

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO DE JOINVILLE
CURSO DE ENGENHARIA NAVAL**

HECTOR ANDREW LISBÔA JACQUES

**Redes Neurais Artificiais: Um Modelo para Estimativa de Bollard Pull de
Rebocadores Twin Screw**

Joinville

2017

HECTOR ANDREW LISBÔA JACQUES

**Redes Neurais Artificiais: Um Modelo para Estimativa de Bollard Pull de
Rebocadores Twin Screw**

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de bacharel em Engenharia Naval no Curso de Engenharia Naval da Universidade Federal de Santa Catarina, Centro Tecnológico de Joinville.

Orientador: Dr. Thiago Pontin Tancredi

Joinville

2017

**Redes Neurais Artificiais: Um Modelo para Estimativa de Bollard Pull de
Rebocadores Twin Screw**

HECTOR ANDREW LISBÔA JACQUES

Este trabalho de conclusão de curso foi julgado e aprovado como requisito parcial para obtenção do título de bacharel em Engenharia Naval na Universidade Federal de Santa Catarina, Centro Tecnológico de Joinville.

Joinville, 29 de Novembro de 2017.

Banca Examinadora:

Professor Dr. Thiago Pontin Tancredi
Orientador

Professor Dr. Bernardo Luis Rodrigues Andrade
Membro 1

Professor Luiz Eduardo Bueno Minioli
Membro 2

AGRADECIMENTOS

Agradeço à minha família, primeiramente aos meus pais, Jaqueline e Afonso. Infinitamente sou grato à vocês por me ensinarem o que é a vida e como podemos se tornar um agente transformador do mundo. Aos meus irmãos, Raquel e Victor, sou grato por acreditar e confiar em mim nos momentos que nem eu mesmo acreditava mais.

Um agradecimento especial à Rapeize, minha segunda família. Nossas memórias são inesquecíveis e guardarei comigo no lugar mais seguro dos meus pensamentos. Me conforto por saber que iremos cultivá-las com o maior esforço, pois nossa amizade é *sui generis*. Em especial agradeço ao Juan, pela sua companhia em praticamente todos os momentos da nossa vida universitária e, neste trabalho, por assumir o papel de co-orientador, aconselhando-me com palavras motivadoras e de esperança. Valeu mesmo, amigo.

Agradeço aos meus amigos de infância do bairro Vendaval por se fazerem presentes na minha vida há 20 anos. Que nossa lealdade perdure até o último dia de nossas vidas. Agradeço fortemente ao Wendell por, através da sua experiência e sabedoria, me guiar durante o período deste trabalho e, também, por ser um amigo de todas as horas.

Agradeço à minha namorada e melhor amiga, Isabelle Buzzi. Seu companherismo foi fundamental ao longo deste trabalho, e também sou grato por me incentivares mostrando que tudo é possível e que o amor sempre vence.

Agradeço aos amigos da Liga Joinvilense de Futebol pela compreensão dos momentos em que estive ausente em virtude das pesquisas e por estimular cada vez mais o término da minha graduação.

Agradeço ao meu orientador Professor Thiago Pontin Tancredi, citado diversas vezes ao longo do texto e outras inúmeras fora dele. O maior orgulho deste trabalho é, sem dúvidas, ter sido orientado por você. Além de todos os conselhos acadêmicos, agradeço também pelos conselhos da vida. Saiba que és a pessoa responsável por eu acreditar que devo navegar nos mares da engenharia naval.

Por fim, agradeço aos membros da banca, Professor Bernardo Andrade e Luiz Minioli, por ter aceitado o convite para avaliar este trabalho.

“Não é a força, mas a constância dos bons sentimentos que conduz os homens à felicidade.”

Friedrich Nietzsche

RESUMO

A engenharia naval engloba diversas áreas que apresentam problemas complexos ainda nas fases preliminares de projeto. Desta maneira, buscam-se soluções alternativas ou inovadoras para a obtenção de resultados confiáveis para a estimativa de desempenho de uma embarcação ainda nas fases iniciais do projeto. Entre os tipos de navios existentes, os rebocadores apresentam-se como uma exceção dentre os demais por serem construídos com uma finalidade específica, a de rebocar outras embarcações durante a realização de manobras. Este reboque, em geral, é realizado com o auxílio de um cabo fixado entre o rebocador e a embarcação a ser rebocada, sendo que a tração atuante neste cabo pode ser definida como a força de reboque (Bollard Pull) provocada pelo rebocador. Neste trabalho é apresentado um modelo empírico baseado em Redes Neurais Artificiais para estimar a capacidade de um rebocador durante as fases iniciais do projeto. Entre os diversos tipos de rebocadores e suas classificações, foram coletados dados de rebocadores com sistema propulsivo twin screw e utilizados no treinamento de uma rede neural destinada a estimativa do Bollard Pull. O trabalho inicia-se com uma revisão bibliográfica a cerca dos temas: redes neurais artificiais e Bollard Pull. A partir do conceito fundamentado é proposta uma metodologia para o desenvolvimento do trabalho que consiste na implementação de um método de referência já existente para estimar o Bollard Pull e de um modelo criado com base em redes neurais artificiais. O modelo criado com base nas redes neurais mostrou mais preciso que o método de estimativa já existente, apresentando erro médio e erro máximo de aproximadamente 2% e 4%, enquanto o método existente apresentou os valores de 6% e 14%, respectivamente.

Palavras-chave: rede neural artificial, bollard pull, rebocadores, projeto, propulsores.

ABSTRACT

Naval engineering embraces several areas that present complex problems still in the preliminary stages of design. In this way, alternative or innovative solutions are sought to obtain reliable results for the estimation of the performance of a vessel during the initial phases of the project. Among the types of existing vessels, tugboats are an exception among the others because they are constructed with a specific purpose, to tow other vessels during the accomplishment of maneuvers. This tow is generally made with the aid of a cable fixed between the tugboat and the vessel to be towed, the traction acting on this cable is defined as the towing force (Bollard Pull) caused by the tugboat. This paper presents an empirical model based on Artificial Neural Networks to estimate the capacity of a tugboat during the initial phases of the project. Among the different types of tugboats and their classifications, data were collected from twin screw propellers system that were used in the training of a neural network for the estimation of Bollard Pull. The work begins with a bibliographical review about the themes: Artificial neural networks and Bollard Pull. Based on the concept, a methodology is proposed for the development of the work, which consists in the implementation of an existing reference method to estimate Bollard Pull and a model created based on artificial neural networks. The model based on neural networks was more accurate for the existing estimation method, presenting mean error and maximum error of approximately 2% and 4%, whereas the method presented values of 6% and 14%.

Key words: artificial neural network, bollard pull, tugboats, design, propellers.

LISTA DE FIGURAS

Figura 1 – a) Rebocador portuário; b) Rebocador oceânico; c) Rebocador costeiro; d) Rebocador de escolta	14
Figura 2 – Propulsor convencional (a); Propulsor azimutal (b); propulsor cicloidal.....	15
Figura 3 – Sistema propulsivo single screw	16
Figura 4 – Sistema propulsivo twin-screw	16
Figura 5 – Composição teórica de uma RNA	20
Figura 6 – Modelo de McCulloch e Pitts	23
Figura 7 – Neurônio artificial	23
Figura 8 – Organização de uma rede neural em camadas	25
Figura 9 – Conexões feedforward entre camadas em uma RNA	25
Figura 10 – Conexões backpropagation	26
Figura 11 – Princípios de funcionamento de uma RNA	27
Figura 12 – Aplicações de RNAs em diversas áreas da engenharia.....	29
Figura 13 – Exemplos de casos de engenharia em que são aplicadas RNAs	30
Figura 14 – Aplicações de RNAs em diversas áreas da engenharia naval.....	31
Figura 15 - Exemplos de casos de engenharia naval em que são aplicadas RNAs	33
Figura 16 - Cabo de reboque tracionado	34
Figura 17 - Bollard Pull por unidade de potência x densidade de potência.....	39
Figura 18 – Fluxograma da metodologia proposta	41
Figura 19 - Palavras-chave utilizadas na construção do banco de dados.....	42
Figura 20 - Etapas de implementação do modelo de RNAs	46
Figura 21 - Sequência de implementação do método da MAN e do modelo de RNAs.....	47
Figura 22 - Possíveis topologias do modelo de RNAs	50
Figura 23 - Layout do programa Synapse	51
Figura 24 - Variáveis que influenciam a topologia neural	52
Figura 25 - Apresentação das embarcações posicionadas ao longo do gráfico de acordo com seu Bollard Pull	55
Figura 26 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 1000 ciclos.....	56
Figura 27 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 10.000 ciclos	57
Figura 28 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 100.000 ciclos	58
Figura 29 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 1.000.000 ciclos	59

