;
- Neumann (1958), no livro *The Computer and the Brain*, apresentou a questão da memória no sistema nervoso biológico;
- Rosembat (1958), no trabalho intitulado *The perceptron: a probabilistic model for information storage and organization in the brain*, desenvolveu uma máquina de aprendizagem, denominada perceptron, capaz de produzir o complexo comportamento cerebral adaptativo;
- Widrow e Hoff (1960) introduziram o algoritmo do mínimo quadrado médio para formular o elemento linear adaptativo;
- Minsky e Papert (1969), no livro *Perceptrons*, conseguiram provar que o perceptron de uma única camada, antes descrito por Rosembat, era incapaz de resolver problemas simples de classificação padrão e, com isso, contestaram a eficácia das RNAs;
- Kohonen (1982) desenvolveu os mapas auto-organizáveis, utilizando uma estrutura de rede unidimensional ou bidimensional;

- Rumelhart *et al.* (1986) descreveram o desenvolvimento do algoritmo *backpropagation* para o perceptron de múltiplas camadas, tornando-se o mais popular algoritmo de aprendizagem por retropropagação do erro;
- Broomhead e Lowe (1988) descreveram o procedimento para o projeto de redes neurais alimentadas adiante (*feedforward*) em camadas, utilizando funções de base radial, as quais fornecem alternativas aos perceptrons de múltiplas camadas;
- Na década de 1990, Vapnik e outros determinaram uma classe de redes de aprendizagem supervisionada considerada poderosa, sob o ponto de vista computacional, utilizada em reconhecimento de padrões, regressão e probabilidade de estimativa de densidade, chamada máquina de vetor de suporte

Conforme Oliveira (2004) pode-se inferir que as RNAs vêm sendo aplicadas em várias áreas com bastante sucesso, tais como: reconhecimento de padrões, controle de sistemas, otimização, processamento de sinais e previsão e algumas pesquisas vem sendo desenvolvidas nas áreas de meteorologia e oceanografia.

Para prever a variabilidade do nível do mar, Filippo (2003) usou um modelo de RNAs para um estudo de caso nos municípios de Cananéia, SP e Ilha Fiscal, RJ, tendo como variáveis representativas do sistema, a pressão atmosférica e o vento. Sperb *et al.* (2003) utilizaram uma rede neural temporal para previsão do nível do mar no município de São Francisco do Sul - SC, e concluíram que as RNA Temporais conseguiram capturar as características dos processos temporais de uma forma muito eficiente, aprendendo diretamente o comportamento não estacionário das séries temporais.

Meena e Agrawal (2015) utilizaram as RNAs para prever o nível do mar em Cochin e Chennai, ambos na Índia; segundo estes autores, as RNAs fornecem um mapeamento não-determinístico entre um dado conjunto de valores de entrada e saída. Isto as torna adequadas para previsão de nível do mar com base nas observações anteriores.

Em um trabalho de Chen *et al.* (2012), foram aplicadas RNAs como uma abordagem de modelagem alternativa para simular o nível de água de séries temporais do estuário do Rio Danshui no norte de Taiwan. Nesse estudo, cinco modelos foram construídos para tal simulação de séries temporais em: Shizi Tou, Ponte Taipei, Rukuoyan, Xinhai Bridge, Ponte Zhongzheng. Esses resultados foram comparados a simulações realizadas com modelos hidrodinâmicos (2D e 3D). A Figura 8 apresenta os gráficos de dispersão de dados simulados e dados observados, usando (a) RNAs, (b) o modelo hidrodinâmico 2D verticais, e (c) o

modelo hidrodinâmico 3D, para a Ponte Taipei (fase de treinamento). Já a Figura 9 apresenta os mesmos gráficos, porém relativos à fase de teste.

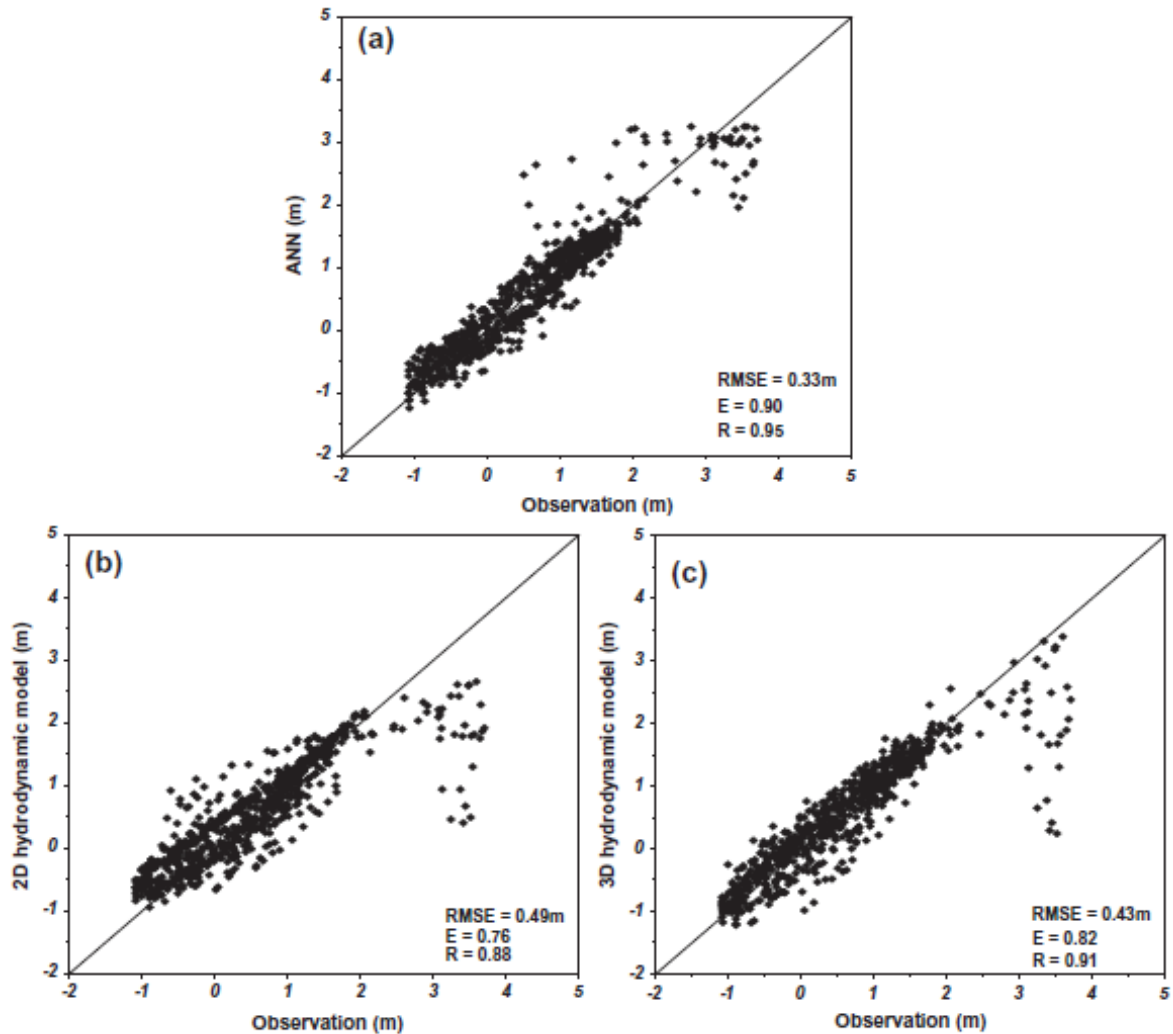


Figura 8 - Gráficos de dispersão de dados simulados e dados observados, usando (a) RNAs (ANN), (b) modelo hidrodinâmico 2D vertical, e (c) o modelo hidrodinâmico 3D, para a Ponte Taipei (fase de treinamento).

Fonte: Adaptado de Chen *et al.* (2012)

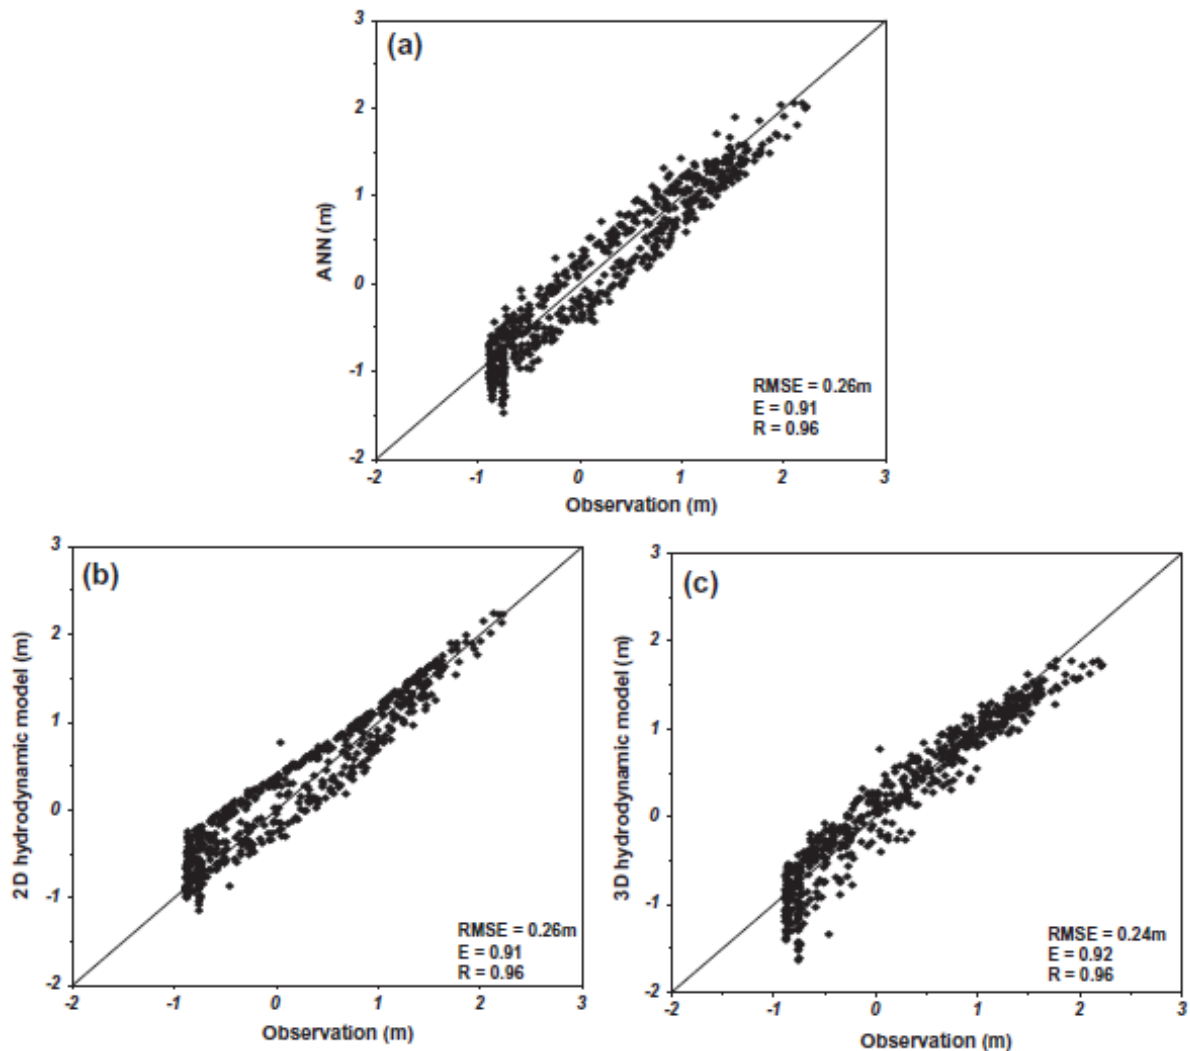


Figura 9 - Gráficos de dispersão de dados simulados e dados observados, usando (a)RNAs, (b) modelo hidrodinâmico 2D verticais, e (c) o modelo hidrodinâmico 3D, para a Ponte Taipei (fase de teste).

Fonte: Adaptado de Chen *et al.* (2012)

Esses autores concluíram que os modelos 2D e 3D não conseguiram capturar os níveis de água observados durante uma entrada de alta descarga fluvial enquanto que a RNA coincidiu com a fase de água observada. Porém, durante a fase de testes, a abordagem RNA foi um pouco inferior aos modelos 2D e 3D em três localidades. Os resultados mostraram também que as RNAs foram capazes de prever o nível de água de séries temporais com razoável precisão, sugerindo ser uma ferramenta valiosa para a gestão estuarina e costeira.

No Brasil, esses modelos desenvolvidos para estudos do comportamento do oceano e da atmosfera ainda são escassos, principalmente na variabilidade do nível do mar relacionado à maré meteorológica.

2.5.1 Características gerais de uma RNA

Para Haykin (2001), uma rede neural se vale de sua estrutura paralelamente distribuída em diferentes entradas e de sua habilidade de aprender e, portanto, de generalizar. A generalização se refere ao fato de a rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem).

Características das RNAs:

- Não-linearidade – uma rede neural constituída por conexões de neurônios não-lineares é ela mesma não-linear;
- Mapeamento de Entrada-Saída – a rede aprende a partir de exemplos;
- Adaptabilidade – capacidade de adaptar seus pesos sinápticos a modificações do meio ambiente;
- Resposta a Evidências – uma rede neural pode ser projetada para fornecer informações sobre qual padrão particular selecionar e sobre a confiança na decisão tomada;
- Informação Contextual – o conhecimento é representado pela própria estrutura e estado de ativação de uma rede neural;
- Tolerância a Falhas – potencial de ser inerentemente tolerante a falhas, ou capaz de realizar computação robusta, no sentido de que seu desempenho se degrada suavemente sob condições de operação adversas;
- Implementação em VLSI (*very-large-scale-integration*) – rapidez na computação de certas tarefas;
- Uniformidade de Análise e Projeto – a mesma notação é utilizada em todos os domínios envolvendo a aplicação de redes neurais;
- Analogia Neurobiológica – o projeto de uma rede neural é motivado pela analogia.

Para Marzban (2003) as RNAs são capazes de ajustarem qualquer dado e, quando comparadas a outros modelos estatísticos, apresentam a característica de menor superestimação.

2.5.2 Cérebro humano, o neurônio biológico e o modelo de um neurônio artificial.

O cérebro humano apresenta, de modo geral, três estágios, como demonstrado na Figura 10.




Figura 10 - Representação em diagrama em blocos do sistema nervoso

Fonte: Adaptado de Haykin (2010)

O sistema nervoso, representado pela rede neural (nervosa), recebe as informações, percebe-as e toma decisões apropriadas. No diagrama em blocos, as setas apontadas da direita para a esquerda indicam realimentação no sistema. Os receptores convertem estímulos do corpo humano ou do ambiente externo em impulsos elétricos que transmitem informações para a rede neural – cérebro. Os atuadores convertem impulsos elétricos gerados pela rede neural em respostas discerníveis como saídas do sistema (HAYKIN, 2001).

Para Kovács (2002 *apud* SANTOS, 2013), o neurônio biológico é o dispositivo computacional elementar do sistema nervoso. O mesmo possui múltiplas entradas e uma saída. As entradas ocorrem por meio de conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos por potenciais de ação. Estes constituem a informação que o neurônio irá processar para produzir como saída um impulso nervoso no seu axônio. O neurônio biológico (representado pela Figura 11) é uma célula que pode ser dividida em três seções: o corpo da célula, os dendritos e o axônio.




Figura 11 - Representação esquemática de um neurônio biológico

Fonte: Adaptado de Oliveira (2004)

Os dendritos são as zonas receptoras de informações, ou impulsos nervosos, oriundas de outros neurônios, e conduzem essas informações até o corpo celular. Lá, a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros neurônios, passando pelo axônio (que correspondem a “linhas de transmissão”) e atingem os dendritos dos neurônios seguintes até chegar ao local de processamento do estímulo.

As sinapses correspondem às unidades estruturais e funcionais elementares que mediam as interações entre os neurônios (HAYKIN, 2001). Pelas sinapses, os neurônios se unem funcionalmente, formando as redes neurais. O efeito das sinapses é variável, e é esta variação que dá ao neurônio capacidade de adaptação. Pode-se impor ao neurônio receptor estímulos de excitação ou de inibição, mas não ambos (HAYKIN, 2001). Em média, cada neurônio forma entre mil e dez mil sinapses.

Já o neurônio artificial é uma estrutura lógico-matemática, uma unidade de processamento de informação que é fundamental para a operação de uma rede neural e procura simular a forma, o comportamento e as funções de um neurônio biológico (Figura 12):

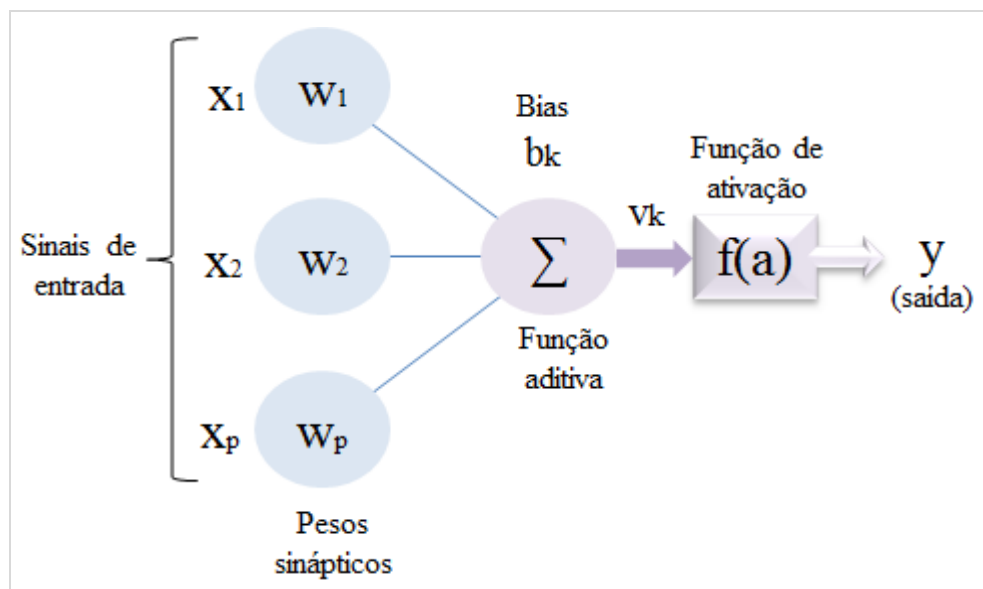


Figura 12 - Modelo não-linear de um neurônio

Fonte: Adaptado de Haykin (2001)

Conforme Haykin (2001), em um conjunto de sinapses (elos de conexão), cada uma é caracterizada por um peso ou força própria e, ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui tanto valores negativos como positivos. A função aditiva caracteriza-se por somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio e possui operações que constituem um combinador linear. A função de ativação é também referida como função restritiva por limitar o intervalo permissível de amplitude do sinal de saída a um valor finito. A saída do neurônio é a previsão do modelo para uma variável no conjunto de dados. O modelo representado na Figura 12 inclui um *bias* (viés) aplicado externamente, que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

Haykin, (2001) descreve matematicamente todo o esquema de um neurônio artificial, conforme as equações a seguir:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (4)$$

$$y_k = \varphi(u_k + b_k) \quad (5)$$

Sendo:

x_j = sinais de entrada

w_j = pesos sinápticos do neurônio k

u_k = saída do combinador linear devido aos sinais de entrada

b_k = *bias* ou viés

φ (.) = função de ativação

y_k = sinal de saída do neurônio

O uso de *bias* tem efeito de aplicar uma transformação afim à saída u_k do combinador linear do modelo, tal como:

$$v_k = u_k + b_k \quad (6)$$

O *bias* b_k é um parâmetro externo de um neurônio artificial k . Podemos considerar a sua presença como na Eq. 5. De modo análogo, podem ser combinadas as Eqs. 4 até 6, como:

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (7)$$

$$y_k = \varphi(v_k) \quad (8)$$

Adicionando-se, agora, na Eq. 7 uma nova sinapse:

$$x_0 = +1 \quad (9)$$

E seu peso é:

$$w_{k0} = b_k \quad (10)$$

2.5.3 Tipos de função de ativação

A função de ativação definirá a saída de um neurônio em termos de campo local induzido v e diferentes tipos dela são descritas abaixo. Para mais detalhes sobre essas equações, sugere-se uma consulta a Haykin (2001).

Função de Limiar: a saída de um neurônio assume valor 1, se o campo local induzido daquele neurônio for nulo ou positivo, enquanto o valor de saída será nulo caso o valor de φ seja negativo. Essa função descreve a propriedade do “tudo ou nada” do modelo de McCulloch-Pitts.

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (11)$$

A saída do neurônio k que emprega esta função de limiar é expressa como:

$$y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (12)$$

Sendo: v_k o campo local induzido do neurônio; ou seja:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (13)$$

Função Linear por partes: pode ser vista como uma aproximação de um amplificador não-linear. Se a região linear de operação for mantida sem entrar em saturação, surge um combinador linear. A função linear por partes se reduz à função de limiar, se o fator de amplificação da região linear é definido como infinitamente grande.

$$\varphi(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (14)$$

Onde assume-se que o fator de amplificação dentro da região linear de operação é a unidade.

Função Sigmoides: possui um gráfico em forma de “s”; é a forma mais comum de função de ativação utilizada na construção de RNAs. É definida como uma função estritamente crescente que exibe um balanceamento adequado entre comportamento linear e não-linear.

- ✓ Um exemplo dessa função de ativação é a função logística, definida por:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (15)$$

Sendo: a o parâmetro de inclinação da função sigmoide. Variando-se o parâmetro “ a ”, obtemos funções sigmoides com diferentes inclinações. No limite, quando o parâmetro de inclinação se aproxima do infinito, a função sigmoide se torna simplesmente uma função de limiar. Se a função de limiar assumir o valor de 0 ou 1, uma função sigmoide assume um intervalo contínuo de valores entre 0 e 1. A função de limiar é definida, neste caso, como:

$$\varphi(v) = \begin{cases} 1 & \text{se } v > 0 \\ 0 & \text{se } v = 0 \\ -1 & \text{se } v < 0 \end{cases} \quad (16)$$

A qual é denominada função sinal. Para a forma correspondente de uma função sigmoide, podemos utilizar a função tangente hiperbólica, definida por:

$$\varphi(v) = \tanh(v) \quad (17)$$

Outros exemplos de funções do tipo sigmoide podem ser explicitadas como:

- ✓ Função identidade:

$$\varphi(v) = a \quad (18)$$

- ✓ Função Tangente Hiperbólica: possui uma curva sigmoide similar à da função logística. Ideal para redes MLP (*multilayer perceptrons* ou Perceptrons de múltiplas camadas), particularmente com camadas ocultas:

$$\varphi(v) = \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (19)$$

- ✓ Função Exponencial: função exponencial negativa:

$$\varphi(v) = e^{-a} \quad (20)$$

- ✓ Função Seno: útil para dados distribuídos radialmente:

$$\varphi(v) = \sin a \quad (21)$$

- ✓ Função *Softmax*: para as tarefas de classificação com função de erro *cross entropy* a função de ativação de saída das redes MLP e RBF (*radial basis function* ou rede de função de base radial) é a *softmax*.

$$\varphi(v) = \frac{\exp(a_i)}{\sum \exp(a_i)} \quad (22)$$

- ✓ Função Gaussiana: utilizada para as redes neurais RBF

$$\varphi(v) = \frac{1}{2\pi\sigma} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] \quad (23)$$

2.5.4 Perceptrons de camada única

De acordo com Haykin (2001), o perceptron é a forma mais simples de uma rede neural (apenas um neurônio com pesos sinápticos ajustáveis e *bias*), usada para classificação de padrões ditos linearmente separáveis, ou seja, que se encontram em lados opostos ou em um hiperplano. O treinamento dá-se pelo algoritmo do *perceptron* que converge na superfície limite entre duas classes. O mínimo quadrado médio - LMS (ou regra de Delta) é um algoritmo simples de implementar e muito efetivo em relação à sua aplicação. Ambos surgiram aproximadamente ao mesmo tempo, durante o final dos anos 1950.

2.5.5 Perceptrons de múltiplas camadas (MLP)

A rede perceptron de múltiplas camadas também é conhecida como rede alimentada adiante de múltiplas camadas, devido ao fluxo da informação ser unidirecional. As entradas são propagadas da camada de entrada para a camada de saída, passando por uma ou mais camadas ocultas (MACHADO E FONSECA JÚNIOR, 2013). Cada uma destas camadas é totalmente conectada com a próxima. A Figura 13 representa um exemplo desta arquitetura.




Figura 13 - Perceptron de múltiplas camadas

Fonte: Oliveira (2004)

Conforme Haykin (2001), os perceptrons de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas difíceis, através do seu treinamento de forma supervisionada com o algoritmo de retropropagação de erro. Um perceptron de múltiplas camadas possui três características distintas (HAYKIN. 2001):

- O modelo de cada neurônio da rede inclui uma função de ativação não-linear, com uma não-linearidade suave. A presença de não-linearidade é importante porque, do contrário, a relação de entrada-saída da rede poderia ser reduzida àquela de um perceptron de camada única. Uma forma de não-linearidade que satisfaz esta exigência é uma não-linearidade sigmoide definida pela função logística, conforme Equação 15;
- Há uma capacitação da rede para realizar tarefas complexas extraíndo as características mais significativas dos padrões de entrada devido à presença de uma ou mais camadas de neurônios ocultos que não são parte da entrada ou da saída da rede;
- As sinapses da rede determinam um alto grau de conectividade da rede. Uma modificação na conectividade da rede requer uma mudança na população das conexões sinápticas ou de seus pesos.

Essas redes têm destaque pela capacidade de abstração em representar as características do fenômeno através das informações encontradas na camada de entrada. Possuem alto grau de generalização, mesmo quando os padrões não pertencem ao conjunto de dados fornecidos à rede. Além disso, a retirada de algum neurônio não compromete, normalmente, a funcionalidade da rede, sendo capaz de reconhecer padrões mesmo na presença de distorções (OLIVEIRA, 2004).

Geralmente, uma MLP treinada com o algoritmo de retropropagação aprende em estágios, partindo da realização de funções de mapeamento razoavelmente simples para funções mais complexas. Conseqüentemente, com têm como objetivo uma boa generalização, é muito difícil perceber quando é o melhor momento para encerrar o treinamento olhando-se apenas para a curva de aprendizagem. Assim, pode-se identificar o início do excesso de treinamento através do uso da validação cruzada, pela qual os dados de treinamento são divididos em subconjuntos de estimação e em um subconjunto de validação (HAYKIN, 2001).

2.5.6 Rede de Função de Base Radial (RBF)

No contexto de uma rede neural, as unidades ocultas fornecem um conjunto de funções que constituem uma base arbitrária para os padrões (vetores) de entrada, quando eles são expandidos sobre o espaço oculto: essas funções são chamadas de funções de base radial (HAYKIN, 2001).

Uma rede RBF apresenta apenas três camadas: uma camada de entrada, uma oculta e uma camada de saída. De acordo com Haykin (2001), a camada de entrada é constituída por nós de fonte que conectam a rede ao seu ambiente. A segunda camada aplica uma transformação não-linear do espaço de entrada para o espaço oculto. A camada de saída é linear, fornecendo a resposta da rede ao padrão (sinal) de ativação aplicado à camada de entrada.

As redes RBF são treinadas em dois estágios:

- a) Modelagem da distribuição de probabilidade dos dados;
- b) As funções de base radial aprendem como associar os dados de entrada e o alvo.

Assim, uma rede RBF pode ser representada, de forma geral, pela Eq. 24:

$$f_k(x) = \exp\left(-\frac{\|x - \mu_k\|^2}{2s_k^2}\right) \quad (24)$$

Onde: μ_k é o k-ésimo centro e s_k é a largura do campo receptivo para o centro.

As redes de função de base radial e os perceptrons de múltiplas camadas são exemplos de redes em camadas alimentadas adiante, não-lineares. Ao comparar-se ambas pode-se constatar que (HAYKIN, 2001):

- Uma rede RBF possui apenas uma camada oculta enquanto que a rede MLP pode ter uma ou mais camadas ocultas;
- A camada oculta de uma rede RBF é não-linear, porém, a camada de saída é linear. No caso da rede MLP, tanto camadas ocultas quanto de saída são, normalmente, não-lineares;
- O argumento da função de ativação de cada unidade oculta em uma rede RBF calcula a norma euclidiana entre o valor de entrada e o centro daquela unidade. Na rede MLP,

a função de ativação de cada unidade oculta, calcula o produto interno do vetor de entrada pelo vetor de peso sináptico daquela unidade;

- Os perceptrons de múltiplas camadas constroem aproximações globais de um mapeamento de entrada-saída não-linear. As redes RBF, utilizando não-linearidades localizadas com decaimento exponencial constroem aproximações locais para mapeamentos de entrada-saída não-lineares. Ou seja, numa aproximação de um mapeamento de entrada-saída não-linear, o MLP requer um número menor de parâmetros que a rede RBF para o mesmo grau de precisão.

2.5.7 Processo de aprendizagem

A definição de aprendizagem no Dicionário Aurélio Básico de Língua Portuguesa (FERREIRA, 1998) corresponde a “(...) aprendizado, ato ou efeito de aprender, especialmente profissão manual ou técnica; o exercício ou prática inicial da matéria aprendida, experiência, tirocínio”. Do ponto de vista de RNAs, pode-se definir aprendizagem como o processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida (MCCLARES, 1970 *apud* HAYKIN, 2001).

Falando-se, portanto, em RNAs, a propriedade mais importante de uma rede neural diz respeito à sua capacidade de aprender a partir de seu ambiente e de melhorar seu desempenho através da aprendizagem. A cada processo de aprendizagem realizado a rede se torna mais instruída sobre o seu ambiente. Desta forma, o processo de aprendizagem da rede dá-se basicamente através dos seguintes passos: estimulação da rede neural por um ambiente; modificações nos parâmetros livres da rede como resultado do primeiro passo; nova resposta da rede neural ao ambiente, devido às modificações ocorridas em sua estrutura interna (HAYKIN, 2001).

Um algoritmo de aprendizagem corresponde a um conjunto de regras definidas para a solução de um problema de aprendizagem. Esses diferem entre si, principalmente, pelo modo como os pesos são modificados. Existem muitos tipos específicos para determinados modelos de redes neurais. Os métodos desenvolvidos para treinamento de redes neurais podem ser separados basicamente em dois tipos:

- Supervisionados: a saída é comparada com a desejada (resultados previamente conhecidos) e ajustes apropriados são realizados nos pesos das conexões até que uma distância mínima seja aceita por algum critério. Conforme Haykin (2001), existe um “professor” capaz de fornecer correções exatas para as saídas da rede quando um erro ocorrer, como na aprendizagem por erro; ou de fixar em relação ao ambiente as unidades de entrada e saída livres da rede, como na aprendizagem de Boltzmann;
- Não Supervisionados: não existe uma saída para comparação. Através dos padrões contidos nas entradas, as unidades experimentais são classificadas automaticamente em grupos. Esse tipo de rede utiliza os neurônios como classificadores e as entradas são os elementos para a classificação. É um processo que envolve competição e colaboração entre os neurônios de rede.

O processo de treinamento supervisionado de redes neurais artificiais multicamadas é equivalente a um problema de otimização não-linear irrestrito, onde uma função de erro global é minimizada a partir do ajuste de parâmetros da rede neural (pesos). Esta perspectiva permite desenvolver algoritmos de treinamento baseados em resultados bem fundamentados da teoria de análise numérica convencional (SILVA, 1998).

O modelo de aprendizagem seletiva darwiniano é baseado na teoria da seleção de grupo neural e difere dos algoritmos de aprendizagem normalmente utilizados em RNAs, porque assume que, por projeto, haja muitas sub-redes e que somente aquelas com a resposta desejada são selecionadas durante o processo de treinamento (HAYKIN, 2001).

Conforme Oliveira (2004), o algoritmo de treinamento mais utilizado é o algoritmo de retropropagação do erro – *backpropagation*, o qual consiste em fornecer à rede a atualização dos pesos no sentido de minimizar o erro entre a saída e o valor alvo ou valor desejado. Esse algoritmo baseia-se no método do gradiente descendente. O objetivo do treinamento é ajustar os pesos sinápticos a um conjunto de entrada para que seja produzido um conjunto de saída desejado. Esse conjunto entrada-saída pode ser referido como um vetor. O treinamento assume que cada vetor de entrada é par do vetor de saída (alvo) representando a saída desejada; juntos são chamados de pares de treinamento. O treinamento *backpropagation* requer as seguintes etapas:

- Selecionar os pares do conjunto de treinamento e apresentar à camada de entrada da rede neural. Esses dados irão percorrer camada por camada da rede, até que a resposta seja produzida pela camada de saída;

- Calcular o erro entre a saída da rede e a saída desejada;
- Ajustar os pesos da rede para minimizar o erro, que é definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (25)$$

Onde:

j = nó de saída;

$d_j(n)$ = resposta desejada para o neurônio j ;

$y_j(n)$ = sinal funcional que aparece na saída do neurônio j , na interação n .

O algoritmo *backpropagation* pode ser usado em vários tipos de redes neurais, porém é o mais apropriado para o treinamento do *perceptron* de múltiplas camadas (OLIVEIRA, 2004). Alguns métodos permitem acelerar a convergência média da fase de treinamento, ao passo que requerem poucas modificações no algoritmo de retropropagação padrão; com isso, resultam em elevados graus de aceleração, além de não mais requererem a escolha de parâmetros críticos da rede neural como a taxa de aprendizagem e o coeficiente de momento (SILVA, 1998).

De acordo com Oliveira (2004), nesse treinamento o erro é propagado a partir da saída até a camada de entrada da rede e os pesos sinápticos das camadas intermediárias são ajustados, de acordo com a retropropagação (Figura 14), minimizando, assim, o valor do erro entre a saída da rede e o alvo.

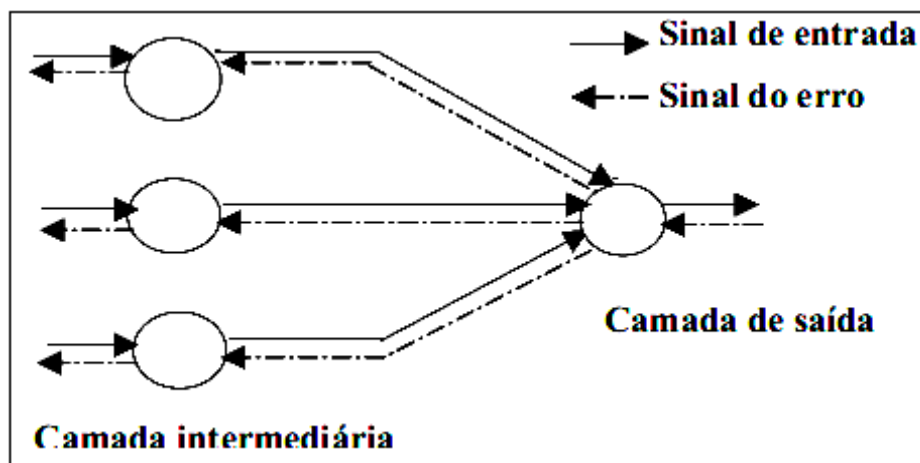


Figura 14 – Esquema de propagação do sinal de entrada e a retropropagação do erro.

Fonte: Oliveira (2004)

Conforme Haykin (2001), as redes que utilizam o algoritmo *backpropagation* operam com a Regra Delta definida para um conjunto de treinamento, onde o erro médio representa a função de custo como uma medida do desempenho da aprendizagem. O objetivo desse processo é ajustar os parâmetros livres da rede para minimizar o erro médio.

A atualização dos pesos aplicada aos pesos sinápticos é definida pela Regra Delta Generalizada, definida por Rumelhart, Hilton e Williams, conforme:

$$\Delta\omega_{ji}(n) = \eta \frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} \quad (26)$$

Onde:

η = parâmetro da taxa de aprendizagem do algoritmo *backpropagation*.

Como $\frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} = -e_{ji}(n)\varphi_j(V_j(n))y_i(n)$, tem-se que: $\Delta\omega_{ji}(n) = \eta\delta_j(n)x_i(n)$

Onde:

$\delta_j(n)$ = erro na unidade j;

$x_i(n)$ = i-ésima entrada da unidade j.

O sinal negativo em “ $-e_{ji}(n)\varphi_j(V_j(n))y_i(n)$ ” indica a descida do gradiente no espaço de pesos.

A atualização do peso da conexão da unidade “i” para a unidade “j” é dada por:

$$\Delta\omega_{ji}(n+1) = \omega_{ji}(n) + \Delta\omega_{ji}(n+1) \quad (27)$$

O gradiente descendente (método de correção dos pesos sinápticos utilizados no algoritmo *backpropagation*) visa reduzir o erro quadrático médio, objetivando-se, assim, buscar um mínimo global, o qual representa a solução teórica ótima para o treinamento, significando o menor erro possível. Porém, durante o treinamento da rede, essa função pode apresentar mínimos locais (Figura 15) e, nesse caso, o parâmetro taxa de aprendizado é muito importante para controlar o tempo de aprendizado da rede, procurando uma convergência em direção ao mínimo global (OLIVEIRA, 2004).




Figura 15 – Pontos de mínimo global (1) e mínimo local (2).

Fonte: Oliveira (2004)

Os algoritmos de otimização podem ser classificados de acordo com a ordem da informação que eles devem calcular:

- Métodos sem diferenciação: não requerem mais do que a simples avaliação da função em diferentes pontos do espaço;
- Métodos de primeira ordem: fazem uso da derivada primeira da função a ser minimizada;
- Métodos de segunda ordem: utilizam informações sobre a derivada segunda da função de custo;
- Métodos empíricos: incluem os algoritmos cujos parâmetros são ajustados de maneira empírica, ou seja, através de procedimentos de tentativa e erro.

De acordo com Silva (1998), o problema de determinação de mínimos globais, mesmo dentro de um conjunto de mínimos locais bem definidos, é difícil devido à impossibilidade fundamental de se reconhecer um mínimo global utilizando-se apenas informações locais. O ponto chave da otimização global é saber quando parar. Recentemente, métodos heurísticos tornaram-se populares, em particular os métodos evolutivos como algoritmos genéticos e recozimento simulado – *simulated annealing*. Entretanto, nenhuma dessas abordagens, analítica ou heurística, garante a localização de um mínimo global de uma função suave e contínua em tempo finito e com recursos computacionais limitados. Estes algoritmos recorrem a um rigor matemático baseado em modelos de otimização não-linear irrestrita bem definidos, não apresentando assim um vínculo natural com a inspiração biológica inicialmente

proposta para as RNAs. A Figura 16 apresenta um fluxograma de estratégias de treinamento para redes MLP, de acordo com os algoritmos de otimização.