Figura 30 - Erro médio e erro máximo do método da MAN e dos modelos RNAs com 1 camada.....	61
Figura 31 - Erro médio e erro máximo do método da MAN e dos modelos RNAs com 2 camadas.....	62
Figura 32 – Comparativo de precisão da rede neural com 6 variáveis de entrada	65

LISTA DE TABELAS

Tabela 1 - Banco de dados de rebocadores twin screw.....	44
Tabela 2 - Embarcações implementadas no método da MAN.....	48
Tabela 3 - Tabela com dados e BP através do modelo da MAN	48
Tabela 4 - Valores das variáveis como dados de entrada das RNAs.....	52
Tabela 5 – Estimativa de Bollard Pull para um rebocador atual	63

SUMÁRIO

1. INTRODUÇÃO	13
1.1 Objetivos	17
1.1.1 Objetivo Geral.....	17
1.1.2 Objetivos Específicos	17
1.1.3 Estrutura e etapas do trabalho.....	18
2. REFERENCIAL TEÓRICO	20
2.1 Redes Neurais Artificiais (RNAs)	20
2.1.1 Conceitos de RNAs	21
2.1.1.1 Conceitos fundamentais das RNAs	22
2.1.1.2 Princípios de funcionamento das RNAs.....	27
2.1.2 Aplicação na Engenharia	29
2.1.3 Aplicação na Engenharia Naval	31
2.2 Bollard Pull	33
2.2.1 Conceito	33
2.2.2 Modelos de estimativa	35
2.2.2.1 Estimativa de Bollard Pull para navios com casco típico de rebocadores	35
2.2.2.2 Estimativa de Bollard Pull através do BHP.....	36
2.2.2.3 Estimativa de Bollard Pull considerando a resistência aerodinâmica e o estado dos mares	37
2.2.2.4 Fórmula simplificada de estimativa do BP.....	37
2.2.3 Modelo de referência para comparativo.....	37
2.3 Motivação do uso de RNAs para cálculo de Bollard Pull	40
3. METODOLOGIA	41
3.1 Construção do banco de dados	42
3.2 Busca por métodos	45
3.3 Criação do Modelo de RNAs	45
3.4 Comparação dos resultados	46
4. DESENVOLVIMENTO	47
4.1 Implementação do método MAN Diesel & Turbo	47
4.2 Implementação do modelo de RNAs	48

4.2.1 Programa Synapse	50
5. RESULTADOS.....	54
5.1 Comparativo entre método da MAN e modelo de RNAs	54
5.2 Diferença média dos resultados	60
5.3 Verificação dos métodos para um rebocador atual	63
5.4 Análise da influência da topologia	63
6. CONSIDERAÇÕES FINAIS	66
6.1 Trabalhos Futuros	67
REFERÊNCIAS	68
ANEXO A	72
ANEXO B	74
APÊNDICE A.....	75
APÊNDICE B.....	78
APÊNDICE C.....	78
APÊNDICE D.....	79
APÊNDICE E.....	80

1. INTRODUÇÃO

Atualmente, o aumento observado no porte dos navios mercantes exigem rebocadores com uma maior capacidade de reboque, o que por sua vez, exige maior força no sistema propulsivo e nas estruturas para atender a demanda dos armadores. É importante que tais aspectos devem ser melhorados sem afetar significativamente a capacidade de manobra de tais embarcações (BALAKRISHNAN, 2016).

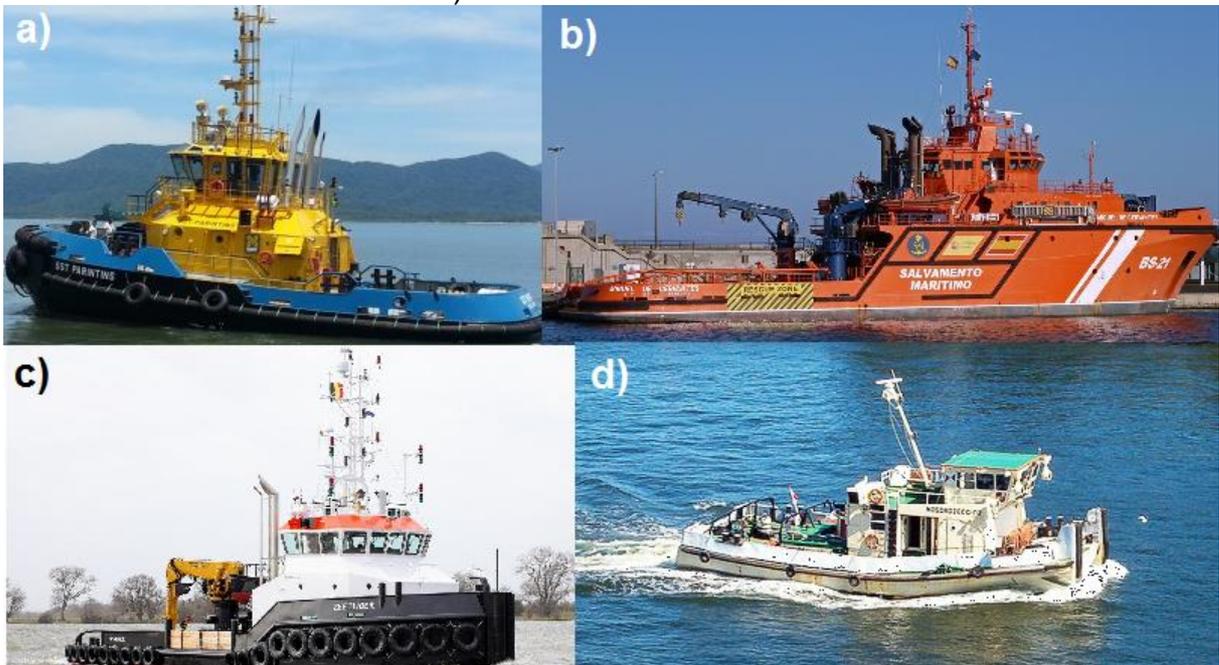
A velocidade com que o estudo para melhorias de projetos é realizado faz com que novas embarcações tenham o conceito de construção baseado em diferentes métodos e técnicas, no qual as grandes organizações têm como foco principal a redução de custos na construção. Com o mercado mais competitivo e globalizado, buscam-se melhores projetos de embarcações, bem como processos de construção mais eficientes.

Dentre os diversos tipos de embarcações, tem-se os rebocadores como embarcações reconhecidas por dar assistência de manobras à outros navios e realizar serviços de salvamento em navios danificados ou em situações de risco (ALLAN, 2012).

Os rebocadores convencionais podem ser classificados de diversas maneiras, sendo mais frequentemente classificados de acordo com dois critérios: locais de operação ou função específica. A U.S. Towing Manual (2002) classifica os rebocadores com base na função que devem cumprir, tais como: rebocadores portuários; rebocadores para operação ponto a ponto; rebocadores de resgate e emergência, rebocadores de salvamento, e rebocadores especiais para operação oceânica.

Já Allan (2012), por sua vez, classifica os rebocadores de acordo com sua área de trabalho e sua função, dividindo-os em: rebocadores portuários de assistência a navios; rebocadores costeiros; rebocadores oceânicos e de salvamento; rebocadores de escolta e rebocadores de rio. Na Figura 1 podem ser observados alguns exemplos de rebocadores conforme a classificação de Allan (2012).