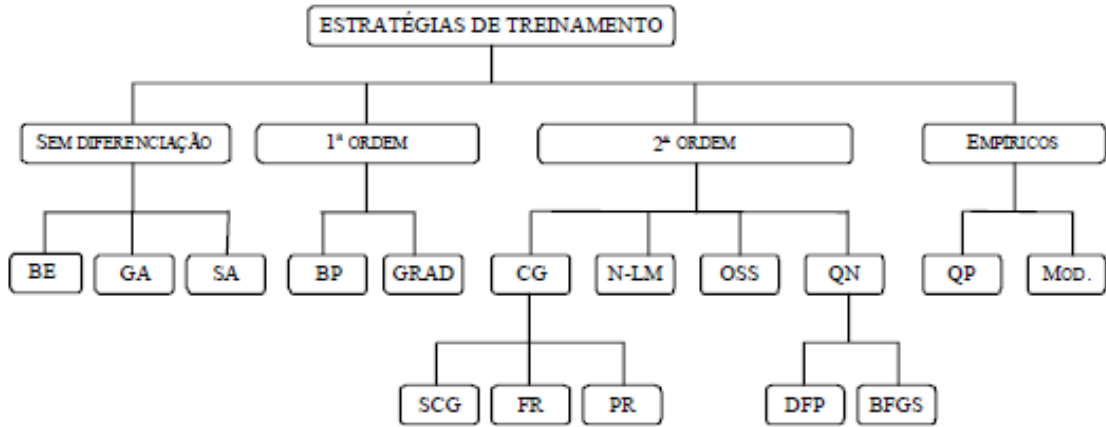


Figura 16 - Estratégias de treinamento de redes neurais do tipo MLP

Fonte: Silva (1998)

Atentando-se ao método de 2ª ordem, destaca-se o Método de Broyden-Fletcher-Goldfarb-Shanno - BFGS: classificado como método quase-Newton. É a forma da aproximação da inversa da matriz hessiana, que, por sua vez, corresponde à derivada segunda de $\epsilon_{med}(W)$ em relação ao vetor de peso “W”, como mostrado pela Equação 28:

$$H = \frac{\delta^2 \epsilon_{med}(W)}{\delta W^2} \quad (28)$$

De acordo com Haykin (2001), a matriz hessiana desempenha um papel importante no estudo das redes neurais, destacando-se:

- Os autovalores da matriz hessiana têm uma forte influência na dinâmica da aprendizagem por retropropagação;
- A inversa da matriz hessiana fornece uma base para podar pesos sinápticos insignificantes de uma MLP;

A expressão que permite determinar a aproximação da inversa da hessiana é apresentada na Equação 29:

$$H_{i+1} = H_i + \frac{p_i p_i^T}{p_i^T q_i} \left[1 + \frac{q_i^T H_i q_i}{p_i^T q_i} \right] - \frac{H_i q_i p_i^T + p_i q_i^T H_i}{p_i^T q_i} \quad (29)$$

Sendo os vetores:

$$q_i \equiv g_{i+1} - g_i = \nabla^2 J(\theta) p_i \quad (30)$$

$$p_i = \alpha_i d_i \quad (31)$$

A avaliação do gradiente em dois pontos fornece informações sobre a matriz hessiana $\nabla^2 J(\theta)$. Como $\theta \in \mathfrak{R}^p$, tomando-se P direções linearmente independentes $\{p_0, p_1, \dots, p_{P-1}\}$, é possível determinar unicamente $\nabla^2 J(\theta)$ caso se conheça $q_i, i = 0, 1, \dots, P - 1$.

2.5.8 Análise de sensibilidade

A sensibilidade de uma função de mapeamento entrada-saída “F” em relação a um parâmetro da função, representado por ω , é definida por (HAYKIN, 2001):

$$S_{\omega}^F = \frac{\frac{\delta F}{F}}{\frac{\delta \omega}{\omega}} \quad (32)$$

Suponha que a função $F(w)$ seja o mapeamento de entrada-saída realizado por esta rede; “w” representa o vetor de todos os pesos sinápticos (incluindo os níveis de *bias*) contidos na rede. As derivadas parciais da função $F(w)$ em relação a todos os elementos do vetor de peso “w” podem ser calculadas eficientemente.

2.5.9 Tipos de arquitetura de redes neurais

Pensar em uma arquitetura de rede neural é pensar na resolução de um problema e, portanto, para tal deve-se ter por base as características do problema a ser tratado. Segundo Haykin (2001), a maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada ao algoritmo de aprendizagem usado para treinar a rede. Assim, podemos pensar no tipo de arquitetura ideal para cada situação a partir do agrupamento das redes neurais, que se dá da seguinte forma:

a) Número de camadas da rede neural

- Camada única: entre as entradas e a saída há apenas uma camada de processamento (Figura 17). Não acontece nenhum processamento na camada de entrada da rede neural;

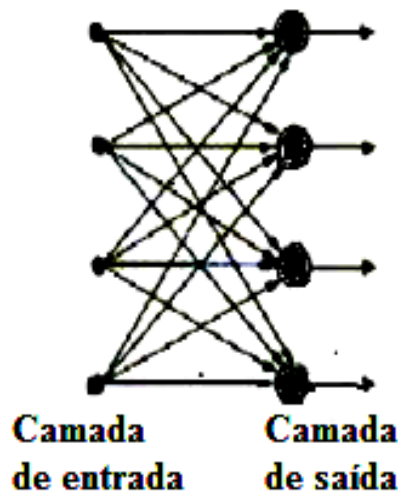


Figura 17 - Rede de camada única

Fonte: Oliveira (2004)

- Múltiplas camadas: entre as entradas e a saída da rede existem diversas camadas onde ocorre o processamento. São distribuídas conforme a necessidade do problema. De acordo com Oliveira (2004), as camadas existentes são definidas por:
 - ✓ Camada de entrada – unidades de entrada, onde os padrões são apresentados à rede e distribuídos para a camada subsequente para serem processados;

- ✓ Camadas escondidas – onde são realizados os processamentos através das funções de ativação e atualização dos pesos sinápticos de forma aleatória. Essas camadas não são observadas diretamente e constituem a não-linearidade da rede neural.
 - ✓ Camada de saída – onde o resultado final da rede é apresentado e comparado ao resultado desejado.
- b) Número de neurônios em cada camada da rede
Relacionado ao tipo de problema a ser resolvido.
- c) Conexão entre neurônios
- *Feedforward* – sistemas de mapeamento não-linear estatístico instantâneo (Figura 18).

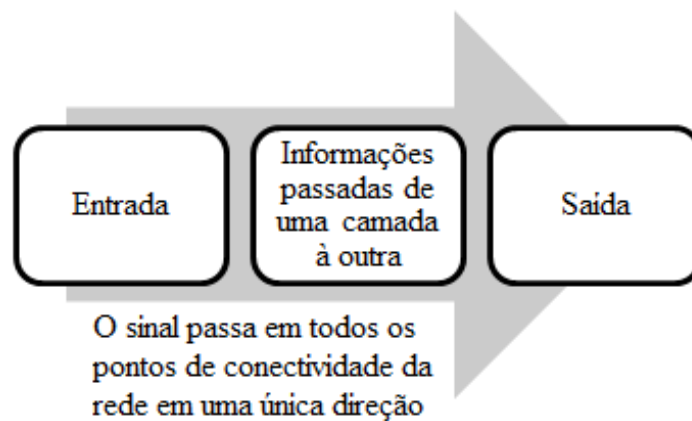


Figura 18 - Esquema representativo de conexão *Feedforward*

Fonte: Adaptado de Haykin (2001)

- Recorrente – sistema não-linear dinâmico. O sinal passa pela rede através de caminhos fechados ou *loops* onde ocorrem laços de realimentação das saídas em direção às entradas.
- Simétrica – se ocorrer conexão de um nó “i” para um nó “j” então haverá a mesma conexão no sentido oposto e os pesos sinápticos associados às duas conexões serão iguais, $w_{ij} = w_{ji}$.
- Assimétrica – as conexões existentes não serão simétricas.

3 DESCRIÇÃO DA ÁREA DE ESTUDO

O Litoral Norte de São Paulo distribui-se em sentido NE-SW, entre a Serra do Mar e o Oceano Atlântico e tem como limites a Serra de Juqueriquerê, a Ilha de São Sebastião e a Serra de Parati no limite entre os Estados de Rio de Janeiro e São Paulo (CARTACHO, 2013). A maior ou menor distância entre a Serra do Mar e a linha de costa faz com que haja uma grande diversidade de paisagens neste segmento litorâneo, com desenvolvimento de extensas planícies costeiras entre Santos (SP) e a baía de São Francisco do Sul (SC) (TESSLER e GOYA, 2005). No Litoral Norte paulista situa-se a região de estudo, inserida entre as coordenadas geográficas: latitudes de 23°26'02" até 23°46'41" S e longitudes de 45°04'16" até 45°24'47" W, como indicado na Figura 19.

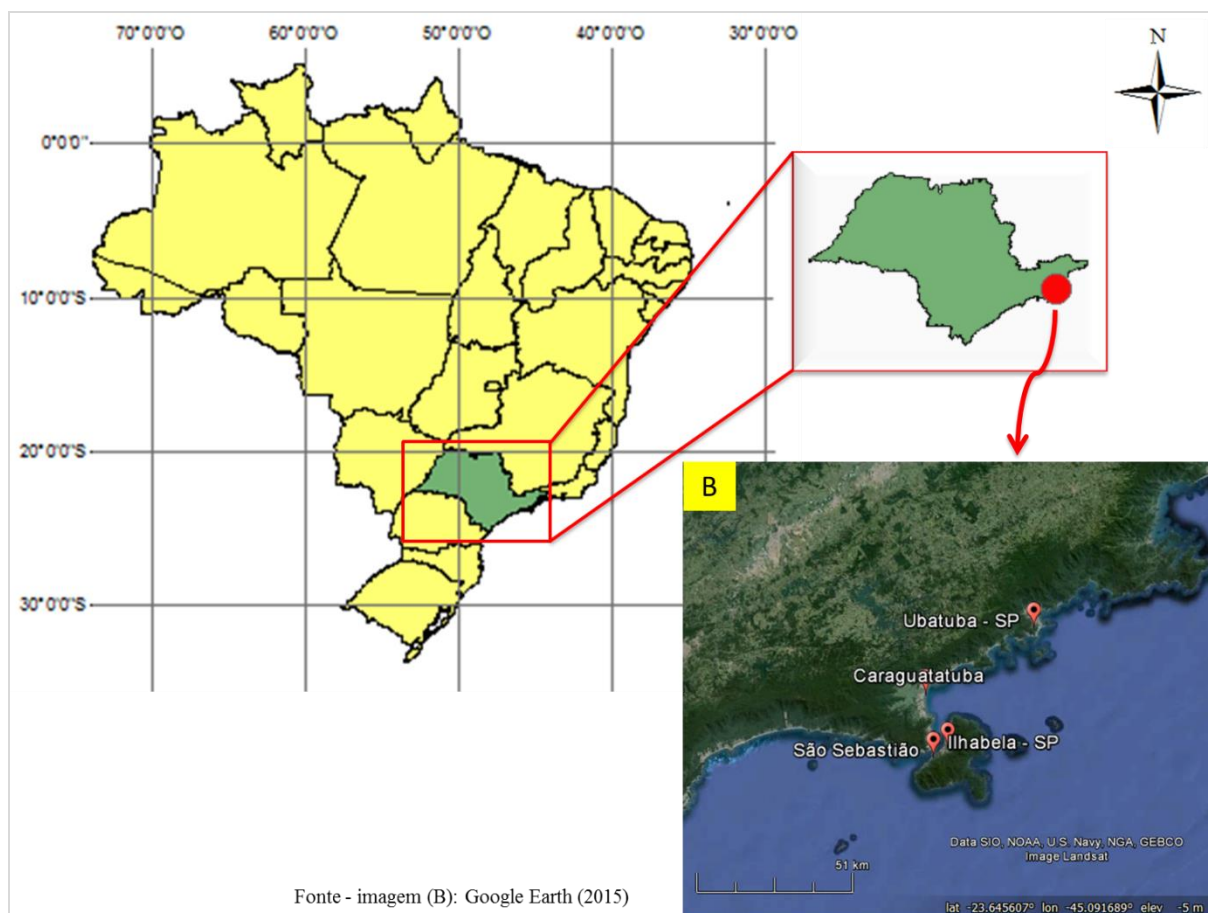


Figura 19 - Localização da área de estudo

Caraguatatuba possui 100.840 habitantes e densidade demográfica de 207,88 hab/km². A Figura 20 apresenta o gráfico de evolução populacional de Caraguatatuba. Ubatuba é o segundo município com maior população, dentre os 4, com um total de 78.801 habitantes e densidade demográfica de 108,87 hab/km²; seguido por São Sebastião – 73.942 habitantes e densidade demográfica de 185,0 hab/km². As Figuras 21e 22 apresentam o gráfico de evolução populacional de Ubatuba e São Sebastião, respectivamente. Por fim, Ilhabela possui um total de 28.196 habitantes e densidade demográfica de 81,13 hab/km²; a Figura 23 apresenta o gráfico de evolução populacional da mesma (IBGE, 2010).

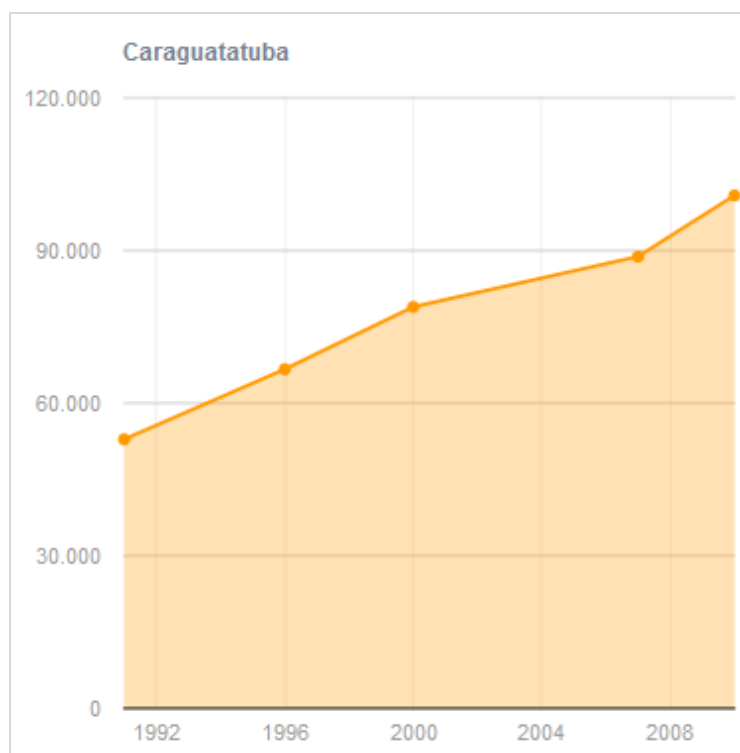


Figura 20 - Gráfico de evolução populacional em mil habitantes de Caraguatatuba entre 1990 a 2010

Fonte: IBGE (2010)




Figura 21 - Gráfico de evolução populacional em mil habitantes de Ubatuba entre 1990 a 2010
 Fonte: IBGE (2010)

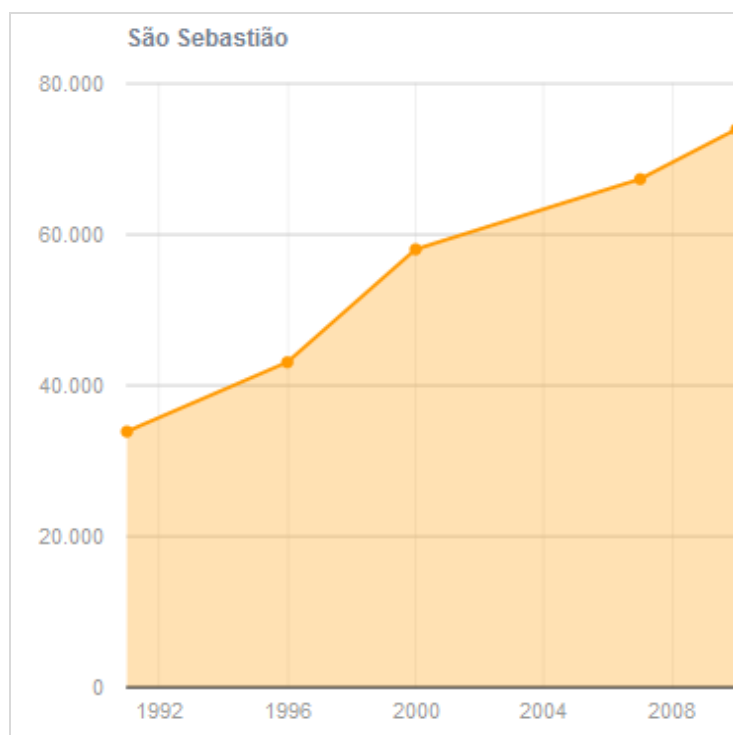


Figura 22 - Gráfico de evolução populacional em mil habitantes de São Sebastião entre 1990 a 2010
 Fonte: IBGE (2010)




Figura 23 - Gráfico de evolução populacional em mil habitantes de Ilhabela entre 1990 a 2010

Fonte: IBGE (2010)

É possível verificar-se, através dos gráficos de evolução populacional apresentados nas Figuras 20 a 23, que todos os municípios tiveram um acentuado crescimento populacional, especialmente a partir de 1996. Todavia, o relatório do Comitê de Bacias Hidrográficas do Litoral Norte (2013) ressalta que os dados apresentados não levam em consideração o fator de sazonalidade que a região sofre em função de sua vocação turística, e que o efeito desta no município impacta negativamente a demanda por recursos naturais, a forma de consumo de água, a geração de efluentes e resíduos.

O elevado crescimento populacional, associado a um modelo de turismo degradador e à falta de planejamento urbano eficiente, tem como principal consequência o agravamento de problemas como os baixos índices de saneamento básico, a ausência de um local apropriado para destinação dos resíduos sólidos, ocupação de encostas, enchentes, poluição, erosão e progradação costeira, redução dos estoques pesqueiros, entre outros, recorrentes e combatidos de forma descoordenada pelo poder público (TEIXEIRA, 2013).

Segundo o relatório da Agência Nacional das Águas – ANA, “Bacias Hidrográficas do Atlântico Sul – Trecho Sudeste” (2001), a Unidade de Gerenciamento de Recursos Hídricos do Litoral Norte – UGRHI-3 (Figura 24) – é a menor do estado de São Paulo, possuindo um

total de 1.977 km² de área de drenagem. Esta bacia é definida por vários cursos d'água que partem de diversas altitudes da Serra do Mar, em direção ao Oceano Atlântico. Devido à configuração geográfica local, as sub-bacias que compõem a UGRHI-3 correm em vales encaixados de alta declividade até desagüarem diretamente no mar ou atingirem a planície costeira.



Figura 24 - Unidade de Gerenciamento de Recursos Hídricos do Litoral Norte – UGRHI-3, que compreende os municípios de Ubatuba, Caraguatatuba, São Sebastião e Ilhabela. Escala 1:1.000.000

Fonte: Adaptado de Instituto Geográfico e Cartográfico

De acordo com a ANA (2001), a sub-bacia do rio Juqueriquerê (Figura 25), possui uma área de 429,8 km² e é a maior do Litoral Norte. Juntamente com o rio Perequê-Mirim, o curso principal forma, na praia das Frecheiras, a denominada Barra do rio Juqueriquerê. No município de Caraguatatuba, esta sub-bacia abrange o ribeirão da Aldeia, o córrego da barra, ribeirão da Divisa, o rio Camburu e seus afluentes, além dos rios: Piracununga Novo, parte do Rio Claro e Perequê-Mirim. Em São Sebastião, fazem parte desta sub-bacia, que inclui a praia da Enseada: o córrego do Cedro, bem como trechos dos rios: Claro e Perequê-Mirim, com seus respectivos afluentes. A vazão mínima garantida em 95% do tempo na Unidade de Gerenciamento de Recursos Hídricos do Litoral Norte (que abrange os municípios de

refere à pluviometria tendo o efeito orográfico enorme participação nessa dinâmica (CONTI, 1975 *apud* CARTACHO, 2013). Conforme a ANA (2001), a UGRHI-3 é fortemente influenciada pelos sistemas tropicais e polares, que atuam de forma desigual na região. Assim, o confronto entre esses dois sistemas é um dos principais fatores responsáveis pela alta precipitação pluviométrica do local em questão, cujos índices variam entre 1.371 mm (registrados em Ilhabela) e 4.731 mm (no alto da Serra do Mar). Segundo Cartacho (2013), a região apresenta totais pluviométricos com média anual superior a 4.000 mm, chegando a 6.000 mm em anos extremos. Há também a presença de “ilhas de sombra de chuvas” proporcionadas principalmente pelo maciço da Ilha de São Sebastião, que atua ao norte do homônimo e sobre a região da Enseada de Caraguatatuba. Nessas áreas, os totais pluviométricos são mais baixos (em torno de 1.800 mm).

Além disso, conforme Valentim (2012), a Zona de Convergência do Atlântico Sul (ZCAS), definida, convencionalmente, como uma persistente faixa de nebulosidade orientada no sentido noroeste-sudeste, é um fenômeno meteorológico significativo que estende-se desde o sul da Amazônia até o Oceano Atlântico Subtropical, por alguns milhares de quilômetros, bem caracterizada nos meses de verão. Observações indicam uma associação entre períodos de enchentes de verão na região sudeste e veranicos na região sul com a permanência da ZCAS por períodos prolongados sobre a região sudeste. A Figura 26 apresenta uma Zona de Convergência do Atlântico Sul em 26 de janeiro de 2004. Salienta-se a importância deste fenômeno no litoral norte de São Paulo, onde a ocorrência de longos períodos de chuva pode contribuir para variações locais do nível do mar na região.

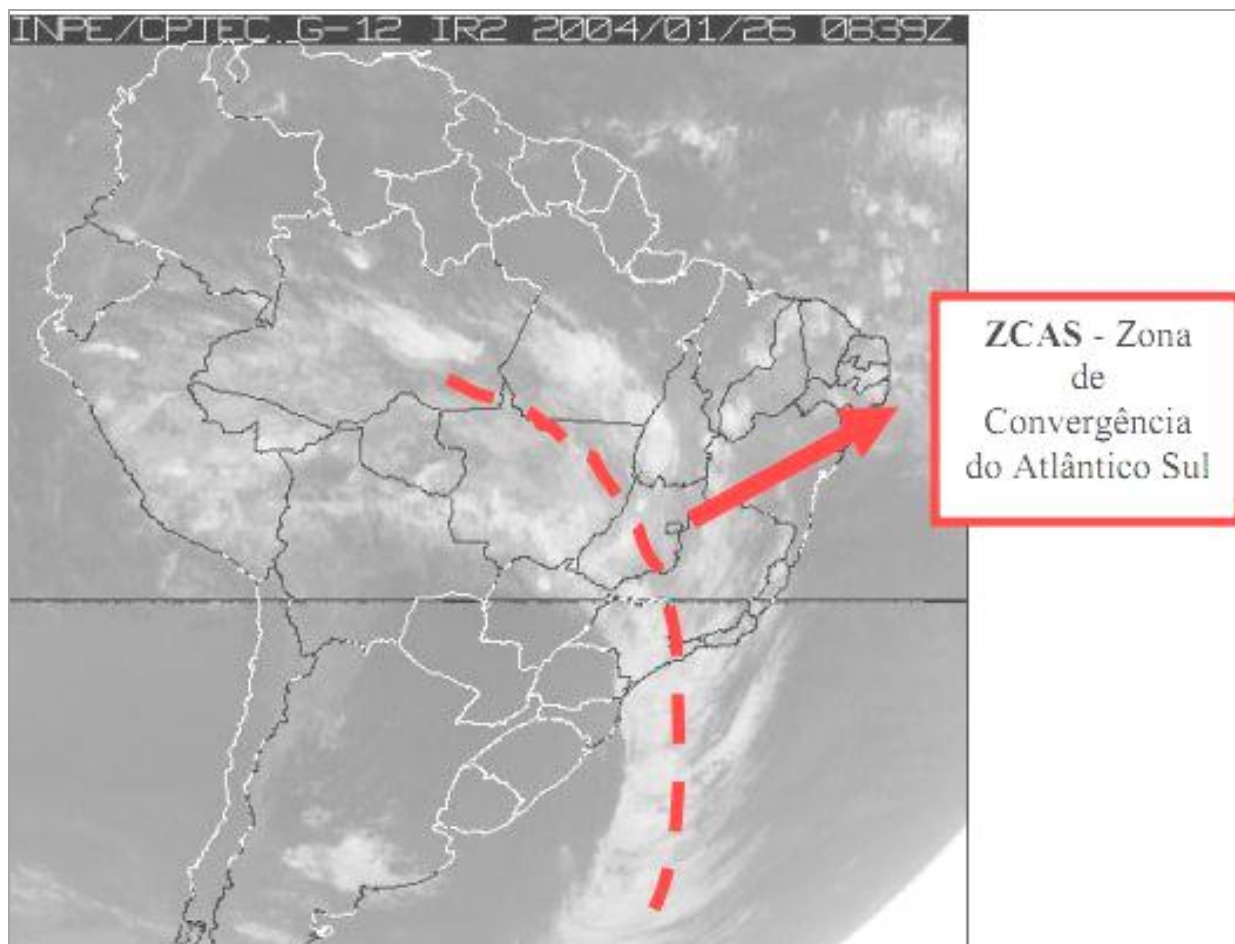


Figura 26 - Zona de Convergência do Atlântico Sul em 26 de janeiro de 2004. Imagem Infravermelho Goes-12
 Fonte: CPTEC/INPE (2004 *apud* VALENTIM, 2012)

Em 18 de março 1967, o município de Caraguatatuba foi atingido por um evento climático que ficou conhecido como “A Catástrofe”. Este causou enchentes e uma sequência de deslizamentos da Serra do Mar, decorrentes de uma anomalia positiva de precipitações. Analisando-se o referido evento, pode-se afirmar que o impacto de um evento como este provavelmente teria consequência piores caso acontecesse atualmente, devido à crescente urbanização da região (MOURA, 2013).

De acordo com Mesquita (1997), os registros típicos do marégrafo de Ubatuba caracterizam as marés locais como semidiurnas. Através dos dados de tábua de maré para o Porto de São Sebastião – São Paulo, verifica-se o mesmo comportamento semidiurno, característico do litoral do sudeste brasileiro, como exemplificado na Figura 27. Conforme os dados oriundos do SIGAM – Sistema Integrado de Gestão Ambiental, a amplitude da maré para o Porto de São Sebastião varia de 0,2 m para baixa-mar a 1,5 m para preamar, tendo

como variação média 0,66 m. Desta forma, a área de estudo é caracterizada como região de influência semidiurna da maré, sob condições de micromaré.




Figura 27 - Maré prevista (em metros) para o Porto de São Sebastião – São Paulo para os dias 05 e 06 de janeiro de 2015

4 MODELO PROPOSTO

Este capítulo visa definir o método de pesquisa empregado, fundamentando-o. Assim, o mesmo divide-se em três seções: Método de pesquisa, Amostragem e Programação das redes neurais. A primeira parte define o método de pesquisa utilizado. A segunda seção refere-se aos dados utilizados ao longo do trabalho e, por fim, refere-se ao modelo.

4.1 Método de Pesquisa

4.1.1 Definição metodológica do trabalho

De acordo com Marconi e Lakatos (2006), o presente trabalho define-se como sendo de natureza aplicada, com objetivos explicativos e normativos, pois visa compreender e testar hipóteses que descrevem o tema. A abordagem é quantitativa por elaborar um modelo matemático, qual seja, o modelo de redes neurais artificiais. A Figura 28 ilustra as fases da implementação da modelagem.

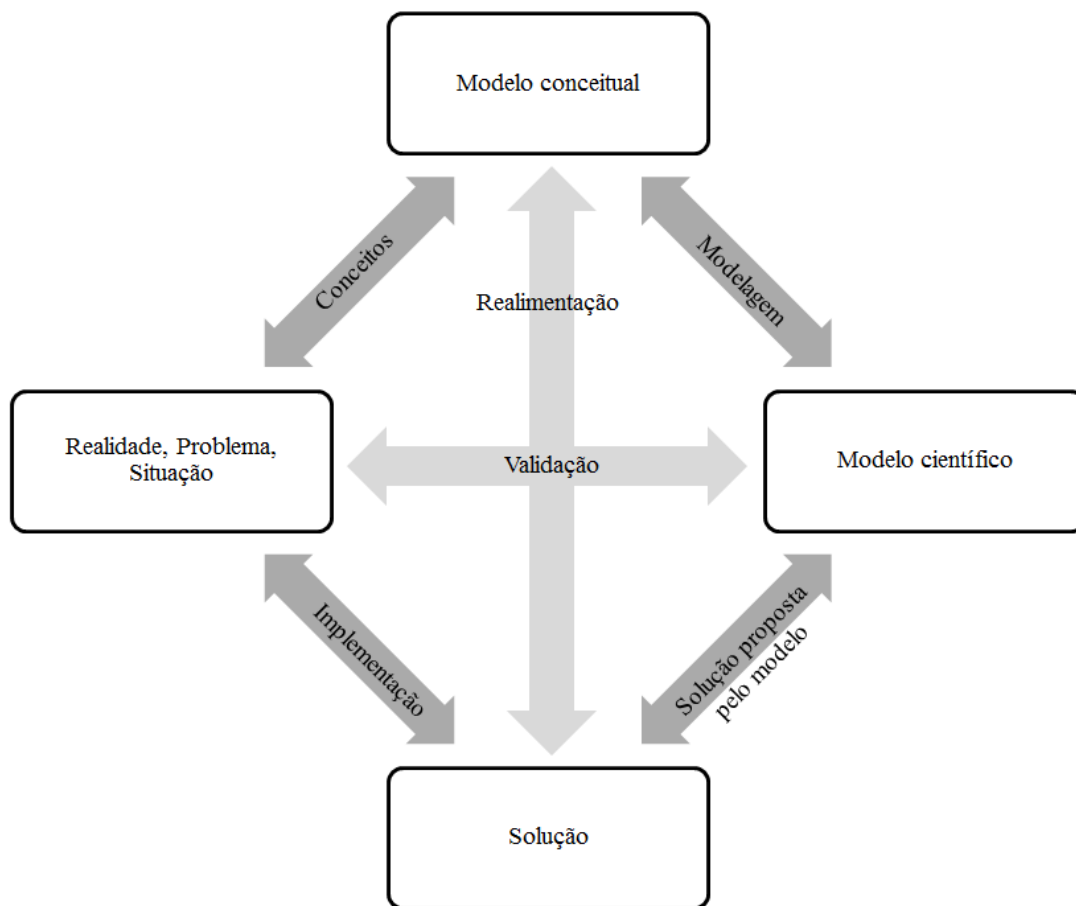


Figura 28 - Fases de uma implementação de modelagem

Fonte: Adaptado de Mitroff *et al.* (1974)

A fase inicial de implantação do método de modelagem consiste na elaboração do modelo conceitual, fase esta em que devem ser estruturadas as variáveis necessárias e suficientes a serem incluídas no modelo, levando-se em consideração o escopo da pesquisa. Na etapa de modelagem científica, são definidas as relações causais e as técnicas matemáticas apropriadas a serem empregadas. Assim, conseqüentemente, na terceira e última etapa, fase de solução, buscam-se os resultados do modelo matemático sistematizado (MARTINS *et al.*, 2014)

4.1.2 Fluxograma

Com base nessas definições, elaborou-se no presente trabalho, a organização de implementação dos procedimentos necessários, conforme descrito na Figura 29.

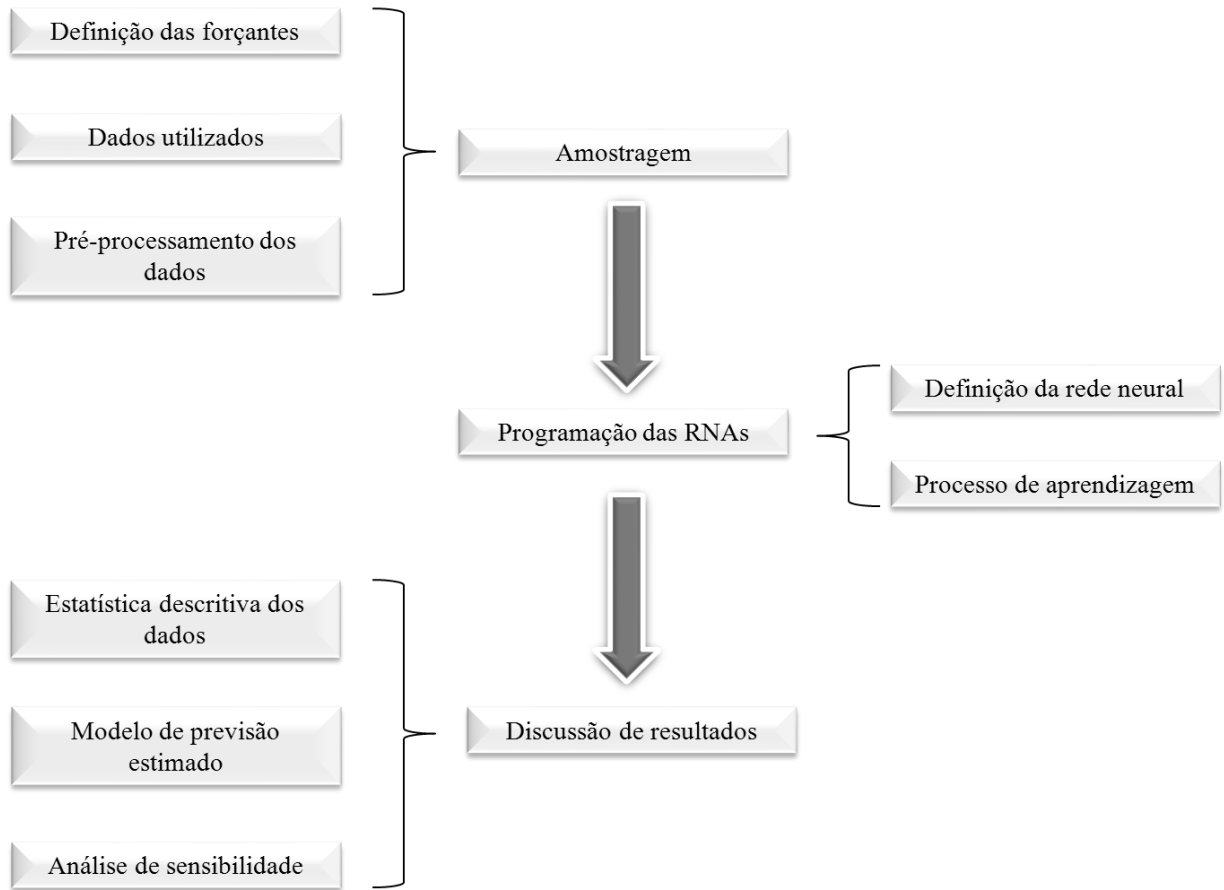


Figura 29 - Fluxograma do trabalho

A primeira etapa (Amostragem) e a segunda etapa (Programação das redes neurais artificiais) do fluxograma, representadas na Figura 29, correspondem aos modelos conceitual e científico, proposto por Mitroff *et al.* (1974), respectivamente. Já a terceira etapa (Discussão de Resultados) corresponde à fase de solução da organização proposta por esses autores para implementação da modelagem e será discutida no capítulo seguinte. Por fim, o sexto capítulo (Considerações finais) encerrará o ciclo de implementação do modelo, onde se buscará extrapolar as soluções encontradas no modelo com a realidade.

4.2 Amostragem

4.2.1 Definição das forçantes influentes no nível do mar

De acordo com a definição estatística, uma série temporal é uma coleção de dados sequenciais obtidos ao longo do tempo. É necessário definir não só o horizonte de previsão, mas também a janela a ser utilizada. Horizonte de previsão relaciona-se à quantidade de valores subsequentes que serão previstos (e pode ser classificado como de curto, médio e longo prazo), enquanto a janela utilizada diz respeito à quantidade de elementos anteriores ao que será previsto (EHLERS,1999).

Sabe-se que diversos fatores podem influenciar a variação do nível do mar em curto prazo (por exemplo, para 6 horas), principalmente quando esta variável é analisada em um ambiente costeiro. A partir dos trabalhos de Oliveira (2004), Chen (2012) e Sperb *et al.*, (2003), o presente estudo focou nas seguintes forçantes para a realização da referida análise: nível observado (m), maré astronômica (m), vento – componentes u e v (m/s), pressão atmosférica em superfície (hPa) e vazão fluvial (m³/s).

A Equação 33 representa o modelo de informação proposto no presente trabalho para representar a dinâmica do nível do mar no litoral norte de São Paulo, com base nas forçantes supracitadas. Salienta-se que, independentemente da maneira com que as forçantes (maré astronômica e variáveis meteorológicas) foram mensuradas pela base de dados, elas são chamadas no contexto de RNA de “observadas” quando são utilizadas como insumos para se prever a variável foco de estudo – chamada de prevista. Isto é, a RNA assume que os dados dos insumos correspondem aos reais e então analisa como estes permitem prever a variável foco de estudo (dito prevista).

$$NM_{(t+6)} = f \left(\begin{array}{c} NM_t, MA_t, Vu_t, Vv_t, PS_t, Q_t, NM_{(t-6)}, MA_{(t-6)}, Vu_{(t-6)}, Vv_{(t-6)}, PS_{(t-6)}, Q_{(t-6)}, \\ MA_{(t+6)}, Vu_{(t+6)}, Vv_{(t+6)}, PS_{(t+6)} \end{array} \right) \quad (33)$$

Sendo:

$NM_{(t+6)}$ = nível do mar a ser estimado após 6 horas

NM_t = nível do mar observado

MA_t = nível da maré astronômica observada

Vu_t e Vv_t = componentes ortogonais do vento observados

PS_t = pressão atmosférica em superfície observada

Q_t = vazão fluvial observada

$NM_{(t-6)}$ = nível do mar observado 6 horas antes

$MA_{(t-6)}$ = nível da maré astronômica observada 6 horas antes

$Vu_{(t-6)}$ e $Vv_{(t-6)}$ = componentes ortogonais do vento observados 6 horas antes

$PS_{(t-6)}$ = pressão atmosférica em superfície observada 6 horas antes

$Q_{(t-6)}$ = vazão fluvial observada 6 horas antes

$MA_{(t+6)}$ = nível da maré astronômica estimada (dado obtido através de modelagem, conforme especificado na Tabela 1 – item 4.2.2)

$Vu_{(t+6)}$ e $Vv_{(t+6)}$ = componentes ortogonais do vento estimado (dado obtido através de modelagem, conforme especificado na Tabela 1 – item 4.2.2)

$PS_{(t+6)}$ = pressão atmosférica em superfície estimada (dado obtido através de modelagem, conforme especificado na Tabela 1 – item 4.2.2)

4.2.2 Dados Utilizados

O período utilizado para os dados deste trabalho vai de 01 de janeiro de 2013 a 15 de agosto de 2013 para o nível do mar; 31 de janeiro de 2013 a 31 de julho de 2013 para os dados de vento, pressão atmosférica em superfície e maré astronômica. Os dados de cota do rio Camburu foram disponibilizados de forma não regular com uma medida por mês sendo que nem todos os meses possuem medidas, de 1960 a 1967. Nesse caso, foram estimadas médias mensais históricas; como alternativa à escassez de dados de vazão disponíveis para a região em questão. As fontes para obtenção desses dados estão descritas na Tabela 1.

Tabela 1 - Fontes de obtenção dos dados

Dado		Local	Período	Fonte
Vazão - Cota	Média mensal histórica	Estação Camburu - Caraguatatuba - SP	1960 a 1967	DAEE (Disponível em: http://hidroweb.ana.gov.br/HidroWeb.asp?TocItem=1080&TipoReg=7&MostraCon=true&CriaArq=false&TipoArq=0&SerieHist=true)
Vazão - Curva Chave	Gerada	Estação Camburu - Caraguatatuba - SP	2012 e 2013	Boulomytis (2014)
Maré Astronômica	Modelado	Porto de São Sebastião - SP	01/01 a 15/08/2013	Tábua de marés do Centro de Hidrografia da Marinha (Disponível em: http://www.mar.mil.br/dhn/chm/box-previsao-mare/tabuas/)
Vento	Modelado	Lon:-45.4275584365 e Lat:-23.7077004024	31/01 a 16/07/2013	Dados da reanálise do ERA Interim (Disponível em: http://apps.ecmwf.int/datasets/data/interim-full-daily/levtype=sfc/)
Pressão em superfície	Modelado	Lon:-45.4275584365 e Lat:-23.7077004024	31/01 a 16/07/2013	Dados da reanálise do ERA Interim (Disponível em: http://apps.ecmwf.int/datasets/data/interim-full-daily/levtype=sfc/)
Nível do mar	Observado	Ubatuba - SP	01/01 a 15/08/2013	IOUSP

A Tabela 2, a seguir, apresenta o descritivo dos dados de cota do Camburu

Tabela 2 - Descritivo do ponto de coleta de dados de cota do Rio Camburu

Nome	Camburu
Bacia	Atlântico, Trecho Sudeste (8)
Rio	Rio Camburu
Estado	São Paulo
Município	Caraguatatuba
Responsável	DAEE-SP
Área de Drenagem (km ²)	125

Fonte: DAEE - disponível no site Hidroweb – conforme tabela 1

A Figura 30 indica os locais (coordenadas geográficas) das estações que originaram os dados, conforme Tabela 1.