Figura 1 – a) Rebocador portuário; b) Rebocador oceânico; c) Rebocador costeiro; d) Rebocador de escolta



Fonte: Sincoman (2015); Sáez (2010); Damen (2017); Miszewski (2010)

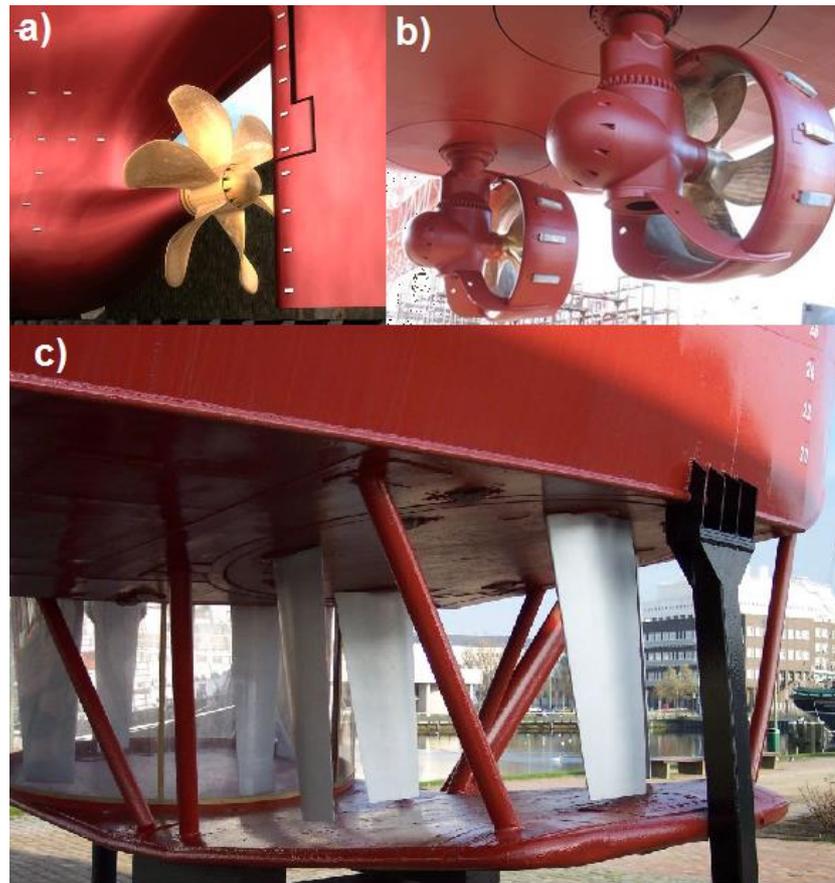
A característica mais importante de um rebocador é a sua potência, que deve estar adequada ao deslocamento dos navios e ao Bollard Pull¹ (SCHEIN, 2010).

De acordo com Allan (2012) os rebocadores são projetados para fornecer força capaz de mover embarcações muito maiores que seu casco. Desta maneira sua potência apresenta-se desproporcionalmente grande, quando comparada a potência de navios de porte similares.

Ainda segundo Allan (2012) existem três grandes grupos de diferentes sistemas propulsivos: propulsores convencionais, propulsores azimutais e propulsores ciclodais (Figura 2).

¹ Refere-se a capacidade de reboque de rebocador. Como o termo Bollard Pull será citado diversas vezes ao longo do texto, será utilizada a sigla BP com o objetivo de apenas resumir a escrita, mantendo a nomenclatura em inglês, amplamente utilizada inclusive no Brasil.

Figura 2 – Propulsor convencional (a); Propulsor azimutal (b); propulsor cicloidal



Fonte: Keywordsuggest (2017); Pacific Marine (2017); Velde (2009)

Além do tipo de propulsão, os sistemas propulsivos convencionais podem se apresentar com arranjos single screw (Figura 3) e twin screw (Figura 4), ou seja, um hélice e dois hélices, respectivamente.

Allan (2012) ainda afirma que os rebocadores com apenas um hélice são raramente construídos atualmente, pois apresentam problemas de manobralidade e limitações de força de reboque, fazendo com que o arranjo twin screw seja o arranjo mais comumente encontrado atualmente.

Os propulsores convencionais também podem apresentar sistemas com tubulões-Kort (Figuras 3 e 4), que são tubos fixos que envolvem o hélice e podem propiciar um aumento da capacidade de reboque em até 30%, mas reduzindo a sua capacidade de governabilidade, criando assim a necessidade de serem associados com lemes mais eficientes (FRAGOSO; CAJATY, 2002).

Figura 3 – Sistema propulsivo single screw



Fonte: Workboatsales.com (2017)

Figura 4 – Sistema propulsivo twin-screw



Fonte: Maritime Journal (2004)

Entre os principais requisitos de projeto para um rebocador, destaca-se a capacidade de reboque, também conhecida como Bollard Pull.

Comumente são realizados testes de Bollard Pull e segundo Candido (2012), deve-se certificar sobre a segurança do local escolhido, da tensão de ruptura do cabo, das condições climáticas, onde estas são normatizadas pelas classificadoras, uma vez que todos estes fatores podem afetar diretamente o resultado final.

Entre os diversos modelos existentes para a estimativa dessa capacidade, destaca-se o método proposto por MAN Diesel & Turbo (2011) , o qual será testado a fim de verificar sua precisão para estimativa do BP em diferentes rebocadores cujos dados foram levantados ao longo desta pesquisa.

As redes neurais artificiais serão utilizadas como nova proposta de modelo de estimativa de Bollard Pull. Elas podem ser implementadas com facilidade na solução de problemas que utilizam banco de dados, visto que sua capacidade de aprendizado permite criar padrões.

Assim, em virtude do exposto acima, sabendo que a estimativa do BP de uma embarcação pode alterar características principais do projeto conceitual, tem-se como sugestão a implementação de um modelo baseado em redes neurais como nova alternativa para estimativa da capacidade de um rebocador ainda nas fases iniciais do projeto.

1.1 Objetivos

Nesta secção são apresentados os objetivos gerais e específicos do trabalho. Por fim, será apresentada a estrutura e as etapas do trabalho, visando demonstrar a sequência das pesquisas e cálculos para que os objetivos fossem alcançados.

1.1.1 Objetivo Geral

Desenvolver uma proposta de modelo baseado em redes neurais artificiais para estimativa da capacidade de Bollard Pull em função das características do projeto conceitual de rebocadores com sistema propulsivo twin screw.

1.1.2 Objetivos Específicos

- Levantar informações sobre rebocadores portuários twin screw atualmente em operação;

- Determinar por meio de análise estatística as características que mais influenciam a capacidade de Bollard Pull de um rebocador;
- Determinar por meio de pesquisa bibliográfica os principais métodos existentes na literatura para a estimativa de Bollard Pull de um rebocador;
- Realizar uma análise de aplicação das redes neurais artificiais na engenharia, visando determinar as possibilidades de aplicação desta técnica ao problema proposto;
- Criar uma proposta para aplicação do conceito de redes neurais por meio de pesquisa exploratória, com importantes atualizações sobre o tema, apresentando uma breve perspectiva sobre sua utilização;
- Comparar a eficácia e a precisão dos diferentes modelos analisados para a predição do Bollard Pull.

1.1.3 Estrutura e etapas do trabalho

Partindo dos objetivos do estudo, realizou-se uma pesquisa exploratória a fim de explanar os principais conceitos que irão compor o problema. Em sequência, da parte da pesquisa que pode ser considerada como descritiva, serão definidas as características de levantamento de dados bem como as verificações dos resultados a fim de viabilizar um novo e mais preciso modelo para o problema proposto. Para relatar o trabalho desenvolvido, esta monografia foi dividida em cinco capítulos:

No primeiro capítulo da pesquisa, após realizar uma contextualização sobre a problemática abordada no trabalho, foram apresentados os principais objetivos e as etapas a serem desenvolvidas.

No segundo capítulo, para início da revisão bibliográfica, realizou-se uma pesquisa para fundamentação teórica sobre Redes Neurais Artificiais², sua aplicação na engenharia e a implementação na engenharia naval.

Após a abordagem sobre as RNAs, apresentou-se um estudo sobre Bollard Pull e seus modelos de estimativa existentes. A partir desses modelos selecionou-se

² Como o termo Redes Neurais Artificiais será citado diversas vezes ao longo do texto, será utilizada a sigla RNAs ou o termo redes, com o objetivo de apenas resumir a escrita.

um método de referência para realização do comparativo e apresentou-se a motivação do uso de redes neurais para este tipo de problema.

O terceiro capítulo descreve a metodologia do trabalho, apresentando como e de que maneira o problema proposto será solucionado. Primeiramente foi realizada uma coleta de banco de dados de rebocadores twin screw, depois foi realizada uma busca por modelos de estimativa do BP, em sequência a criação de um modelo de RNAs e por fim a comparação dos resultados.

No quarto capítulo, como desenvolvimento, foi implementado o modelo comparativo e o modelo das rede. A respeito do modelo criado com o programaSynapse foi apresentado e realizou-se uma análise paramétrica da topologia neural mais adequada para o problema.

No quinto capítulo são apresentados os resultados através de comparativos e da diferença média dos resultados, analisando a influência da topologia da rede.

No último capítulo são apresentadas as considerações finas e as discussões a respeito da implementação adotada e o quão satisfatório os resultados obtidos foram e, por fim, sugestões para futuros pesquisadores a cerca do tema abordado.

2. REFERENCIAL TEÓRICO

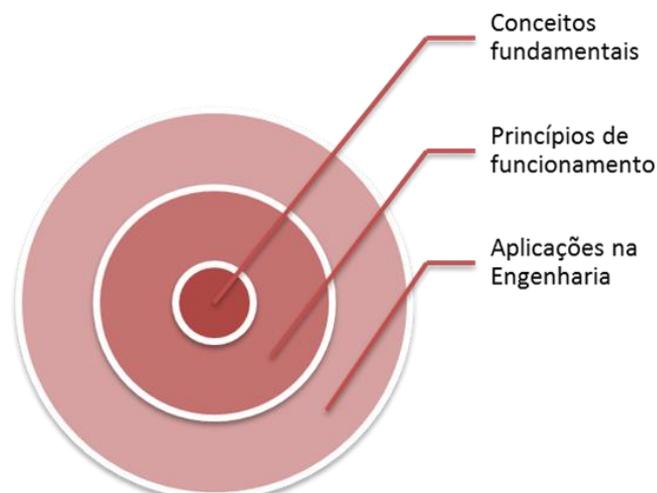
O referencial teórico permite verificar o estado do problema a ser pesquisado, sob o aspecto teórico e de outros estudos e pesquisas já realizadas (MARCONI; LAKATOS, 2003). A partir disso, é possível fundamentar o estudo da maneira que a pesquisa apresente embasamento suficiente para que o problema possa ser resolvido a partir dos conceitos, das teorias clássicas e das pesquisas relacionadas ao tema.

2.1 Redes Neurais Artificiais (RNAs)

Atualmente as buscas por metodologias para resolver problemas característicos de inteligência artificial tem se intensificado (BARRETO, 2002). Dentre as diversas metodologias, métodos e modelos, para a solução destes problemas, a escolha das redes neurais motivou-se principalmente pela sua capacidade de aprendizado e por seu modelo apresentar a capacidade que o cérebro humano possui de reconhecer, associar e generalizar padrões (VELLASCO, 2007).

Na Figura 5 podem ser observados os tópicos em que serão estudados a fim de melhor entender o conceito teórico de uma rede neural.

Figura 5 – Composição teórica de uma RNA



Fonte: Elaborado pelo autor

Vale ressaltar que esta composição de conceitos de uma rede neural foi determinada pelo autor e existem inúmeras outras abordagens a cerca do tema e suas aplicações. Embora seja uma composição que apresenta o conteúdo de forma breve, tem-se como objetivo a apresentação de maneira mais didática sobre o assunto abordado, facilitando a interpretação dos conceitos de RNAs.

2.1.1 Conceitos de RNAs

As RNAs podem ser entendidas como um conjunto de várias unidades de neurônios artificiais interconectados, formando um sistema similar ao cérebro humano. Cada neurônio contém uma pequena porção local de memória e são formados por dendritos e axônios, terminais de entrada e saída de informações, respectivamente (TANCREDI, 2008).

O conceito de RNAs parte de alguns princípios que norteiam sua aplicação. Entre os diversas definições apresentadas na pesquisa elaborada, é possível destacar as seguintes definições de diversos autores do tema, apresentadas de forma cronológica:

- A capacidade de uma rede neural realizar cálculos baseia-se na possibilidade de que possa ser reproduzida parte da flexibilidade e do poder do cérebro humano por meios artificiais (ZURADA, 1992);
- Segundo Regueiro (1995), uma RNA pode ser definida como um sistema de processamento de informação composto por um grande número de elementos de processamento (neurônios), conectados entre si através de canais de comunicação;
- Uma rede neural artificial consiste num processador paralelo distribuído massivamente, composto por unidades de processamento simples que tem uma propensão natural para armazenar o conhecimento experiencial e torná-lo disponível para uso (HAYKIN, 2005);
- Uma rede neural consiste em unidades de processamento simples, representadas por neurônios, com conexões direcionadas e ponderadas entre si (KIRESEL, 2005).

- Redes neurais artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através de experiência. Outra característica importante das redes neurais é a capacidade destas em se adaptarem a cada novo evento, incorporando experiências e preservando a memória do processo (TANCREDI, 2008).

Partindo dos conceitos apresentados, entende-se que as RNAs se diferenciam dos cálculos computacionais tradicionais, estes baseados em algoritmos previsíveis, por sua computação neural permitir o desenvolvimento de sistemas que possam resolver problemas complexos, cuja formulação matemática é de extrema dificuldade. Apesar dos cálculos computacionais apresentarem evolução ao longo dos anos e as tecnologias serem aprimoradas constantemente, a busca por um sistema mais similar ao cérebro humano fomentou o desenvolvimento de códigos dessa natureza.

Para um melhor entendimento faz-se necessário uma breve apresentação dos conceitos fundamentais das RNAs e também de seus princípios de funcionamento.

2.1.1.1 Conceitos fundamentais das RNAs

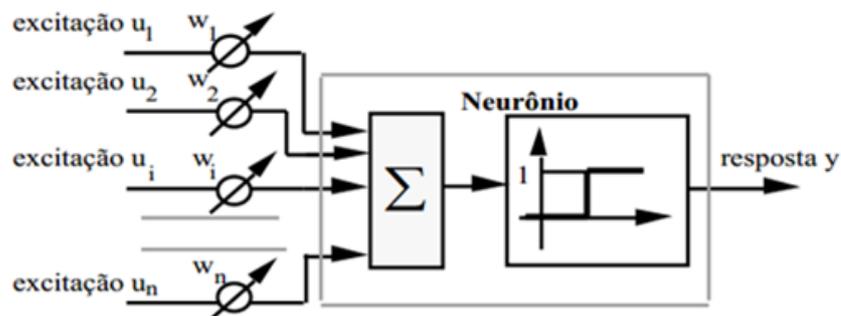
Redes neurais artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligente e que adquirem conhecimento através da experiência (TANCREDI, 2008). A partir dos seus conceitos fundamentais torna-se possível um melhor entendimento do processo de cálculos que ocorrem dentro da rede.

A topologia de uma rede neural artificial se refere às diferentes composições estruturais possíveis com diferentes quantidades de neurônios nas camadas de entrada, intermediária e de saída da rede. Estes neurônios poderão ser conectados de diversas maneiras e treinados de acordo com os algoritmos que estabelecem suas conexões.

A construção de RNAs tem inspiração nos neurônios biológicos e nos sistemas nervosos. Um dos primeiros modelos de neurônios foi proposto por McCulloch-Pitts em 1943. Cabe ressaltar que a intenção deste modelo era de imitar

a realidade biológica, preocupação não compartilhada por muitos pesquisadores atuais (BARRETO, 2002). O modelo de McCulloch-Pitts, apresentado na Figura 6, surgiu a partir da interpretação do funcionamento de um neurônio e sua entrada de forma binária, gerando a partir de uma combinação por uma soma ponderada de várias entradas, uma entrada real do neurônio.