Figura 30 - Localização das coletas de dados

Fonte: Google Earth (2016)

A partir da Figura 30, é possível verificar-se a proximidade das estações de onde foram extraídos os dados, garantindo-se, portanto, a representatividade destes para a previsão do nível do mar no litoral norte de São Paulo.

Conforme descrito no site de tábuas de Maré da Marinha do Brasil, as previsões elaboradas no Centro de Hidrografia da Marinha (CHM) são geradas a partir das componentes harmônicas (ondas sinusoidais com frequência determinada pelo efeito exclusivo da ação de forças astronômicas e que compõem a onda de maré) obtidas das observações realizadas por diversas instituições, através do método de análise harmônica desenvolvido pelo Vice-Almirante Alberto dos Santos Franco. Para cada componente de maré, estão associadas as suas constantes harmônicas, h (amplitude da componente no local) e g (diferença de fase da componente real em relação a componente teórica). As previsões apresentadas nas Tábuas das Marés não considerando os efeitos meteorológicos sobre o nível do mar, os quais não podem ser previstos deterministicamente.

Os dados de vento e pressão atmosférica em superfície foram obtidos através do ERA-Interim que é o mais recente reanálise atmosférica global produzida pelo Centro Europeu de Previsão do Tempo a médio prazo (ECMWF). São discretizados espacialmente em uma grade de $0,75 \times 0,75$ graus de latitude \times longitude. O ponto selecionado foi escolhido de acordo com a proximidade da desembocadura do estuário do rio Juqueriquerê. Os dados de velocidade do vento foram estimados para uma altitude de 10 metros. Foram baixados dados de intensidade do vento em duas direções: U, componente perpendicular à costa e V, paralela à costa. Em seu trabalho, Oliveira (2004), concluiu que os dados de reanálise mostraram que, além de traduzirem melhor as variações dos fenômenos atmosféricos em baixas frequências na área oceânica, são uma fonte eficaz de informação em regiões onde a carência de dados ainda é substancial.

Para se saber quais as intensidades dos ventos paralelos (para a região, aproximadamente ventos nordeste e sudoeste) e perpendiculares à costa (noroeste e sudeste), é necessário realizar-se uma rotação do sistema de coordenadas, em torno em 50 graus (VALENTIM *et al.*, 2013).

4.2.3 Pré-processamento dos dados

Inicialmente, efetuou-se a filtragem numérica da série de dados de nível do mar conforme descrito no item 4.2.3.1. Os dados de vento (componentes u e v) e de pressão atmosférica em superfície foram coletados nos intervalos de 0, 6, 12 e 18h através do ERA Interim (Tabela 1). Para os dados de vento, realizou-se uma rotação do sistema de coordenadas, de 50 graus em sentido horário (conforme definido no item 4.2.2).

Cumprе salientar que a quantidade de dados utilizada nas séries de vento (ambos componentes) e pressão atmosférica em superfície, assim como dos dados de maré astronômica e vazão, foi determinada através da quantidade de dados gerados na série de nível do mar após aplicação do filtro numérico, de forma a parear todos os dados utilizados no presente trabalho.

Os dados de vazão e maré astronômica foram gerados conforme descrito nos itens 4.2.3.2 e 4.2.3.3, respectivamente.

4.2.3.1 Filtragem numérica da série de nível do mar

Conforme Costa (2007), os filtros numéricos atenuam a quantidade de energia em certas faixas de frequência. Ou seja, em séries temporais, um filtro separa, no domínio do tempo, ruído ou interferência e distingue e/ou separa baixas e altas frequências ou frequências especiais (MENEZES, 2007). De acordo com Costa (2010), os filtros são classificados quanto à posição das frequências de corte, sendo eles: passa-baixa – atenuam oscilações acima da frequência de corte; passa-alta – atenuam oscilações abaixo da frequência de corte e passa-banda – atenuam oscilações fora do intervalo de frequência pré-determinado. Podem, ainda, ser subdivididos em filtros digitais e analógicos, diferenciando-se pelo tipo de tratamento dado aos registros de entrada durante o processo de filtragem.

As oscilações do nível do mar, neste contexto, se caracterizam como fenômenos de longo período e, portanto, de baixa frequência. Assim, em uma série de nível do mar, é imprescindível a atenuação das oscilações causadas por fenômenos de “alta” frequência, tais como as marés diurnas, semidiurnas e terdiurnas. Esse processo dá-se, então, pelo emprego de um filtro passa-baixa.

O filtro utilizado neste trabalho corresponde ao filtro passa-baixa de Lanczos, desenvolvido por Lanczos em 1956. Em seu trabalho, Valentim (2012) cita autores que indicaram o filtro de Lanczos como eficiente, tais como:

- Duchon (1979) – demonstrou a simplicidade da utilização do filtro de Lanczos, comparou a resposta do filtro Lanczos com outros tipos de filtros e estendeu esta análise para duas dimensões. Concluiu que a simplicidade do cálculo e a resposta adequada do filtro Lanczos o tornam um método de filtragem interessante;
- Walters e Heston (1982) – exemplificaram através de fórmulas e gráficos a resposta da aplicação deste filtro numa análise de dados a partir da fundamentação matemática do método do filtro Lanczos;
- Dottori e Castro (2009) realizaram um estudo para analisar a resposta dos ventos sinóticos na Plataforma Continental de São Paulo.

Segundo Menezes (2007), a filtragem numérica de uma série temporal pode ser feita a partir da convolução da série original, $x(t)$, e a função filtro passa-baixa, $w(t)$, transformando a série original em uma série de valores médios $y(t) \rightarrow \hat{y}(t) = w(t) * x(t)$, cujos valores y , discretizados, devem ser iguais a $2N+1$ pesos, $w(k)$.

Através de Mesquita (1997), inferiu-se que as componentes harmônicas são as mesmas, ao longo da região costeira do sudeste brasileiro. Desta forma, as componentes harmônicas locais foram baseadas em Costa (2010) que analisou a influência das tensões do vento na variação do nível médio do mar na região costeira de Cananéia (SP) através de filtragem numérica e análise espectral (Tabela 3).

Tabela 3 - Constantes harmônicas das constituintes de marés de Cananéia e de Ubatuba calculadas a partir de registros horários do ano de 1978 e utilizadas para a filtragem numérica da série de nível do mar do litoral norte de São Paulo. As colunas apresentam: primeira coluna – nome da constituinte; segunda – a frequência angular; na terceira – a frequência angular em hertz, na quarta – a amplitude; na quinta – o desvio padrão da amplitude; na sexta – o ângulo de fase; na sétima – o ângulo de fase em relação ao meridiano de *Greenwich* (Inglaterra) e, na oitava – o desvio padrão do ângulo de fase da componente. Todas as constantes foram determinadas com intervalos de intervalos de confiança estatística de 95%

Constantes	Frequência (°/hora)	Frequência (10⁻⁵ Hz)	H (cm)	DPH	G°	GW°	DPG
P1	14,95893	1,154	2,3	0,2	146,8	191,6	7,1
S1	15,00000	1,157	1,7	0,2	125,8	170,8	9,3
MU2	27,96821	2,158	2,3	0,2	151,8	235,7	7,4
Q1	13,39866	1,034	3,1	0,2	61,0	101,2	5,2
O1	13,94307	1,076	11,0	0,3	81,6	123,4	1,5
K1	15,04107	1,161	6,5	0,2	145,5	190,6	2,5
N2	28,43973	2,194	5,6	0,3	161,8	247,1	3,1
M2	28,98410	2,236	36,6	0,3	92,3	179,2	0,4
S2	30,00000	2,315	23,7	0,3	94,2	184,2	0,7
K2	30,08214	2,321	7,6	0,3	85,0	175,3	2,3
MO3	42,92714	3,312	5,3	0,3	21,6	150,4	4,1
M3	43,47616	3,355	8,1	0,3	233,8	4,2	2,7
MK3	44,02517	3,397	2,7	0,3	138,5	270,6	8,0
MN4	57,42383	4,431	3,4	0,2	157,4	329,7	4,3
M4	57,96821	4,473	7,0	0,2	208,0	21,9	2,1
MS4	58,98410	4,551	3,5	0,2	314,4	131,4	4,2

Fonte: Mesquita (1997)

Conforme Costa (2010), as componentes P₁, S₁, Q₁, O₁ e K₁ são ditas diurnas (com períodos de cerca de 24 horas e 50 minutos), sendo a S₁ a principal componente solar, enquanto as componentes Mu₂, N₂, M₂, S₂ e K₂ são ditas semidiurnas (com períodos de cerca de 12 horas 25 minutos). Já as componentes MO₃, M₃, MK₃, MN₄, M₄ e MS₄ são harmônicos das constituintes diurnas e semidiurnas e resultam da influência da costa na deformação da onda de maré, sendo o atrito com a costa – tanto das margens como do fundo, uma das principais causas.

A Figura 31 apresenta o gráfico com a série de nível do mar registrada no marégrafo IOUSP (conforme Tabela 1) e a série de nível do mar gerada após aplicação do filtro de Lanczos.




Figura 31 – Série de nível do mar registrada pelo marégrafo IOUSP e série de nível do mar gerada após aplicação do filtro de Lanczos

Foi aplicada a filtragem com o filtro cosseno de Lanczos, com 241 pesos ($2N+1$ pesos, em função da simetria), com o limite de comprometimento de 60 dias de dados. Ao todo, foram utilizados 905 dados (01/01/2013 a 15/08/2013 – 0:00 h); após a aplicação do filtro houve uma perda de 240 dados inerente ao processo de convolução e devido à janela de pesos utilizada, sendo 120 dados no começo e 120 dados no final da série temporal. Portanto, a série de nível do mar gerada possui 665 dados de nível do mar, dispostos nos horários de 0, 6, 12 e 18 horas (pareados com os demais dados). Através da Figura 31 é perceptível a atenuação das oscilações de alta frequência.

4.2.3.2 Geração dos dados de vazão

Uma curva-chave de vazão estabelece a relação entre a altura da lâmina de água de um rio com a sua vazão. Como não haviam dados de vazão suficientes para se obter uma série temporal, para o rio Juqueriquerê, houve a necessidade de uma improvisação para gerar dados de vazão fluvial utilizáveis. Como descrito anteriormente, foram utilizados dados secundários do DAEE no período de 1960 a 1967, para a estação Camburu – afluente com uma das maiores contribuições de aporte fluvial do rio Juqueriquerê; foi realizada uma média dos dados para cada mês, gerando, conseqüentemente, doze médias mensais de cota. Para cada um dos doze valores, foi utilizada a curva-chave de vazão de Boulomytis *et al.* (2014) obtendo-se, conseqüentemente, doze valores de vazão, cada um relativo a um mês do ano, a fim de se garantir uma estimativa da variação mensal dessa forçante. Replicou-se, na seqüência, cada valor para todos os dias do respectivo mês para os anos de 2013, 2014 até agosto de 2015, gerando, portanto, uma série histórica com médias mensais de vazão fluvial.

Através da Tabela 4, é feito um comparativo entre os dados de vazão gerados e utilizados no presente trabalho e os dados de vazão medidos in loco, apresentados por Boulomytis *et al.* (2014).

Tabela 4- Comparativo entre as vazões médias mensais (utilizadas no presente trabalho) e vazões levantadas nas campanhas hidrológicas do estudo de Boulomytis *et al.* (2014). A linha cinza mais escura corresponde à campanha realizada no período chuvoso no sudeste. O dado em vermelho corresponde a um valor anômalo

Estação Camburu				
Boulomytis <i>et al.</i> (2014)		Média mensal histórica		
Data da medição	Vazão (m³/s)	Mês	Vazão média mensal (m³/s)	Característica
01/05/2012	20,04	mês 05	7,99	seco
30/05/2012	5,76	mês 05	7,99	seco
04/02/2013	25,73	mês 02	14,69	chuvoso
01/05/2013	8,83	mês 05	7,99	seco

Conforme Boulomytis *et al.* (2014), no dia 30/04/2012 choveu durante todo o dia impossibilitando a medição na estação Camburu, que, assim, foi realizada no dia seguinte (01/05/2012); esta vazão corresponde à vazão destacada (em vermelho). O fato de ter chovido durante todo o dia anterior a esta medição torna o valor de vazão encontrado muito superior

ao que seria esperado para o período (característico de estiagem) e, portanto, um valor anômalo. As outras duas medições realizadas no mês de maio dos anos de 2012 e 2013 apresentam valores entre 5 e 9 m³/s, e a média destes corresponde a 7,15 m³/s; assim, o valor médio mensal utilizado para os meses de maio representa de maneira satisfatória a realidade local.

Ainda de acordo com Boulomytis *et al.* (2014), choveu intensamente entre 24 e 31 de janeiro de 2013, quando passou a cessar, gerando a maior tomada de valores nessa campanha. Apesar de não haver um pluviômetro na cabeceira do rio Camburu, segundo dados do Radar São Roque (disponível em <http://sigma.cptec.inpe.br/radar/>), havia precipitação nessa região, tornando o volume de águas muito representativo nessa estação.

4.2.3.3 Interpolação dos dados de maré astronômica

A tábua de marés também não apresenta um padrão para os dados disponibilizados, pois os extremos (preamar e baixamar) apresentam variações, podendo ocorrer dias com apenas três extremos (duas baixamar e uma preamar e vice-versa) e outros com cinco, por exemplo. Desta forma, foi elaborada uma planilha com a interpolação dos dados, para os horários de 0, 6, 12 e 18h (conforme gráfico apresentado na Figura 32).




Figura 32- Série temporal de dados de maré astronômica gerada após interpolação dos dados de maré astronômica disponibilizados pela Marinha do Brasil.

4.3 Programação das RNAs

Para a implementação das RNAs, utilizou-se o *software* Statistica 13, versão *Automated Network Search* (ANS). Alguns parâmetros de aprendizagem são automaticamente utilizados, tal como os algoritmos de aprendizagem supervisionada, que para as estruturas de rede do tipo MLP correspondem à técnica BFGS e para as estruturas de rede RBF condizem com a técnica RBFT. As variáveis independentes (todas, com exceção do nível do mar previsto para 6 horas) são de natureza contínua, e, por tal característica, utilizou-se a opção regressão.

Como em quase todas as amostras (com exceção da maré astronômica e vazão fluvial) verificaram-se valores omissos, definiu-se na programação a eliminação desses dados para a

modelagem. Além disso, definiu-se uma proporção de 70% da amostra para treinamento, 15% para teste e os 15% restantes para validação da rede.

4.3.1 Definição da rede neural

Foram testadas tanto as redes MLP quanto as redes RBF. No primeiro caso, em que é possível definir os tipos de funções de ativação, foram selecionadas as seguintes:

- ✓ Identidade
- ✓ Logística
- ✓ Tangente hiperbólica
- ✓ Exponencial
- ✓ Seno

Deve-se acrescentar que por limitação do *software* utilizado, as estruturas de rede do tipo MLP são definidas com apenas uma camada oculta. No caso das redes RBF, a função de ativação é a Gaussiana e, por definição, esta rede possui apenas uma camada oculta.

4.3.2 Processo de aprendizagem

Com a finalidade de testar um grande número de estruturas de rede – aumentando assim a probabilidade de obter uma rede com bom desempenho representativo da dinâmica do nível do mar – definiu-se o intervalo de 5 a 40 neurônios na camada oculta tanto das estruturas de rede do tipo MLP como das estruturas de rede do tipo RBF. Adicionalmente, ressalta-se que foram testadas 1000 estruturas de redes neurais artificiais.

Dentre todos os testes realizados, foram selecionadas as 5 melhores estruturas de rede, sendo que, a utilização combinada destas 5 estruturas aumenta a consistência do modelo de previsão – ao aprimorar o desempenho de previsão do nível do mar.

Destaca-se que é utilizado como critério de desempenho a correlação dos resultados estimados com os valores reais e, simultaneamente, o erro de estimação – sendo que, é adotada a soma dos quadrados dos erros como medida de erro (erro SOS). Esses critérios são

utilizados nas três etapas de aprendizagem: teste, treinamento e validação. Além disso, como informação complementar, calculou-se mais uma medida de erro para as 5 estruturas de rede selecionadas e para o resultado combinado destas, denominada *Root Mean Squared Error* – RMSE – apresentada na Equação 34 e com unidades em metros. Um valor RMSE igual a zero implica em não haver erros entre os dados em comparação.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (NM - \widehat{NM})^2}{n}} \quad (34)$$

Sendo:

NM = nível do mar observado (m)

\widehat{NM} = nível do mar estimado pela RNA (m)

n = tamanho da amostra

Por fim, é importante ressaltar que na fase de teste adotou-se o número 1000 como semente aleatória de inicialização – número *default* do *software*. Este procedimento viabiliza a replicação do presente estudo, pois a semente aleatória permite reproduzir a mesma quantidade de testes anteriores.

5 DISCUSSÃO DE RESULTADOS

Este capítulo exibirá a estatística descritiva dos dados utilizados; o modelo de previsão estimado e a análise de sensibilidade das forçantes no processo de inferência do nível médio do mar.

5.1 Estatística descritiva dos dados

A partir das amostras geradas para cada uma das forçantes realizou-se a estatística descritiva das mesmas, conforme Figuras 33 a 38. Cumpre salientar que de acordo com Triola (2008), os *outliers* são determinados por um critério específico que usa o intervalo interquartil $IIQ = Q_3 - Q_1$. O valor IIQ pode, então, ser usado para a identificação de *outliers* como segue: um valor é considerado um *outlier* se ele está acima de Q_3 por uma quantidade maior do que $1,5 \times IIQ$ ou abaixo de Q_1 por uma quantidade maior do que $1,5 \times IIQ$.

Conforme Triola (2008), o teste de Anderson-Darling é utilizado para determinar se uma série de dados atende à suposição de normalidade. Quando o valor-p encontrado for menor que 0,05 há evidências para afirmar-se que uma amostra não segue uma distribuição normal.




Figura 33 - Estatística descritiva dos dados de maré astronômica (valores em metros)

A Figura 33 apresenta a estatística descritiva dos dados coletados para a forçante maré astronômica. Com base nesta, pode-se atestar que a média e o desvio padrão da altura da maré para a região é de aproximadamente 0,67 m e aproximadamente 0,22 m, respectivamente.

Efetuuou-se o teste de Anderson-Darling, considerando-se o nível de significância de $\alpha=5\%$, com a finalidade de verificar-se a hipótese de normalidade do referido conjunto de dados. Na medida em que a probabilidade de estatística de teste (valor-p) foi da ordem de 0,005, há evidências para afirmar que a frequência de maré não segue uma distribuição normal. Tal fato impacta na adoção da técnica de RNA que, justamente, ganha importância quando a distribuição dos dados se afasta da normal, pois as redes neurais são adequadas neste contexto.

A partir do *boxplot*, pode-se constatar que no conjunto de dados de maré astronômica não há presença de *outliers*. Tal conclusão, em parte, possui relação com o fato de serem valores derivados da mecânica celeste, sem ocorrência de qualquer evento anômalo no período.