Figura 6 – Modelo de McCulloch e Pitts

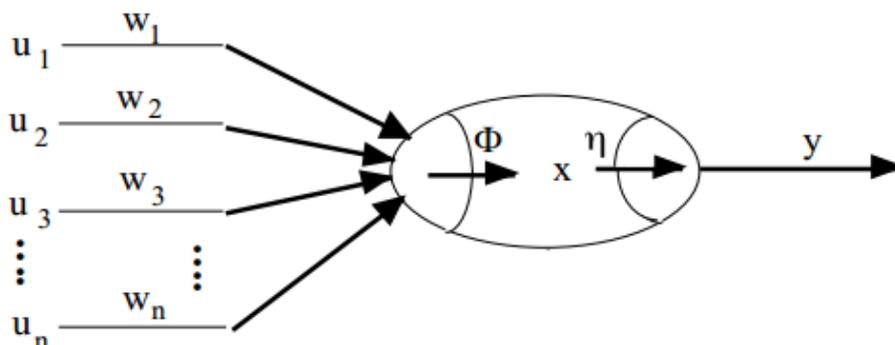


Fonte: Adaptada de Barreto (2002)

A partir deste somatório de diversas entradas binárias em cada neurônio, uma função definida como função de transferência ou função neural calcula a resposta do neurônio.

O modelo geral de um neurônio artificial, a partir do modelo de McCulloch-Pitts pode ser visualizado na Figura 7, no qual as entradas (u_n^1) são combinadas com pesos (w_n^1) e limites de ativação utilizando uma função Φ , no qual a saída do neurônio será produzida numa função η . Segundo Barreto (2002), esta saída é correspondente à frequência de descarga do neurônio biológico

Figura 7 – Neurônio artificial



Fonte: Adaptado de Barreto (2002)

Segundo Tancredi (2008) os neurônios se comunicam através de sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles.

Com relação ao número de neurônios nas camadas, estes geralmente são definidos empiricamente, porém não devem ser utilizados em grandes quantidades pois podem fazer com que a rede memorize os dados de treinamento, ocasionando o fenômeno denominado como overfitting. Este fenômeno faz com que a rede não extraia as características gerais que permitirão a generalização dos dados (SILVA; OLIVEIRA, 2007).

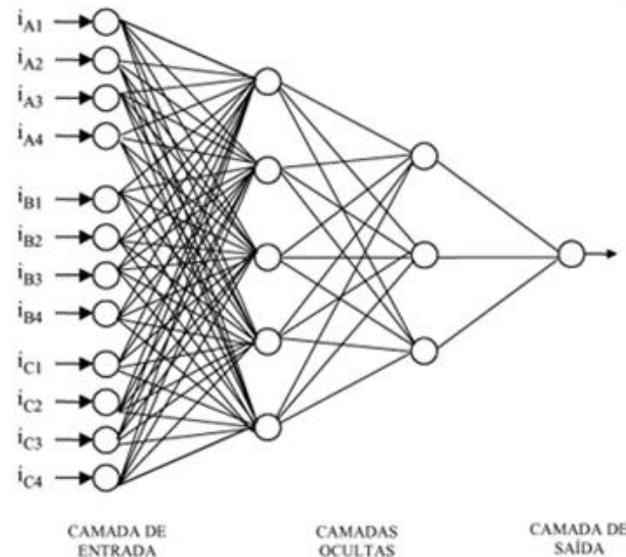
Para evitá-lo, é desejável que o modelo da rede seja o mais simples possível, pois assim será dada mais importância às maiores regularidades nos dados e as menores serão ignoradas, pois essas podem ser resultantes de divergências. Também é possível evitar esse problema aumentando o número de padrões de treinamento (ciclos), utilizando padrões que representem o máximo de variações possíveis dos dados (THEODORIS, 1999).

Segundo Silva e Oliveira (2007), recomenda-se então um número baixo de neurônios mas não tão baixo quanto o estritamente necessário, pois se não pode ocorrer o fenômeno denominado underfitting, levando a rede a não convergir durante o processo de treinamento.

Outro conceito fundamental sobre as RNAs é definido como camada. Normalmente as camadas são representadas como o formato em que as redes são dispostas. Nas camadas de entrada estão os neurônios que recebem o sinal de excitação, enquanto nas camadas de saída estão os neurônios que pertencem à saída da rede (BARRETO, 2002). Vale ressaltar que uma rede pode apresentar diversas camadas como pode ser visto na Figura 8, porém segundo Silva e Oliveira (2007) a utilização de um grande número de camadas não é recomendado, pois durante o treinamento a cada vez que o erro médio³ é utilizado para atualizar os pesos das sinapses das camadas, ele se torna menos útil ou preciso.

³ O erro médio tem será o fator que irá encerrar o treinamento após o erro médio quadrático da rede ficar abaixo do seu valor, pré-definido no início da execução da rede. Comumente o erro médio é utilizado como um valor muito próximo de zero. Ex: 0,0001.

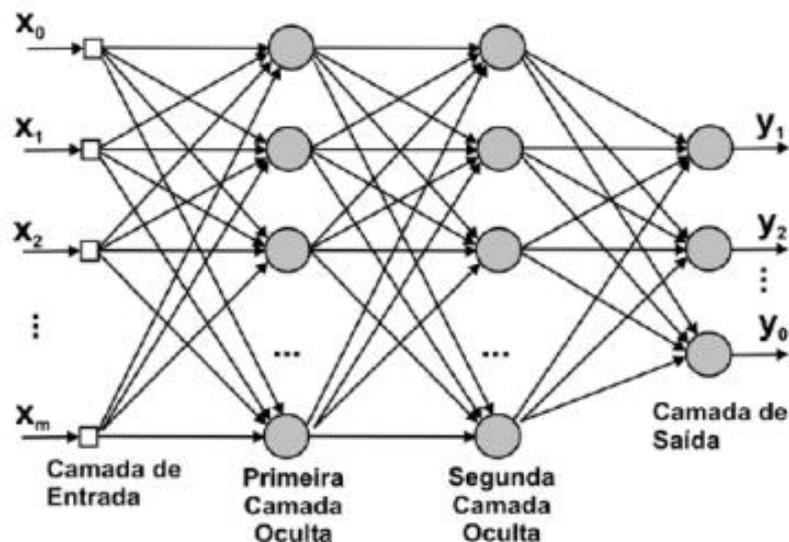
Figura 8 – Organização de uma rede neural em camadas



Fonte: Segatto (2008)

As camadas podem se apresentar em dois diferentes métodos, feedforward ou backpropagation. O método feedforward define que cada camada se conecta à próxima, porém não há caminho de volta durante as sinapses. Todas as conexões portanto, têm a mesma direção, partindo da camada de entrada em direção à camada de saída (RUELA, 2012). A Figura 9 demonstra o método feedforward de conexões entre camadas.

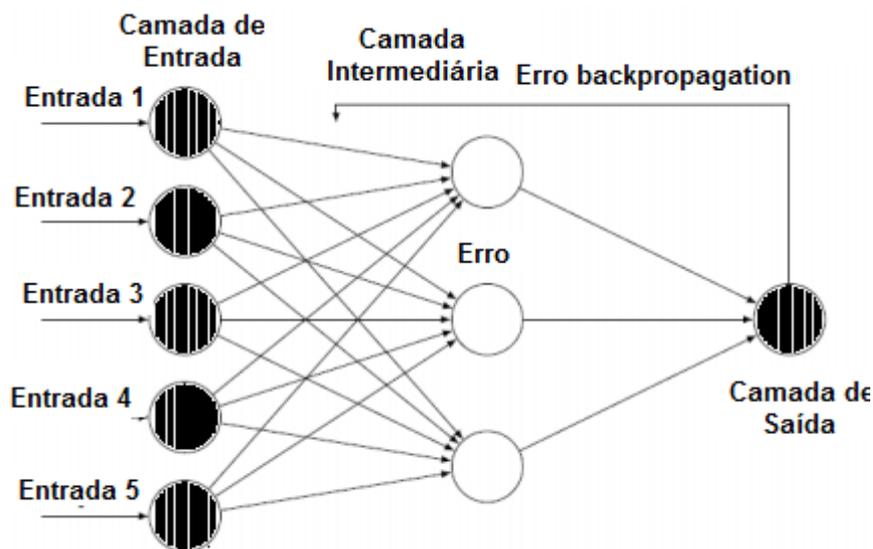
Figura 9 – Conexões feedforward entre camadas em uma RNA



Fonte: Ruela (2012)

O backpropagation é outro método de representação das camadas e através dele é possível definir como a rede será treinada. Este algoritmo se trata de um treinamento supervisionado, onde a partir do erro calculado, são realizadas correções dos pesos nas camadas, partindo da saída até a entrada. Como pode ser visto na Figura 10, o algoritmo retorna para as camadas intermediárias em busca de resultados mais precisos.