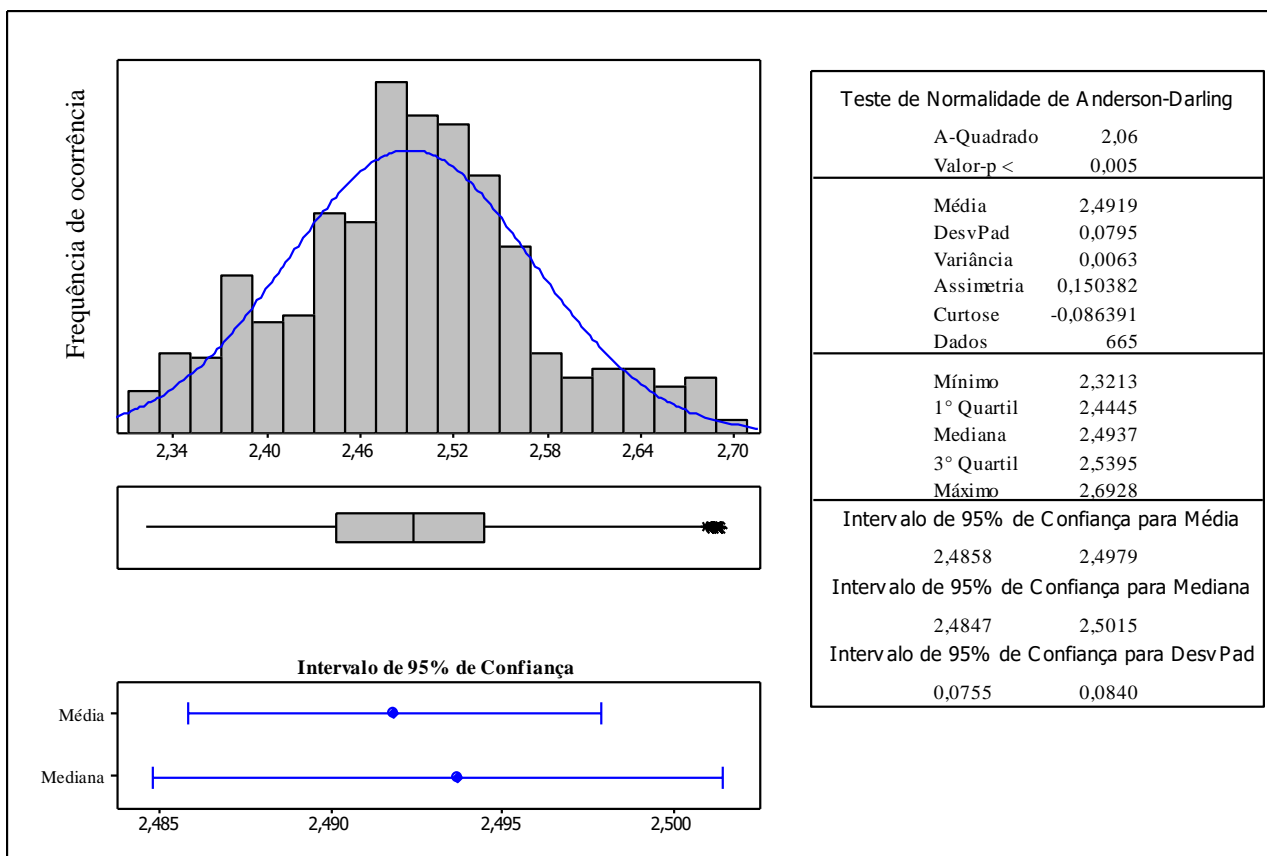


Figura 34 - Estatística descritiva dos dados de nível do mar (valores em metros)

A estatística descritiva dos dados de nível do mar é apresentada na Figura 34. De acordo com esta, podem-se verificar variações de aproximadamente 2,49 m para o nível médio e aproximadamente 0,08 m de desvio padrão para a amostra.

O teste de Anderson-Darling foi aplicado com um nível de significância $\alpha=5\%$ para verificar-se a normalidade da frequência de nível do mar. O valor-p encontrado foi inferior a 0,005 e, portanto, há evidências para afirmar-se que esta não segue uma distribuição normal.

Analisando-se o *boxplot* exposto verifica-se a presença de *outliers*. Conforme a definição de Triola (2008) estipula que um valor correspondente a $1,5 \times$ IIQ acima do 3° Quartil corresponde a um *outlier*. Considerando-se que aplicando-se filtro de Lanczos e, consequentemente, retirando-se as oscilações de alta frequência da série de nível do mar, os valores interquartis tornaram-se muito próximos (diferença interquartil de 0,095) e, assim, alguns valores de nível do mar, mesmo que esperados por serem compatíveis com a amostra de dados para a região são estatisticamente definidos como *outliers*.




Figura 35 - Estatística descritiva dos dados da componente u do vento (valores em m/s)

A Figura 35 apresenta a estatística descritiva do conjunto de dados da componente u do vento (componente perpendicular à costa). Para os valores de média e desvio padrão encontrou-se -1,19 m/s aproximadamente e aproximadamente 2,64 m/s, respectivamente.

Através da aplicação do teste Anderson-Darling, com nível de significância $\alpha=5\%$, encontrou-se um valor-p menor que 0,005. Assim, há evidências para afirmar que trata-se de uma amostra que não segue uma distribuição normal, reafirmando a adequada utilização da técnica de RNA para a previsão do nível do mar.

Há no *boxplot* a presença de *outliers*. Esse fato pode estar relacionado com a presença de valores extremos reais, característica condizente com a forte ventos, sujeito a ocorrência de rajadas. Optou-se por manter esses valores extremos na amostra utilizada de forma a analisar-se como os valores extremos da componente perpendicular da forte vento podem influenciar na previsão do nível do mar.




Figura 36 - Estatística descritiva dos dados da componente v do vento (valores em m/s)

A Figura 36 apresenta a estatística descritiva dos valores de vento, componente v (paralelo à costa). Para a média da amostra encontrou-se um valor de aproximadamente -0,96 m/s e para o desvio padrão da amostra encontrou-se um valor de aproximadamente 3,23 m/s.

No teste Anderson-Darling aplicado, com um nível de significância $\alpha=5\%$, encontrou-se um valor-p igual a 0,015; desta forma, há evidência de um padrão de distribuição não normal.

No que tange a existência de valores extremos, pode-se perceber a presença de *outliers* no *boxplot*. Assim, remete-se às mesmas possíveis justificativas da componente paralela do vento e, portanto, optou-se por manter esses valores na amostra estudada.




Figura 37 - Estatística descritiva dos dados de Pressão Atmosférica de Superfície (valores em hPa)

A estatística descritiva do conjunto de dados de pressão atmosférica em superfície apresentou um valor de média de 998,50 hPa e um valor de desvio padrão de 4,02 hPa, como pode-se verificar na Figura 37.

Foi aplicado o teste de Anderson-Darling, com nível de significância $\alpha = 5\%$, para a amostra, resultando em um valor-p igual a 0,479. Assim, não há evidências para concluir-se que esta distribuição não segue um padrão normal de distribuição.

Verifica-se a presença de *outliers* no *boxplot* apresentado na Figura 37. Por se tratar de dados de pressão atmosférica em superfície, bem como os dados de vento, a existência de valores extremos na amostra é esperada e manter-se esses valores na amostra submetida a modelagem visa garantir a proximidade com o comportamento real dessas forçantes e suas relações com a variação do nível do mar.

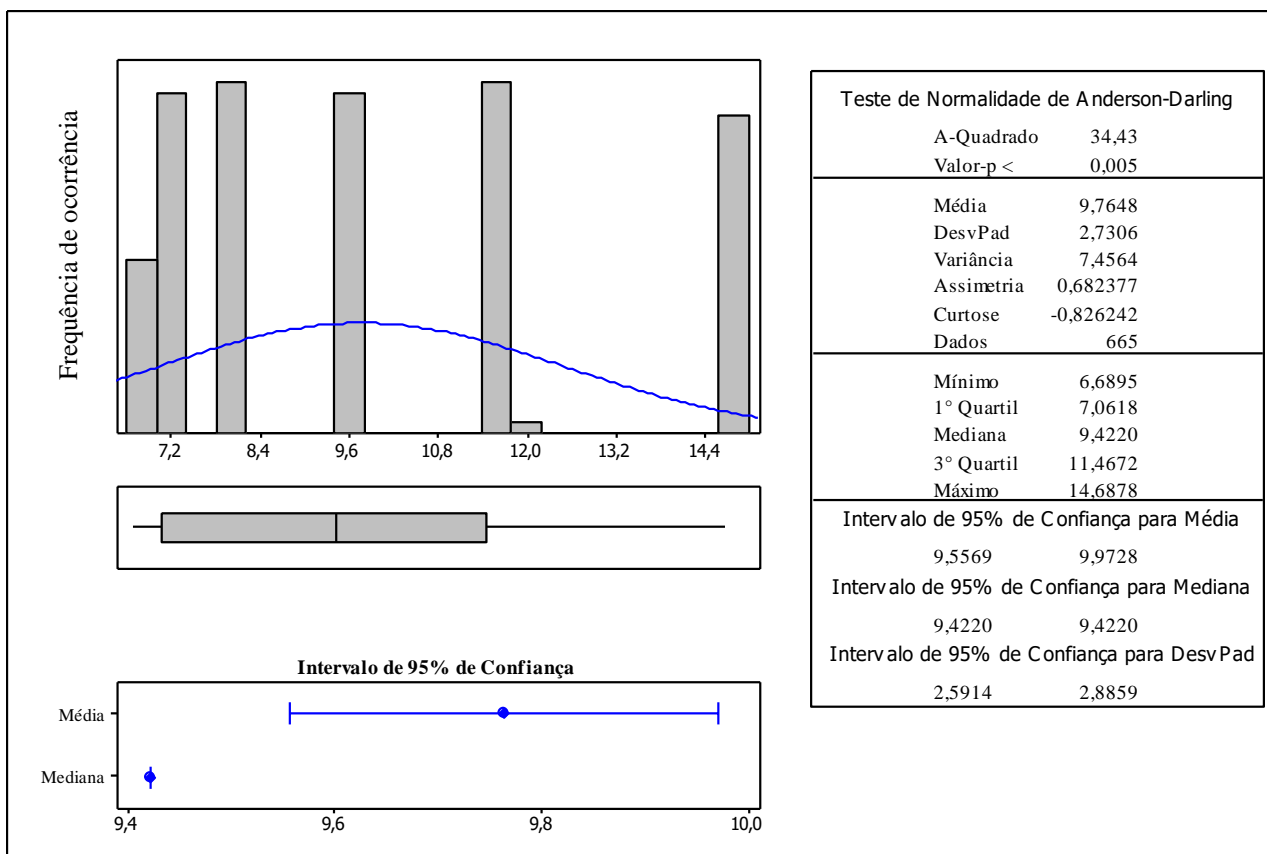


Figura 38 - Estatística descritiva dos dados de vazão (valores em m³/s)

Por fim, analisou-se a estatística descritiva dos dados de vazão fluvial, apresentados da Figura 38. O valor de média da amostra corresponde a aproximadamente 9,77 m³/s e o valor de desvio padrão da amostra corresponde a aproximadamente 2,73 m³/s.

Na aplicação do teste Anderson-Darling, com nível de significância $\alpha=5\%$, encontrou-se um valor-p menor que 0,05; assim, há evidências para se afirmar que estes dados não seguem uma distribuição normal.

A ausência de *outliers* no *boxplot* relaciona-se com a forma com que foi gerada a série de vazão fluvial, tratando-se de um valor médio para cada mês replicado a todos os horários analisados de cada dia do referido mês, conforme explicitado no item 4.2.3.

5.2 Modelo de previsão estimado

A Figura 39 ilustra a arquitetura das RNAs com as variáveis de entrada, descritas anteriormente (Equação 33), que influenciam o processo físico modelado.




Figura 39 - Arquitetura da RNA

Fonte: Adaptado de Oliveira (2004)

Nota-se que são 16 variáveis de entrada no modelo. A variável de saída, que corresponde à previsão do nível do mar, é definida como $NM_{(t+6)}$ onde “t+6” indica que é uma previsão para 6 horas à frente. Desta forma, pode-se inferir que as forçantes descritas com o tempo “t+6” correspondem às entradas no modelo com o respectivo passo de tempo (variáveis oriundas de modelagens e, portanto, 6 horas à frente). Como algumas séries de dados são obtidas através de modelagens (neste caso, dados de vento, pressão atmosférica em superfície e maré astronômica), torna-se possível utilizar os dados de previsão para 6 horas das mesmas; fato, este, que não ocorre com os dados de vazão.

As forçantes definidas como “t” estarão defasadas em 6 horas em relação a variável de saída do modelo e as forçantes definidas como “(t-6)” estarão defasadas em 12 horas da mesma variável de saída.

O item 5.2.1 denotará a arquitetura das 5 redes neurais artificiais selecionadas pelo e o item 5.2.2 apresentará a aglutinação de redes através da rede combinada – *ensemble* – e o desempenho de previsão desta rede.

5.2.1 Arquitetura de redes neurais artificiais selecionadas

Das 1000 RNAs testadas foram selecionadas 5 redes, todas do tipo MLP com estratégias de treinamento do tipo BFGS (2ª ordem). Todas as redes selecionadas apresentaram as funções de ativação das camadas ocultas corresponderam à função tangente hiperbólica e as funções de ativação das camadas de saídas corresponderam à função identidade.

No que tange a composição de neurônios por camadas e ciclos para obtenção de convergência, as RNAs se apresentaram conforme a Tabela 5.

Tabela 5–Composição dos neurônios por camadas das redes neurais artificiais e ciclos para obtenção de convergência

Rede	Camada de Entrada	Camada Oculta	Camada de Saída	Ciclos
1	16	8	1	173
2	16	21	1	140
3	16	38	1	211
4	16	31	1	154
5	16	11	1	150

Um dos critérios para seleção de uma rede corresponde aos erros nas etapas de treinamento, teste e validação. A Tabela 6 apresenta os erros SOS (fornecidos pelo modelo) e RMSE, em metros (calculados a partir dos dados de predição fornecidos pelo modelo) para as 5 referidas RNAs.

Tabela 6–Valores de erro por processo de modelagem - SOS (fornecido pelo modelo) e valores de erro RMSE (calculado), em metros

Rede	Erro	Treinamento	Teste	Validação
1	SOS	0,00000015	0,00000018	0,00000018
2	SOS	0,00000017	0,00000025	0,00000019
3	SOS	0,00000015	0,00000020	0,00000018
4	SOS	0,00000017	0,00000023	0,00000018
5	SOS	0,00000017	0,00000020	0,00000018
1	RMSE	0,00054	0,00059	0,00059
2	RMSE	0,00058	0,00066	0,00060
3	RMSE	0,00055	0,00063	0,00060
4	RMSE	0,00058	0,00067	0,00060
5	RMSE	0,00058	0,00063	0,00060

Ao comparar-se o *target* com o valor estimado, pela técnica RMSE, verifica-se que todas as redes apresentam um erro extremamente baixo tanto nas etapas de treinamento, quanto nas etapas de teste e validação (inferiores a 1,00 mm), ou seja, os valores dos erros encontrados em relação à média do nível do mar (2,49 m) são muito pequenos, o que garante a confiabilidade de todas as RNAs na previsão do nível do mar.

Outro critério para a seleção das melhores redes neurais corresponde aos valores de correlações encontrados entre os valores previstos e os valores observados para o nível do mar (para as 5 referidas redes, estas correlações estão dispostas na Tabela 7).

Tabela 7 - Correlação entre nível do mar previsto e observado

Rede	Treinamento	Teste	Validação
1	0,999977	0,999972	0,999972
2	0,999973	0,999967	0,999971
3	0,999976	0,999969	0,999971
4	0,999973	0,999964	0,999971
5	0,999974	0,999969	0,999971

Os resultados obtidos pelas RNAs durante as fases de treinamento são muito próximos. Conforme Brito *et al.* (2003), considera-se que um coeficiente igual a 1 garante uma correlação perfeita e o intervalo $0,91 < \text{coeficiente} < 0,99$, garante uma correlação

fortíssima. Portanto, as 5 RNAs demonstraram excelentes desempenhos, aproximando-se, inclusive, da correlação perfeita.

5.2.1.1 Modelo gerado utilizando-se a série de nível do mar bruto

Objetivando-se demonstrar a importância da filtragem numérica aplicada na série de nível do mar (item 4.2.3.1), foi criado um modelo de previsão do nível do mar, similar ao apresentado anteriormente, porém, a série de nível do mar corresponde à série temporal de nível do mar bruto (sem o processo de filtragem).

Neste caso, das 1000 RNAs testadas, também foram selecionadas 5 redes, e todas foram do tipo MLP com estratégias de treinamento do tipo BFGS (2ª ordem). As funções de ativação na camada oculta e na camada de saída foram (Tabela 8):

Tabela 8 - Funções de ativação nas camadas ocultas e nas camadas de saída das redes selecionadas

Rede	Camada oculta	Camada de saída
1	Exponencial	Tangente hiperbólica
2	Exponencial	Tangente hiperbólica
3	Exponencial	Tangente hiperbólica
4	Exponencial	Seno
5	Logística	Tangente hiperbólica

A composição de neurônios por camadas e ciclos para obtenção de convergência, das referidas RNAs, se apresenta conforme a Tabela 9.

Tabela 9 - Composição dos neurônios por camadas das redes neurais artificiais e ciclos para obtenção de convergência, utilizando-se a série de nível do mar bruto (sem aplicação do processo de filtragem numérica)

Rede	Camada de Entrada	Camada Oculta	Camada de Saída	Ciclos
1	16	29	1	32
2	16	10	1	47
3	16	5	1	67
4	16	9	1	82
5	16	34	1	37

A Tabela 10 apresenta os erros SOS (fornecidos pelo modelo) e RMSE, em metros (calculados a partir dos dados de predição fornecidos pelo modelo) para as 5 referidas RNAs.

Tabela 10 - Valores de erro por processo de modelagem - SOS (fornecido pelo modelo) e valores de erro RMSE (calculado), em metros, utilizando-se a série de nível do mar bruto (sem aplicação do processo de filtragem numérica)

Rede	Erro	Treinamento	Teste	Validação
1	SOS	0,00767295	0,01069318	0,00777051
2	SOS	0,00749219	0,01017510	0,00738329
3	SOS	0,00701286	0,00980558	0,00721515
4	SOS	0,00608025	0,01004923	0,00723725
5	SOS	0,00766541	0,01015295	0,00751491
1	RMSE	0,123879	0,146241	0,124664
2	RMSE	0,122411	0,142654	0,121518
3	RMSE	0,118430	0,140040	0,120126
4	RMSE	0,110275	0,141769	0,120310
5	RMSE	0,123818	0,142499	0,122596

Na comparação entre o *target* com o valor estimado, pela técnica RMSE, verifica-se que as 5 redes apresentam erros, aproximadamente, entre 11,03 a 12,39 cm na fase de treinamento, entre 14,00 a 14,62 cm na fase de teste e entre 12,01 a 12,47 cm na fase de validação. Quando comparado ao modelo anterior (com utilização de filtragem numérica na série temporal de nível do mar) verifica-se que, sob este critério para seleção das melhores redes neurais, os erros saltaram de valores inferiores a 1 mm, a valores superiores à 10 cm (100 mm), culminando, conseqüentemente em uma piora nos resultados.

O segundo critério para a seleção das melhores redes neurais, que corresponde aos valores de correlações encontrados entre os valores previstos e os valores observados para o nível do mar estão dispostas na Tabela 11.

Tabela 11 - Correlação entre nível do mar previsto e observado, utilizando-se a série de nível do mar bruto (sem aplicação do processo de filtragem numérica)

Rede	Treinamento	Teste	Validação
1	0,902791	0,877484	0,920235
2	0,905217	0,882234	0,920958
3	0,911553	0,887490	0,923358
4	0,923844	0,884434	0,923301
5	0,903098	0,884778	0,919208

Corroborando a constatação de que há um declínio no desempenho do modelo quando utilizada a série de nível do mar sem aplicação da filtragem numérica, as correlações apresentadas pelas 5 RNAs (Tabela 11) são inferiores às correlações anteriormente apresentadas (Tabela 7). As RNAs 1, 2 e 5, na etapa de treinamento (Tabela 11), não se enquadram no intervalo estipulado por Brito *et al.* (2003), onde “ $0,91 < \text{coeficiente} < 0,99$ ”, garante uma forte correlação.