Figura 10 – Conexões backpropagation



Fonte: Adaptada de Ruela (2012)

O treinamento de uma rede neural é outro conceito fundamental para o entendimento de seu comportamento. O treinamento supervisionado de uma rede utilizando backpropagation consiste em dois passos. No primeiro, um padrão é apresentado às unidades da camada de entrada e, a partir desta camada as unidades calculam sua resposta que é produzida na camada de saída. O erro é calculado e no segundo passo, este é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados utilizando a regra delta generalizada.

Depois que a rede estiver treinada e o erro estiver em um nível satisfatório, ela poderá ser utilizada como uma ferramenta para classificação de novos dados (FINNOCHIO, 2014).

Segundo Tancredi (2008) o desenvolvimento do algoritmo de treinamento backpropagation resultou no modelo de redes neurais artificiais mais utilizado atualmente, as redes Multilayer Perceptrons (MLP), no qual o erro obtido entre a

resposta calculada e a resposta original é propagado, modificando-se os pesos das conexões. Dessa maneira o erro progressivamente é diminuído a cada padrão apresentado.

Um problema comum que pode ser observado no treinamento das redes é o overtraining. Este problema ocorre quando a rede é treinada com muitas iterações de treinamento. A consequência desse fato faz com que a capacidade de generalização da rede seja reduzida, proporcionando falhas quando esta for utilizada para classificar padrões não pertencentes ao conjunto de treinamento (CAMPOS, 2000).

2.1.1.2 Princípios de funcionamento das RNAs

As redes neurais se comportam com características similares a de um neurônio biológico. Com base nisso, segundo Hilera e Martínez (2000) o funcionamento das redes neurais baseiam-se em cinco princípios de funcionamento, apresentados na Figura 11.

Figura 11 – Princípios de funcionamento de uma RNA



Fonte: Adaptado de Hilera e Martínez (2000)

Os princípios de funcionamento das redes neurais explanam as principais características do método, descritos da seguinte maneira:

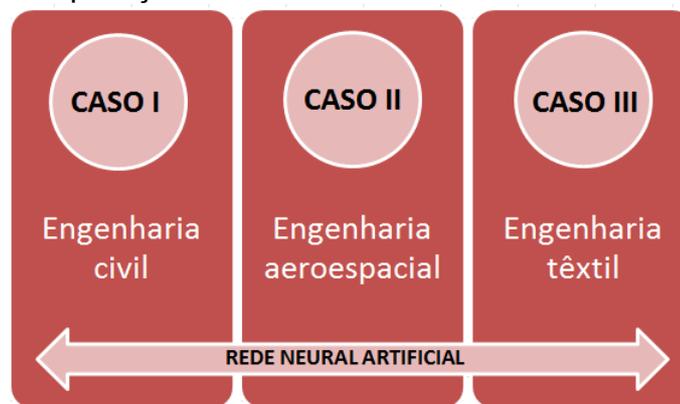
- **Aprendizagem adaptativa:** característica mais importante das RNAs já que podem se comportar em função de um treinamento com uma série de exemplos. Desta forma, não é necessário elaborar um modelo prioritário, nem estabelecer funções probabilísticas. Uma RNA é adaptativa porque pode modificar-se constantemente com o objetivo de adaptar-se à novas condições de trabalho;
- **Auto-organização:** como a aprendizagem é um processo onde se modifica a informação interna da rede, a auto-organização consiste na modificação de toda a rede com o propósito de atingir um objetivo específico, ou seja, a auto-organização é um princípio que significa generalização, possibilitando a rede uma resposta à dados ou situações que não tenha experimentado antes, mas que pode interferir na sua base de treinamento. Está informação é muito útil quando a informação de entrada é pouco clara ou se encontra incompleta;
- **Tolerância à falhas:** na computação tradicional a perda de um fragmento pequeno de informação pode acarretar comumente na inutilização do sistema, já nas RNAs a tolerância à falhas entende-se em dois sentidos: primeiro, as redes podem reconhecer padrões de informações com ruídos, distorções ou até mesmo incompletos (tolerância à falhas com respeito às informações); e segundo, podem seguir trabalhando, com certa degradação, sem danificar parte da rede (tolerância à falhas com respeito à estrutura);
- **Operação em tempo real:** de todos os métodos existentes, a RNA é o método mais indicado para o reconhecimento de padrões em tempo real, devido a trabalharem em paralelo, atualizando todas suas instâncias simultaneamente;
- **Fácil inserção na tecnologia existente:** é relativamente simples obter chips especializados para redes neurais que melhoram sua capacidade em determinadas tarefas. Isso facilita a integração modular dos sistemas existente.

Após seus conceitos fundamentais e princípios de funcionamento serem discutidos, serão apresentadas brevementes algumas aplicações das RNAs em problemas de engenharia, bem como sua implementação na área da engenharia naval.

2.1.2 Aplicação na Engenharia

A RNA é um modelo que pode ser aplicado em inúmeras áreas, desde para solução de problemas simples até os mais complexos. Apesar do caso de estudo ser uma aplicação real na área de engenharia naval, como uma breve introdução da aplicação deste modelo são apresentadas aplicações em outras áreas da engenharia Figura 12.

Figura 12 – Aplicações de RNAs em diversas áreas da engenharia



Fonte: Elaborado pelo autor

O Caso I utiliza as RNAs no dimensionamento de seção transversal de vigas retangulares em concreto armado (LASTIRI; PAULETTI, 2004). Este caso tem como proposta o desenvolvimento de uma rede neural capaz de relacionar de forma coerente dados utilizados para o dimensionamento da viga com os resultados do dimensionamento real. Para este treinamento foram utilizados 500 casos distintos, entretanto apenas 15 destes casos podem ser observados no Anexo A. Para a implementação da rede foram utilizadas planilhas eletrônicas, devido a simplicidade de programação das células para treinamento da rede bem como a grande disponibilidade deste tipo de programa em qualquer computador.

Como no do Caso I o erro relativo final obtido nos testes para os valores reais do problema foi inferior ao limite pré-estabelecido, concluiu-se que a rede foi treinada com sucesso.

Um outro caso descreve o uso de uma rede neural artificial aplicada à classificação automática de descontinuidades em chapas de compósito laminado de alumínio e epóxi reforçado por fibra de vidro (LOPES, 2010). O Caso II aborda o fato

de os compósitos serem largamente empregados em peças de aviões por apresentarem vantagens como elevada rigidez associada a uma baixa massa específica, além de longo tempo de vida útil e diversidade de aplicações devido à flexibilidade quanto ao formato do laminado. Sua proposta é desenvolver novas metodologias de avaliação estrutural de chapas em compósito laminado, realizando uma varredura ultrassônica na configuração pulso eco por imersão em corpos de prova de compósito laminado de alumínio e epóxi, reforçado por fibra de vidro com três diferentes configurações: sem qualquer defeito, com delaminação e com fratura da fibra. Na Figura 12 (Caso II) é possível visualizar um projeto tridimensional de uma asa de avião que pode ser produzida com o material do caso abordado.

No Caso II, os resultados da RNA foram satisfatórios, visto que foi possível detectar e qualificar danos através de sinais ultrassônicos.

O Caso III apresenta a aplicação de redes neurais artificiais na indústria de fios de algodão (ANTONELI; NEITZEL, 2015). A partir das características físicas das fibras de algodão é possível decidir sua forma de consumo e ajustar variáveis para o processo de fiação. O treinamento da rede foi realizado a partir das características presentes no Anexo A, com o objetivo de determinar a qualidade do fio de algodão.

Neste caso, provou-se que é possível determinar a qualidade do fio através das RNAs, entretanto, um fato limitante no uso dos resultados obtidos, está na seleção dos dados utilizados no processo de treinamento da rede, ou seja, a limitação de um determinado tipo de fio devido à suas características pode ocasionar em uma limitação na estimativa de qualidade.

Na Figura 13 é possível visualizar o exemplo real dos 3 casos de engenharia em que são aplicadas RNAs como modelo de estimativa.

Figura 13 – Exemplos de casos de engenharia em que são aplicadas RNAs

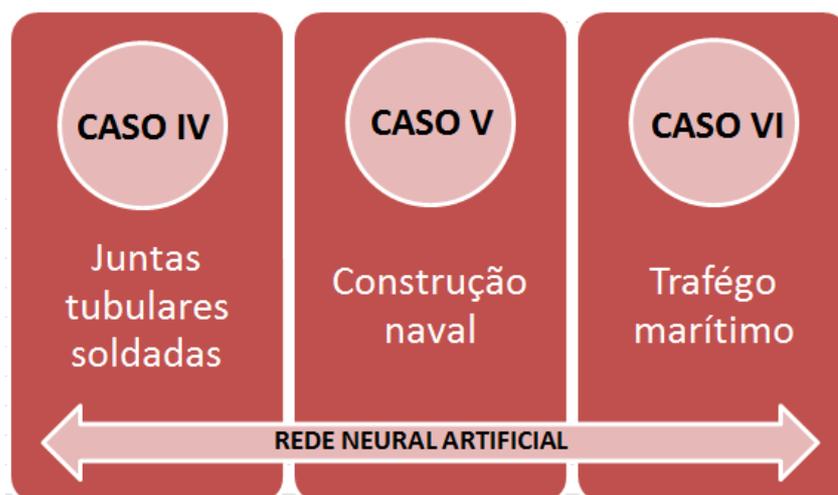
CASO I	CASO II	CASO III
		
Fonte: Cava (2016)	Fonte: Milatias (2014)	Fonte: IncoFios (2017)

2.1.3 Aplicação na Engenharia Naval

Na área de engenharia naval, não diferente das demais áreas em que podem ser aplicadas, as redes neurais podem ser encontradas em diversos tipos de problemas. Nesta seção são apresentados alguns exemplos de aplicação, conforme enumerados na Figura 14.

Vale destacar que apesar dos casos apresentarem-se como possíveis abordagens da engenharia naval, eles não possuem praticamente nenhuma relação entre si, o que prova como a aplicação de uma RNA pode ser abrangente em diversos temas e problemas.

Figura 14 – Aplicações de RNAs em diversas áreas da engenharia naval



Fonte: Elaborado pelo autor

O Caso IV consiste na aplicação de redes neurais artificiais na avaliação de concentração de tensões em juntas tubulares soldadas (CARDOSO, 1999). Nesse trabalho propõem-se uma alternativa para o cálculo do fator de concentração de tensões em juntas tubulares soldadas.

As redes neurais foram utilizadas para representar a distribuição de tensões ao longo da junta tubular para os casos de carregamento de força axial e momento fletor no plano. O conjunto de dados utilizado foi formado a partir de simulações numéricas nas juntas com o auxílio da mecânica de elementos finitos, considerando parâmetros geométricos do tubo soldado e do próprio cordão de solda. Como diferencial do resultado deste modelo, é possível observar que a RNA permite obter

uma distribuição de tensões ao longo do comprimento da junta soldada, ao invés das tradicionais equações paramétricas, que permitem determinar somente os valores máximos de tensões. Desta maneira, a RNA apresenta-se como um modelo pioneiro na representação da distribuição de tensões em juntas soldadas.

A aplicação de RNAs observada no Caso V aborda ferramentas de análise inteligente aplicadas ao planejamento e controle da construção naval (SOUZA, 2011), tendo como objetivo do estudo, o desenvolvimento de um sistema baseado em inteligência artificial, com o uso de redes neurais artificiais, possibilitando a melhoria do agregamento das diferentes partes estruturais dos navios, identificando os diversos elementos de uma família de produtos e os agrupando de acordo com atributos de projeto e de produção, utilizando os princípios da tecnologia de grupo de forma a mobilizar recursos específicos em sua concepção e também minimizar custos.

Para isso, foi utilizado um banco de dados com um total de 30 blocos de construção de um navio tanque⁴, como pode ser observado no Anexo A, e em todos os testes as redes apresentaram resultados adequados, validando a proposta inicial do estudo e indicando a possibilidade do seu uso em situações reais e em aplicações aos sistemas de produção de estaleiros.

O Caso VI de estudo é apresentado em (DARANDA, 2016). Este modelo de aplicação das RNAs considera como motivação para sua implementação o aumento do tráfego marítimo e o problema de prevê-lo devido ao fato de que os movimentos dos navios não serem facilmente identificados. Além disso, os dispositivos mais modernos de navegação apresentam algumas informações de maneira incompleta, devido às dificuldades do meio em que se captadas (alto-mar), dificultando o uso do piloto automático mesmo em trechos curtos. A RNA deste modelo tem com objetivo determinar a posição do navio através de sua longitude e latitude, a partir dos dados de entrada da embarcação como: velocidade, tamanho, tipo de casco, dimensões e número de identificação.

Como resultado, concluiu-se que a rede tem a capacidade de prever o tráfego marítimo de maneira satisfatória, podendo ser utilizado como aviso prévio e sistema de prevenção para colisões. Ainda pode ser entendido que o tráfego marítimo pode ser analisado estatisticamente e determinado por predição e que este

⁴ O navio-tanque é um navio projetado para o transporte de líquidos a granel. Os principais tipos são os petroleiros e graneleiros.

modelo pode ser utilizado para determinar num trabalho futuro o fluxo de tráfego marítimo. Na Figura 15 é possível visualizar um exemplo real dos casos de aplicação de redes neurais na engenharia naval.

Figura 15 - Exemplos de casos de engenharia naval em que são aplicadas RNAs

CASO IV	CASO V	CASO VI
		
Fonte: IST/FUNDEC (2015)	Fonte: Diaz (2014)	Fonte: Daranda (2016)

Com o conceito de redes neurais já definido e suas possíveis aplicações para problemas de engenharia, torna-se possível dar sequência ao trabalho, definindo o conceito de Bollard Pull.

2.2 Bollard Pull

Com o objetivo de esclarecer o conceito de Bollard Pull e relevar sua importância como parâmetro de projeto de um rebocador, será apresentada sua definição, seus modelos para estimativa, o método de referência a ser comparado com o modelo proposto e a motivação da utilização do mesmo neste cenário.

2.2.1 Conceito

Entre diversas bibliografias existentes, o termo Bollard Pull é apresentado com diversa definição. Para que seja realizado um entendimento com clareza deste conceito, foram consideradas as definições de dois autores:

- Segundo Candido (2012), Bollard Pull pode ser traduzido como tração estática e representa a capacidade de reboque estático de uma embarcação;

- O Bollard Pull é a força de tração estática de uma embarcação, normalmente utilizada como medida de força aplicável de cada rebocador a ser utilizado em uma manobra (GERENT, 2010);

A partir disso, podemos afirmar que o BP de uma embarcação é entendido como um dos critérios de projeto mais importantes para o armador de um rebocador, visto que a principal finalidade deste tipo de embarcação é a realização do reboque.

Além disso, fatores como o diâmetro do hélice e a potência da embarcação são essenciais para que o BP não seja super dimensionado, tendo como consequência maiores custos de construção do projeto.

Esta força de tração é exercida por um navio em potência total, ou seja, o valor da carga de tração que deve ser imposta ao cabo de reboque. Na Figura 16 é possível visualizar um cabo de reboque tracionado e conectado à uma embarcação.

Figura 16 - Cabo de reboque tracionado



Fonte: Surveyor's Lexicon (2002)

Para que a embarcação seja avaliada num teste de tração mínima, após sua construção, comumente é exigido um teste de Bollard Pull. Neste teste assume-se que o rebocador tenha velocidade de avanço igual a zero e plena rotação do motor. A partir disso, é gerado empuxo máximo através do propulsor da embarcação e avaliada a força de tração (Bollard Pull), sendo uma medição da capacidade de reboque de um determinado navio.

Por ser um requisito de grande parte dos armadores, segundo Bruning (2014) este parâmetro é de grande importância do ponto de vista comercial e contratual de um rebocador.