5.2.2 Aglutinação das arquiteturas de rede e desempenho de previsão

As 5 redes neurais selecionadas pelo modelo, dentre as 1000 redes testadas, apresentaram desempenhos de previsão muito semelhantes entre si, como pode-se notar nos valores de erro e correlação encontrados para cada uma destas (demonstrados na seção 5.2.1). Portanto, os gráficos de dispersão e de linha, das referidas redes, são extremamente parecidos. Sendo a rede *ensemble* gerada através da combinação das 5 RNAs utilizadas neste estudo, como supracitado, esta rede apresenta o melhor desempenho dentre as 6 redes neurais analisadas. Assim, a seção 5.2.2 apresentará o desempenho de previsão da rede *ensemble*.

O gráfico *boxplot* contido na Figura 40 possibilita uma visão geral do comportamento da rede *ensemble* comparando-o ao comportamento real do nível do mar.

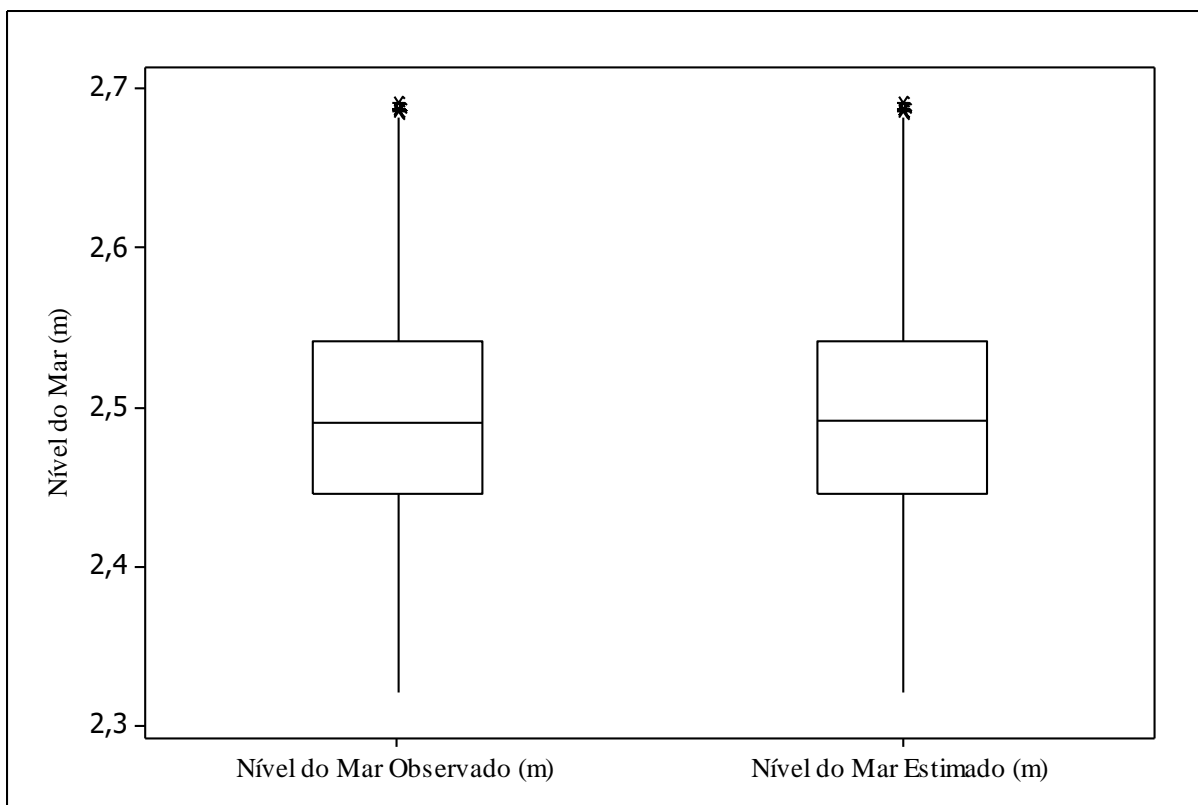


Figura 40 - Gráfico *boxplot*. Comparação entre o nível do mar observado e o nível do mar estimado pela rede *ensemble*

Observa-se que os dados do nível do mar estimados se distribuem de maneira praticamente idêntica aos dados observados. As medianas encontram-se muito próximas. Ambas possuem pequenas dispersões dos dados, semelhantes entre si. Um fato relevante apontado pelo gráfico *boxplot* é a existência de valores extremos para cima na rede *ensemble*, da mesma forma como se comporta a série de dados de nível do mar observado; este fato implica em uma fiel representação da RNA combinada; assim, em uma análise de previsão do nível do mar para o litoral norte de São Paulo em que esteja sendo considerada a existência de alguns eventos extremos, o modelo representará o comportamento real com êxito.

Ao analisar-se o erro RMSE das 6 redes neurais, nota-se que o erro da rede *ensemble* (exibido na Tabela 12) está entre os menores valores.

Tabela 12 – Valores de erro RMSE (calculado), em metros, nas fases de treinamento, teste e validação, para a rede *ensemble*

Rede	Erro	Treinamento	Teste	Validação
<i>Ensemble</i>	RMSE	0,00055	0,00025	0,00024

Salienta-se que o modelo não fornece o erro SOS para a rede *ensemble*; porém, são fornecidos dados de predição para esta rede e, assim, possibilitou-se o cálculo deste erro RMSE. É importante destacar-se que, apesar da rede *ensemble* não apresentar o menor erro dentre as 6 redes neurais analisadas, a referida rede evita o surgimento de erros abruptos; fato, este, que ocorreu nas demais redes.

A Figura 41 demonstra o gráfico de linha para as séries de nível do mar (observado e estimado); uma forma eficaz de atestar a exatidão alcançada pela RNA combinada (o quão perto a predição do nível do mar está do valor real do nível do mar). A exatidão constitui a chave para o propósito de validação da rede neural (a falta de exatidão é observada como um desvio sistemático do valor real – *viés*).




Figura 41- Gráfico de linha da rede *ensemble*; comportamento do nível do mar observado e comportamento do nível do mar estimado (dados em metros)

Pode-se comprovar pelo gráfico exposto na Figura 41 que o comportamento do nível do mar estimado pelo modelo acompanha com exatidão o comportamento do nível do mar observado e, sendo assim, assegura a validação do modelo.

De acordo com Brito *et al.* (2003), define-se como precisão o parâmetro que verifica a proximidade entre os valores de uma grandeza calculada. A falta de precisão caracteriza a incerteza da rede neural. A Figura 42 apresenta o gráfico de dispersão da rede *ensemble* que pode ser utilizado como parâmetro para verificação da precisão desta rede neural.

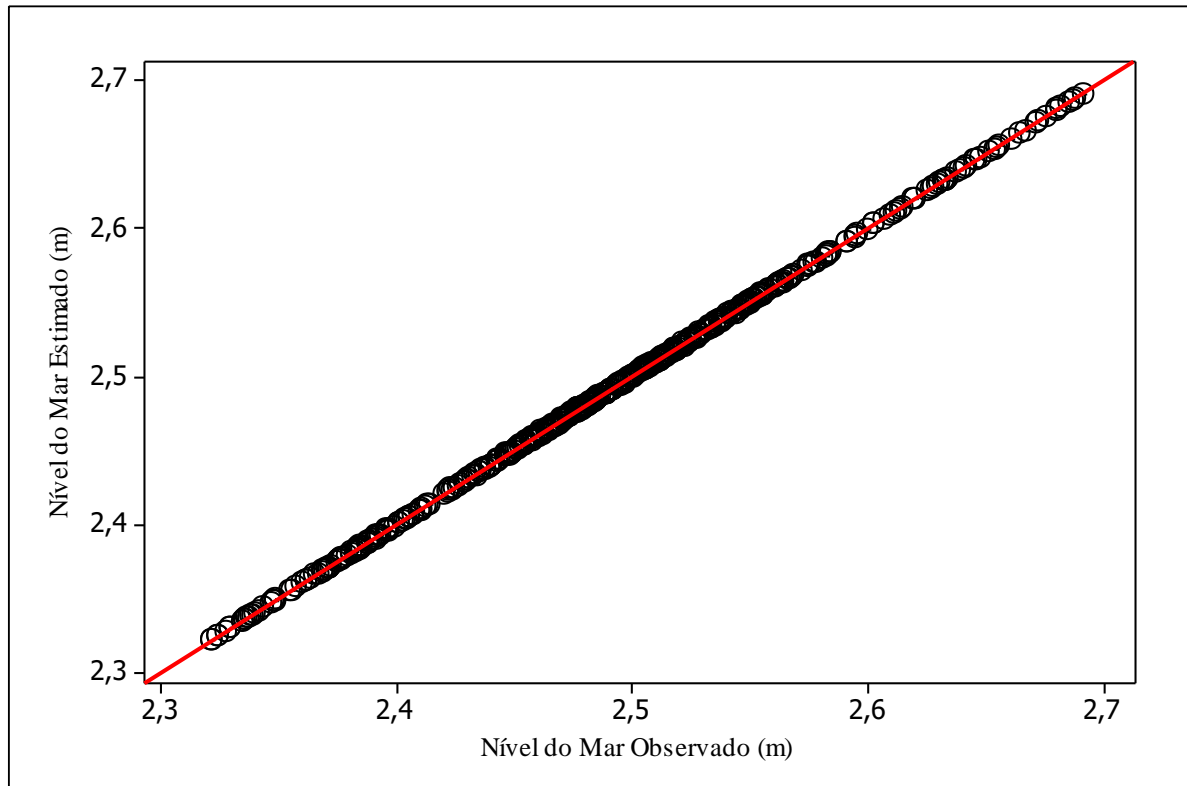


Figura 42 - Gráfico de dispersão da rede *ensemble*

Ao analisar-se o gráfico de dispersão da rede neural ensemble é evidente que esta rede se faz precisa. Corroborando a análise do gráfico *boxplot*, verifica-se a mínima dispersão apresentada pela referida rede neural. Os dados encontram-se bem distribuídos longitudinalmente, o que indica que esta distribuição não tende a errar sistematicamente nem para cima e nem para baixo.

5.3 Análise de sensibilidade

O valores dos pesos de cada forçante, em cada rede, no processo de previsão do nível do mar estão dispostos na Tabela 13.

Tabela 13 - Análise de sensibilidade das forçantes utilizadas no processo de modelagem. As forçantes definidas como “-6” e “-12” correspondem as forçantes defasadas em 6 e 12 horas, respectivamente, em relação à precisão do nível do mar para 6 horas

Rede 1	Forçante	NM-6	NM-12	Q-6	Q-12	PS-12	PS-6	PS	MA-6
	Peso	7726,58	17127,25	3,31	2,87	1,23	1,23	1,20	1,17
Rede 1	Forçante	MA-12	Vv-12	Vu	Vu-12	MA	Vv	Vu-6	Vv-6
	Peso	1,09	1,09	1,13	1,04	1,05	1,03	1,03	1,01
Rede 2	Forçante	NM-6	NM-12	Q-6	Q-12	PS-12	PS-6	PS	MA-6
	Peso	69829,69	17003,56	2,05	2,02	1,01	1,11	1,08	1,11
Rede 2	Forçante	MA-12	Vv-12	Vu	Vu-12	MA	Vv	Vu-6	Vv-6
	Peso	1,08	1,03	1,02	1,02	1,01	1,02	1,00	1,01
Rede 3	Forçante	NM-6	NM-12	Q-6	Q-12	PS-12	PS-6	PS	MA-6
	Peso	75674,82	18814,45	2,01	1,62	1,22	1,20	1,13	1,15
Rede 3	Forçante	MA-12	Vv-12	Vu	Vu-12	MA	Vv	Vu-6	Vv-6
	Peso	1,06	1,04	1,04	1,05	1,05	1,04	1,03	1,02
Rede 4	Forçante	NM-6	NM-12	Q-6	Q-12	PS-12	PS-6	PS	MA-6
	Peso	69023,03	17178,71	2,35	2,6	1,15	1,06	1,05	1,06
Rede 4	Forçante	MA-12	Vv-12	Vu	Vu-12	MA	Vv	Vu-6	Vv-6
	Peso	1,04	1,03	1,00	1,01	1,01	1,02	1,01	1,03
Rede 5	Forçante	NM-6	NM-12	Q-6	Q-12	PS-12	PS-6	PS	MA-6
	Peso	70829,35	16777,21	2,12	1,83	1,11	1,13	1,24	1,13
Rede 5	Forçante	MA-12	Vv-12	Vu	Vu-12	MA	Vv	Vu-6	Vv-6
	Peso	1,06	1,06	1,05	1,07	1,02	1,03	1,01	1,01
Rede En	Forçante	NM-6	NM-12	Q-6	Q-12	PS-12	PS-6	PS	MA-6
	Peso	72526,69	17380,24	2,37	2,19	1,16	1,15	1,14	1,12
Rede En	Forçante	MA-12	Vv-12	Vu	Vu-12	MA	Vv	Vu-6	Vv-6
	Peso	1,07	1,05	1,05	1,04	1,03	1,03	1,02	1,02

A importância relativa de cada variável foi encontrada aplicando-se o método “*change of root mean square error*”, descrito por Günay e Yildirim (2011), no qual: treina-se a rede com todas as variáveis de entrada obtendo-se, assim o RMSE-1. Em seguida, retira-se uma variável e repete-se o processo de treinamento, obtendo-se o RMSE-2. Este procedimento é, então, repetido para todas as variáveis. Ao final do processo compara-se os RMSEs obtidos (funcionando-se, desta forma, como um indicador da importância de cada variável). Quanto maior tornou-se o RMSE-x, na ausência de determinada variável “x”, maior será a importância desta para determinar a variável de saída do modelo.

Constatou-se que com a retirada de qualquer uma das variáveis utilizadas no presente trabalho, o valor RMSE-x aumentou em relação ao valor RMSE obtido com a entrada das 16 variáveis (Eq. 33), corroborando os dados obtidos através da análise de sensibilidade, onde pode-se perceber que todas as forçantes foram significantes no processo de variação do nível do mar uma vez que todas obtiveram um valor de peso maior que 1.

De acordo com a Tabela 13, as forçantes que mais influenciaram a previsão do nível do mar, em todas as RNAs, foram: nível do mar observado 6 horas antes e nível do mar observado 12 horas antes ($NM-6 \gg NM-12 \gg 1$). Desta forma, pode-se inferir que o nível do mar previsto terá uma forte relação com o nível já existente no local analisado. Em outras palavras, as oscilações de nível do mar ao longo de 12 horas, principalmente durante as últimas 6 horas, terão forte impacto nas oscilações de previsão de nível do mar para 6 horas, configurando-se, portanto, variáveis de entrada no modelo imprescindíveis para a previsão do nível do mar de curto prazo, através das RNAs. Assim, mais uma vez destaca-se a importância de observações sistemáticas e de longo período ao longo de toda a costa brasileira, a fim de se minimizar as consequências decorrentes de anomalias positivas no nível do mar.

A vazão fluvial também tem grande destaque, uma vez que todas as RNAs apresentaram o mesmo comportamento definido por: $Q-6 > Q-12 > 1$, ocupando os 3º e 4º lugares, respectivamente, de importância. Assim como as forçantes NM-6 e NM-12, a vazão fluvial defasada em 6 horas tem maior influência no processo quando comparada à vazão fluvial defasada em 12 horas. Com base neste resultado, pode-se inferir que o aporte fluvial do rio Juqueriquerê (analisado no presente trabalho pela vazão de seu afluente, rio Camburu) tem grande impacto no movimento de subida e descida do nível do mar na região costeira.

As demais variáveis exibiram pesos semelhantes, analogamente às suas influências no sistema. Dentre estas, a maré astronômica é a única forçante que mantém o comportamento

de MA-6 > MA-12 > MA, em todas as RNAs. No que tange às influências das forçantes atmosféricas, as redes neurais apresentaram comportamentos distintos. Em relação aos componentes do vento, analisando-se as 5 RNAs selecionadas, verifica-se que: para a defasagem de 12 horas, a maioria das redes neurais exibe maior influência da componente Vv (paralela à costa); para a defasagem de 6 horas, a maioria das redes neurais atribui influências iguais à ambas componentes da forçante vento (influência da componente paralela igual à influência da componente perpendicular no processo de previsão do nível do mar); para as variáveis estimadas, a maioria das redes neurais exibe maior influência da componente Vu (perpendicular à costa). Nota-se que este comportamento apresentado pelas redes em relação às componentes ortogonais do vento é, exatamente, o comportamento apresentado pela rede neural *ensemble*, reafirmando sua propriedade de rede combinada das demais redes selecionadas. Verifica-se, também, que os pesos de ambas as componentes do vento foram semelhantes, conferindo, desta forma, a igual importância destas componentes ao sistema; este comportamento pode ser justificado pela abordagem de RNA que compara as forçantes de maneira conjunta no processo de predição do nível do mar.

6 CONSIDERAÇÕES FINAIS

6.1 Conclusões

O presente trabalho teve como objetivo a previsão do nível do mar para o litoral norte de São Paulo. Para tal, utilizou-se uma abordagem de Redes Neurais Artificiais – em pesquisas realizadas na literatura, foram encontrados estudos com metodologia e objetivos semelhantes, como o de Chen *et al.* (2012), que aponta para um melhor desempenho das modelagem realizadas com redes neurais quando comparadas às modelagens numéricas 2D e 3D. Foram testadas 1000 combinações de redes, tanto MLP quanto RBF. Foram selecionadas as 5 redes que obtiveram o melhor desempenho e uma rede *ensemble* – combinada das outras 5, sendo todas as redes do tipo MLP, demonstrando ser esse tipo o mais eficiente no que tange o objetivo geral do presente trabalho.

Estudos costeiros que compreendam o litoral brasileiro defrontam-se com a escassez de dados hidrológicos, oceanográficos e meteorológicos. Este trabalho buscou como alternativa a este problema a utilização de dados gerados através de modelagens (exceto para os dados de nível do mar). No entanto, ressalta-se que o contínuo aprimoramento e precisão de metodologias como RNAs e outros tipos de modelos passa, necessariamente, pelo monitoramento sistemático e de longo prazo.

A série de nível do mar, registrada pelo marégrafo do IOUSP em Ubatuba – SP contém as medições registradas no local. Sabe-se que estas medidas são compostas por oscilações provindas de diversas fontes, tais como marés astronômicas e meteorológicas e, assim, possuem altas e baixas frequências. Porém, é importante que se eliminem as interferências de “alta” frequência para que a amostra gerada contenha apenas as alturas de nível do mar de baixa frequência (ou o mais próximo que se possa chegar dessa separação). Isso porque a abordagem de RNAs se baseia na “aprendizagem” das relações em que as variáveis estabelecem e, desta forma, a não retirada das interferências de alta frequência da amostra de nível do mar, dificulta o estabelecimento destas relações pelo modelo; por exemplo, as oscilações de marés astronômicas e marés meteorológicas participariam do processo duplamente, na forma de interferência na série de nível do mar e na forma de forçantes estipuladas para as entradas no modelo. Em outras palavras, objetivou-se prever um

comportamento estacionário (nível do mar) e, portanto, sem ruídos. Com isso, a aplicação do filtro cosseno de Lanczos, realizada na série de nível do mar, mostrou-se imprescindível para a geração de uma amostra satisfatória desta variável. A estimação do nível do mar em curto prazo, 6 horas, através das influências das forçantes: nível do mar, maré astronômica, componentes ortogonais do vento, pressão atmosférica em superfície e vazão fluvial, pelo processo de redes neurais artificiais, comprovou ser um processo extremamente eficiente; os erros RMSE, calculados, em todas as RNAs selecionadas, foram inferiores a 1 milímetro e os coeficientes de correlação garantiram as correlações fortíssimas existentes nestas redes.

Para a região estudada foram constatados, na série de nível do mar observado, valores extremos positivos, mesmo não sendo, estes, valores anômalos. Justifica-se esta ocorrência pela pequena dispersão da amostra. Analisando-se a rede neural *ensemble*, verifica-se a mesma existência de valores extremos positivos. Portanto, a rede neural *ensemble* assegura a confiabilidade na detecção e reprodução de valores extremos de nível do mar, comportamento comum para esta variável, uma vez que diversos fatores podem influenciar este tipo de variação, tal como a passagens de frentes frias.

Um dos principais interesses deste trabalho consistiu-se em analisar-se a influência relativa de cada forçante na determinação do nível do mar. De acordo com os resultados obtidos pela análise de sensibilidade, pode-se inferir que todas as forçantes empregadas como entradas no modelo são significantes no processo de previsão do nível do mar por redes neurais artificiais. Através desta análise, comprovou-se a expressiva atuação da vazão fluvial no que tange a variação do nível do mar, para a região estudada, que corrobora o fato de que como as marés constituem uma barreira natural à drenagem da bacia do rio Juqueriquerê, é de se esperar que o aporte fluvial tenha valiosa contribuição na dinâmica do nível do mar no litoral. No caso de utilização desta rede neural para previsão do nível do mar, fica notória a necessidade de uma amostra de vazão que represente com mais exatidão a realidade local a fim de se aprimorar o desempenho da rede.

Segundo o trabalho de Valentim (2012) associado ao mecanismo de transporte de Ekman esperava-se que com o rotacionamento das componentes ortogonais do vento, a componente paralela (V_v) ganharia maior peso na modelagem, quando comparada à componente perpendicular (V_u). Porém, este acontecimento não foi verificado. Os pesos de ambas as componentes foram muito próximos e variaram de acordo com a defasagem em cada rede neural. Esta constatação pode ser justificada pela metodologia das RNAs onde o modelo compara todas as variáveis de forma conjunta e como esta comparação influi no

variável de resposta. Desta forma, analisando-se conjuntamente todas as influências das forçantes na variabilidade do nível do mar, a abordagem escolhida inferiu que as variáveis meteorológicas possuem similar expressão, independentemente de suas direções.

6.2 Sugestões para trabalhos futuros

Como constatado, é imprescindível que se utilizem amostras representativas das forçantes. Sugere-se para estudos futuros, a obtenção de dados de vazão, principalmente, mais coesos. Sugere-se, também, que outras variáveis podem ser acrescentadas ao modelo, como por exemplo: correntes marítimas, salinidade e temperatura do ar, com o intuito de verificar suas influências na previsão do nível do mar.

7 REFERÊNCIAS

ALFREDINI, P.; ARASAKI, E. **Obras e Gestão de Portos e Costas**. 2ª ed. São Paulo: Editora Edgard Blucher Ltda., 2009.

ARASAKI, E.; ALFREDINI, P.; PEZZOLI, A.; ROSSO, M. **Coastal area prone to extreme flood and erosion events induced by climate changes: study case of Juqueriquerê river bar navigation, Caraguatatuba (São Paulo state), Brazil**. In: 9th International Conference on Marine Navigation and Safety of Sea Transportation. Proceedings. Gdynia, Polônia, 2011.

ANA – **AGÊNCIA NACIONAL DAS ÁGUAS**. Disponível em: <www.ana.gov.br>. Acesso em: 13 mai 2014.

ANA – Agência Nacional de Águas (ANA / DLE). **Sinopse das Bacias Hidrográficas do Atlântico Sul – Trecho Sudeste**. Brasília, 2001.

BOULOMYTIS, V.T.G. **The Parametrization for the hydrological and hydraulic modelling of non-assessed water sheds: case of Juqueriquerê river basin in Caraguatatuba, São Paulo – Brazil**. In: VIII Workshop Projeto RedeLitoral. Mudanças Climáticas Globais e Impactos na Zona Costeira: Modelos, Indicadores, Obras Civas e Fatores de Mitigação/Adaptação. Ilhabela. 2014.

BOULOMYTIS, V.T.G.; ALVES, C.D. **Multi-temporal analysis of the urban expansion in the Juqueriquere river basin**. In: Vth World Water Congress - WAC: Adaptive & Integrated Water Management. Nova Délhi, 2011.

BOULOMYTIS, V. T. G.; BERNARDES, M. E. C.; KRUK, N. S.; SOUSA JUNIOR, W. C. **Avaliação do comportamento hidrológico da bacia do rio Juqueriquerê, Caraguatatuba, SP**. In: II Simpósio de Recursos Hídricos do Rio Paraíba do Sul. São José dos Campos, São Paulo, 2014.

BRITO, N. M.; AMARANTE JUNIOR, O. P.; POLESE, L.; RIBEIRO, M. L. Validação de métodos analíticos: estratégia e discussão. **Pesticidas: R. Ecotoxicológica e Meio Ambiente**, v. 13, p. 129-146, 2003

CAMPOS, R.M.; CAMARGO, R.; HARARI, J. Caracterização de eventos extremos do nível do mar em Santos e sua correspondência com as reanálises do modelo do NCEP no sudoeste do atlântico sul. **Revista Brasileira de Meteorologia**, v.25, n.2, p. 175-184, 2010.

CARTACHO, D.L. **Análise probabilística chuva-maré para a bacia do rio Santo Antônio em Caraguatatuba (SP)**. 116 f. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2013.

CARVALHO, A.R.; MARINHO, A.M.; SILVA, A.C.R. S.; BERNARDES, M.E.C. **comparação entre os índices de qualidade da água (IQA) dos estuários dos rios Itambuca e Juqueriquerê– litoral norte de São Paulo – sob mesma sazonalidade**. Em: IV Congresso Brasileiro de Gestão Ambiental. Salvador, 2013.

CHEN, W-B.; LIU, W-C.; HSU, M-H. Comparison of ANN approach with 2D and 3D hydrodynamic models for simulating estuary water stage. **Advances in Engineering Software**, v.45, p. 69–79, 2012.

COMITÊ DE BACIAS HIDROGRÁFICAS DO LITORAL NORTE. **Relatório de Situação dos Recursos Hídricos do Litoral Norte**, 2013.

COSTA, M. C. **Análise do nível médio do mar utilizando filtro de passa-baixa de Thompson e de Lanczos aplicados à região costeira de Cananéia (SP)**. 48 f. Trabalho de conclusão de curso (Engenharia Ambiental) - Universidade Federal de Itajubá, Itajubá, 2007.

COSTA, M. C. **Influência das tensões do vento na variação do nível médio do mar na região costeira de Cananéia (SP): filtragem numérica e análise espectral**. 179 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos. Universidade Federal de Itajubá, Itajubá, 2010.

DHN - DIRETORIA DE HIDROGRAFIA E NAVEGAÇÃO DO MINISTÉRIO DA MARINHA. **Convenção das Nações Unidas Sobre o Direito do Mar. Lisboa: Ministério dos Negócios Estrangeiros e do Mar**, 1985. 313 p. (Versão em Língua Portuguesa com Anexos e Acta Final da Terceira Conferência das Nações Unidas sobre o Direito do Mar), 1995

DSA – DIVISÃO DE SATÉLITES E SISTEMAS AMBIENTAIS. Disponível em: <<http://sigma.cptec.inpe.br/radar>>. Acesso em: 13 fev 2016.

EHLERS, R.S. **Análise de séries temporais**. Trabalho de conclusão de curso. Universidade Federal do Paraná. Curitiba, 1999.

FILIPPO, A. M.; Variabilidade do nível do mar em função de eventos meteorológicos de baixa frequência. Tese de doutorado. Universidade Federal Fluminense. Niterói, Rio de Janeiro, 2003.

FERREIRA, A.B.H. **Dicionário Aurélio da Língua Portuguesa**. 1ª ed. Rio de Janeiro: Editora Nova Fronteira, 1988.

GENZ, F.; LESSA, G.C.; CIRANO, M. Vazão mínima para estuários: um estudo de caso no rio Paraguaçu/BA. **Revista Brasileira de Recursos Hídricos**, v. 13, n.3, p.73-82, 2008.

GRUBER, N. L. S.; BARBOZA, E. G.; NICOLODI, J. L. Geografia dos sistemas costeiros: subsídio para gestão integrada da zona costeira. **Gravel**. Porto Alegre, n. 1, p, 81-89, 2003.

GÜNAY, M. E., YILDIRIM, R. Neural network analysis of selective CO oxidation over copper-based catalysts for knowledge extraction from published data in the literature. **Ind.Eng.Chem.Res**, v. 50, p. 12488–12500, 2011.

HAYKIN, S. **Redes Neurais, Princípios e Práticas**. 2ª ed. Porto Alegre: Bookman, 2001.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Disponível em: <[http:// http://cidades.ibge.gov.br/xtras/uf.php?lang=&coduf=35&search=sao-paulo](http://http://cidades.ibge.gov.br/xtras/uf.php?lang=&coduf=35&search=sao-paulo)>. Acesso em: 13 fev 2016.

IPCC – INTERNATIONAL PANEL ON CLIMATE CHANGE. The Science of Climate Change – The Scientific Basis Cambridge: Cambridge Univ., 2001.

IPCC – INTERNATIONAL PANEL ON CLIMATE CHANGE. Fourth Assessment Report: Climate Change, 2007.

KALIL, A. F. D. Contribuições ao estudo do nível médio do mar no Estado do Rio de Janeiro. Dissertação de Mestrado em Ciências em Engenharia Oceânica - Instituto Alberto Luiz Coimbra de Pós- Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, 1999.

LENTINI, C. Módulo 3 – oceanografia física. Aula 4 – hidrodinâmica costeira, ondas e marés. 2007. Disponível em: < http://www.oceanografia.ufba.br/ftp/Introducao_Oceanografia/fisica_4.pdf > Acesso em: 08 ago 2016.

MACHADO, W.C.; FONSECA JUNIOR, E.S. Redes neurais artificiais aplicadas na previsão do Vtec no Brasil. **Boletim de Ciências Geodésicas.** Curitiba, v. 19, n. 2, p. 227-246, 2013.

MAGALHÃES, F. S. Utilização do Fitoplâncton como instrumento de avaliação em programas de monitoramento dos ecossistemas aquáticos. Estudo de caso: Laguna de Araruama/RJ. 160 f. Dissertação (Mestrado) – Programa de Pós-graduação em Engenharia Ambiental da Universidade do Estado do Rio de Janeiro. Rio de Janeiro, 2012.

MARCONI, M. A.; LAKATOS, E. M. Fundamentos de metodologia científica. 6ª ed. São Paulo: Atlas, 2006.

MARTINS, R. A.; MELLO, C. H. P.; TURRIONI, J. B. Guia para elaboração de monografia e TCC em engenharia de produção. 1a ed. São Paulo: Atlas, 2014.

MARZBAN, C. Neural Network for Postprocessing Model Output: ARPS. **Montly Weather Review,** v. 131, n. 6, pp. 1103-1111, Jun, 2003.

MEENA, B. L.; AGRAWAL, J. D. Tidal level forecasting using ANN. 8th International Conference on Asian and Pacific Coasts (APAC 2015). **Procedia Engineering.** v. 116, p. 607-614, 2015.

MENEZES, D. C. Contribuições metodológicas para a análise de flutuações atmosféricas e oceanográficas de baixa frequência na costa do Estado do Rio de Janeiro. 136 f. Dissertação (Mestrado) – Instituto Alberto Luiz Coimbra de Pós Graduação e Pesquisa de Engenharia. Universidade Federal do Rio de Janeiro, 2007.

MESQUITA, A. R. Marés, circulação e nível do mar na costa sudeste do Brasil. Documento preparado à Fundespa (fundação de estudo e pesquisa aquáticas), 1997. Disponível em :<www.mares.io.usp.br>. Acesso em: 10 dez 2015.

MIGUENS, A.P. Marés e correntes de marés; correntes oceânicas. In: **Navegação: ciência e a arte. Volume I - Navegação costeira, estimada e em águas costeiras.** Niterói, DHN –

Diretoria de Hidrografia e Navegação, órgão da Marinha do Brasil.1996. Disponível em: <http://www.mar.mil.br/dhn/bhmn/publica_manualnav.html>. Acesso em: 10 dez 2015.

MINISTÉRIO DO MEIO AMBIENTE. **Plano Nacional de Gerenciamento Costeiro – PNGC II**. Site. Disponível em: <www.mma.gov.br/estruturas/orla/_arquivos/pngc2.pdf>. Acesso em: 13 fev 2016.

MINISTÉRIO DO MEIO AMBIENTE. Site. Disponível em: <<http://www.mma.gov.br/biodiversidade/biodiversidade-aquatica/zona-costeira-e-marinha>>. Acesso em: 13 fev 2016.

MINISTÉRIO DO MEIO AMBIENTE. Site. Disponível em: <<http://www.mma.gov.br/gestao-territorial/gerenciamento-costeiro/a-zona-costeira-e-seus-m%C3%BAltiplos-usos/caracteristicas-da-zona-costeira>> Acesso em: 13 fev 2016.

MIRANDA, L.B.; CASTRO, B.M.; KJERFVE, B. **Princípios de Oceanografia Física de Estuários**. São Paulo: Editora da Universidade de São Paulo, 2002.

MITROFF, I. I.; BETZ, F.; PONDY, L. R.; SAGASTI, F. On managing science in the systems age: two schemas for the study of science as a whole systems phenomenon. **Interfaces**, v. 4, n. 3, p. 46–58, 1974.

MOURA, C. A. Avaliação de tendência a enchentes das bacias hidrográficas do município de Caraguatatuba (SP). **Revista de Geografia (UFPE)**, v. 30, n. 2, 2013.

NATIONAL OCEANOGRAPHY CENTRE, SOUTHAMPTON. Disponível em: <<http://www.soes.soton.ac.uk/teaching/courses/soes3018/2008/group9/Falmouth.htm>>. Acesso em: 10 dez 2015.

NEVES, C. F.; MUEHE, D. Vulnerabilidade, impactos e adaptações a mudanças do clima: a zona costeira. **Parcerias Estratégicas**, v. 13, n. 27, 2008.

OLIVEIRA, M.M.F. **Redes neurais artificiais na predição da maré meteorológica em Paranaguá – PR**. 160 f. Dissertação (Mestrado) – Programas De Pós-Graduação De Engenharia Da Universidade Federal Do Rio De Janeiro. Rio de Janeiro, 2004.

OLIVEIRA, M.M.F.; EBECKEN, N.F.F.; SANTOS, I.A.; NEVES, C.F.; CALOBA, L.P.; OLIVEIRA, J.L.F. Modelagem da maré meteorológica utilizando redes neurais artificiais: uma aplicação para a baía de Paranaguá – PR, Parte 1: dados meteorológicos da estação de superfície. **Revista Brasileira de Meteorologia**, v.21, n.2, p. 220-231, 2006.

POWELL, G.L.; MATSUMOTO, J.; BROCK, D.A. Methods for determining minimum freshwater in flow needs of Texas bays and estuaries. **Estuaries**, v. 25, p. 1262-1274, 2002.

PROJETO REDELITORAL. Disponível em: <<http://redelitoral.ita.br>>. Acesso em: 13 mai 2014.

PUGH, D.T. Tides, Surges and Mean Sea Level. **Great Britain, John Wiley & Sons**. 1987.

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

SAKAI, R. O. ; Cartacho, D. L. ; ARASAKI, E. ; ALFREDINI, P. ; PEZZOLI, A. ; SOUSA JR., W. C. ; ROSSO, M. ; MAGNI, L. Extreme events assessment methodology coupling debris flow, flooding and tidal levels in the coastal floodplain of the São Paulo North Coast (Brazil). **International Journal of Geosciences**, v. 4, p. 30-38, 2013.

SANTOS, F.L. **Redes neurais artificiais artmap-fuzzy aplicadas ao estudo de agitação marítima e ondas de lagos**. 257 f. Tese (Doutorado) – Programa de Pós- Graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira da UNESP. Ilha Solteira, 2013.

SANTOS, L. I. V.; CARMO, J.S.A.; PINHO, J.L.S. Influência da variação do nível médio das águas do mar no estuário do rio Mondego, Portugal. **Recursos Hídricos. Associação Portuguesa dos Recursos Hídricos**, v. 33, n. 1, 2012.

SANTOS, R.T. F. **Mudanças climáticas e a zona costeira: uma análise do impacto da subida do nível do mar nos recursos hídricos – o caso do canal de São Francisco – baía de Sepetiba – RJ**. 127 f. Dissertação (Mestrado) – Programa de Pós-graduação em Planejamento Energético, COPPE, da Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2012.

SOUZA, J. M. Mar territorial, zona econômica exclusiva ou plataforma continental?. **Revista Brasileira de Geofísica**, n. 1, v. 17, 1999.

SCHETTINI, C.A.F. Caracterização física do estuário do rio Itajaí-açu, SC. **Revista Brasileira de Recursos Hídricos**, v. 7, n.1, p. 123-142, 2002.

SIGAM – SISTEMA INTEGRADO DE GESTÃO AMBIENTAL. Disponível em: <http://www.sigam.ambiente.sp.gov.br/sigam2/Repositorio/472/Documentos/Mural_PlanosdeFiscalizacao/pesca_costeira/npcp_sp.pdf>. Acesso em: 13 mai 2014.

SILVA, A.C.R.S. **Diagnóstico de nitrogênio (amônia, nitrato e nitrito) e fósforo (fosfato) na bacia do rio Juqueriquerê e seu estuário, Caraguatatuba – SP**. Trabalho de conclusão de curso (Engenharia Ambiental) – Instituto de Recursos Naturais, Universidade Federal de Itajubá. Itajubá, 2013.

SILVA, L.N.C. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. Dissertação (Mestrado) – Faculdade de Engenharia Elétrica e de Computação – Unicamp. Campinas, 1998.

SKLAR F.H.; BROWDER, J.A. Coastal environmental impacts brought about by alterations to freshwater flow in the Gulf of Mexico. **Environmental Management**, v. 22, n. 4, p. 547-562, 1998.

SPERB, R.M.; TRUCCOLO, E.C.; SARAIVA, R.A. **Uma rede neural temporal para previsão do nível do mar: um estudo de caso**. In: II Congresso sobre Planejamento e Gestão das Zonas Costeiras dos Países de Expressão Portuguesa; IX Congresso da Associação Brasileira de Estudos do Quaternário; II Congresso do Quaternário dos Países de Língua Ibéricas, 2003.

STEWART, R. H. Introduction to physical oceanography. **Texas A & M University**, 2008. Disponível em: < <http://kingfish.coastal.edu/physics/msci301/stewart/TOC.pdf> >. Acesso em: 10 mai 2016.

TABORDA, R.; DIAS, J.M.A. Análise da sobrelevação do nível do mar de origem meteorológica durante os temporais de fevereiro/março de 1978 e dezembro de 1981. **Geonovas: a geologia e o ambiente**. Nº Especial 1 "A Geologia e o Ambiente", p.89-97, Lisboa. 1992

TEIXEIRA, L.R. **Megaprojetos no litoral norte paulista: o papel dos grandes empreendimentos de infraestrutura na transformação regional**. 274 f. Tese (Doutorado) – Universidade Estadual de Campinas, Campinas, 2013.

TESSLER, M.G.; GOYA, S.C. Processos costeiros condicionantes do litoral brasileiro. **Revista do Departamento de Geografia**, v. 17, p. 11-23, 2005.

THURMAN, H. V. **Essential of Oceanography**. 5ª ed. Prentice-Hall, Inc, 1996.

TRIOLA, M. F. **Introdução à Estatística**. 10ª ed. Editora LTC, 2008.

TSCHÖKE, G.V.; KRUK, N.S.; MARTINS, D. **Correção do viés pelo modelo de transformação de potência das previsões de precipitações do modelo ETA/CPTEC para a bacia do Rio Juqueriquerê**. In: Simpósio Brasileiro de Recursos Hídricos. Anais. Bento Gonçalves - RS, 2013.

UAISSONE, A. J. R. **Influência das forçantes atmosféricas em mesoescala sobre o nível médio do mar em Piraquara, RJ**. Dissertação de Mestrado em Engenharia Oceânica - Instituto Alberto Luiz Coimbra de Pós- Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, 2004.

VALENTIM, S. S. **Análise das variações do nível médio do mar (NMM) em Ubatuba (SP) a partir de dados maregráficos**. 98 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Meio Ambiente e Recursos Hídricos. Universidade Federal de Itajubá. Itajubá, 2012.

VALENTIM, S.S.; BERNARDES, M.E.C.; DOTTORI, M.; CORTEZI, M. Low-frequency physical variations in the coastal zone of Ubatuba, northern coast of São Paulo state, Brazil. **Brazilian Journal of Oceanography**, v. 61, n. 3, p. 187-193, 2013.