2.2.2 Modelos de estimativa

Devido a complexidade do BP ser estimado, alguns modelos que possibilitam uma estimativa aproximada são pouco utilizados. Existem modelos que definem o BP do rebocador a partir da geometria de rebocadores e outras características. A seguir são apresentados diversos modelos aproximados⁵ para estimativa do Bollard Pull com base em ZAHALKA (2005).

2.2.2.1 Estimativa de Bollard Pull para navios com casco típico de rebocadores

O primeiro modelo estima o BP através da geometria da embarcação e de outros dados como velocidade de reboque, número de propulsores e de um coeficiente do equipamento de reboque. Na equação 1

$$R = \frac{2,5 (R_1 + R_2 + R_3)}{2240} \quad (1)$$

$$R_1 = F * S * V^2 \quad (2)$$

Onde,

$$F = 0,01$$

S = superfície molhada (pés²)

$$S = 1,025 * L_{pp} * (C_b * B + 1,7T) [m^2] \quad (3)$$

Onde,

L_{pp} = comprimento entre perpendiculares [m]

⁵ ZAHAKLA (2005) aborda os modelos com modeos grosseiros ou aproximados através do termo “rough”. Segundo o autor, isso se aplica a todos os diferentes tipos de diferentes tipos de sistemas de propulsão e podem fornecer diferentes valores de Bollard Pull.

T = calado [m]

B = boca [m]

C_b = coeficiente de bloco

V = velocidade de reboque [nós]

1 pé² = m² * 10,764262

1 nó = m/s * 0,514444

$$R_2 = D^2 * V^2 * N \quad (4)$$

Onde,

D = diâmetro do propulsor [m]

V = velocidade de reboque [nós]

N = número de propulsores

$$R_3 = 0,1 * R_2 \quad (5)$$

Onde,

R_3 = coeficiente do equipamento de reboque

Esta fórmula fornece um valor de Bollard Pull correspondente à resistência hidrodinâmica do navio em águas calmas, porém outros fatores como a rugosidade da área submersa, o encalhe do reboque, a resistência aerodinâmica e o estado do mar são desconsiderados. Um fator multiplicador entre 2 e 3, dependendo das circunstâncias, pode ser adequado.

2.2.2.2 Estimativa de Bollard Pull através do BHP

O BHP é calculado utilizando a fórmula abaixo e a partir dele será possível estimar o BP em toneladas.

$$BHP = \frac{\left[D * \left(\frac{2}{3} \right) * v^2 \right]}{120} \quad (6)$$

A partir do cálculo do BHP conforme a equação (2), o Bollard Pull pode ser definido conforme a equação (2.1).

$$BP = \frac{BHP}{100} * 1,4 \quad (7)$$

2.2.2.3 Estimativa de Bollard Pull considerando a resistência aerodinâmica e o estado dos mares

$$BP = [(D^{\frac{2}{3}} * v^3)]/7200 + (C_{mw} * B * D_1)] * K \quad (8)$$

Onde,

D = deslocamento do rebocador [ton]

v = velocidade de reboque [nós]

C_{mw} = coeficiente de velocidade média do vento

B = boca do rebocador [m]

D_1 = Altura da área de revestimento do vento acima da água

K = fator de 3 à 8, dependendo das circunstâncias

2.2.2.4 Fórmula simplificada de estimativa do BP

$$BP = \frac{Deslocamento * 60}{100.000} + 40 \quad (8)$$

Em casos em que o Bollard Pull real é acima de 40 toneladas esta fórmula não é aplicada.

2.2.3 Modelo de referência para comparativo

O modelo teórico será utilizado na comparação de resultados com a rede neural artificial com o objetivo de validação de um novo modelo implementado como técnica de estimativa do Bollard Pull de rebocadores twin screw. Foi considerado

como requisito para seleção do modelo de referência as suas capacidades de precisão na estimativa do Bollard Pull.

Desta maneira o método selecionado é o seguinte:

- MAN B&W Diesel, baseado no artigo “Propulsion of Offshore Support Vessels” (2011);

O modelo da MAN é descrito através de um artigo desenvolvido desde 1904, que tem como objetivo ser a fonte única para projetos de sistemas de propulsão de embarcações de apoio costeiro.

Segundo o artigo da MAN Diesel & Turbo (2011), o recente progresso tecnológico realizado ao redor do mundo no campo de propulsão de embarcações apresenta soluções de propulsão que envolvem muitas partes, tais como proprietários de embarcações, estaleiros, consultores/fabricantes de navios e fornecedores. A melhor solução para o cliente requer uma estreita cooperação e coordenação entre todas as partes e o mais recente desenvolvimento é complementado pelos resultados dos testes de modelos.

Além da potência do motor, o diâmetro do hélice é o segundo fator mais importante na determinação do Bollard Pull. Com base em um estudo teórico dos resultados do modelo em tanque de provas, correlacionando com medidas em escala real, uma nova formulação refinada foi realizada (MAN Diesel & Turbo, 2011). Vale ressaltar que a potência do motor pode ser inserida como BHP, pois ambas representam a potência de freio do propulsor da embarcação, apresentando-se apenas em unidades dimensionais diferentes.

A potência entregue no propulsor comumente está disponível no sistema internacional de unidades (SI) como Watt (W) e a BHP como horsepower (hp). Para arredondamento dos cálculos no banco de dados considerou-se que cada 1kW de potência pode ser convertido em 1,34 hp de BHP.

Na equação 8 é possível visualizar como será definida a densidade de potência do rebocador que posteriormente será utilizada para definir o Bollard Pull de acordo com a Figura 17.

$$\rho = \frac{P_d}{\frac{\pi}{4} D_p^2} \quad (8)$$

Onde,

ρ = densidade de potência

P_d = potência entregue no propulsor

D_p = diâmetro do propulsor

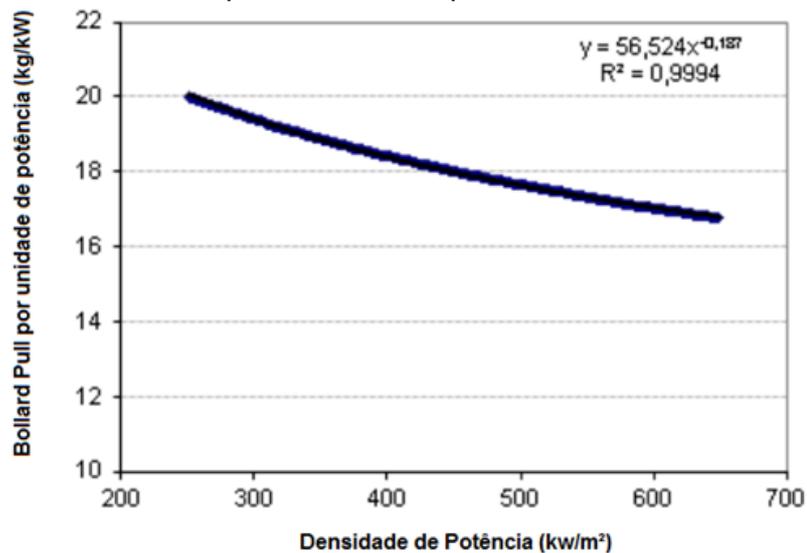
1 horsepower (hp) = 745,6999872W

1 kW \approx 1,34 hp

Ainda é possível observar na Figura 17 que existirá um intervalo específico de densidade de potência para que o BP possa ser calculado, ou seja, para um Bollard Pull muito pequeno ou muito grande, o método não pode ser aplicado, visto que foi baseado em modelos reais de rebocadores convencionais com dimensões dentro de padrões de construção.

É possível ressaltar que a curva de determinação do Bollard Pull também apresentará uma equação. Esta equação auxiliará nos cálculos futuros que estimarão o BP para os rebocadores selecionados.

Figura 17 - Bollard Pull por unidade de potência x densidade de potência



Fonte: Adaptado de Tancredi e Andrade (2013)

A partir da equação que associa a curva de densidade de potência é possível estimar o BP de diversos rebocadores desde que sejam fornecidos os dados de entrada do sistema propulsivo como diâmetro do propulsor e BHP.

2.3 Motivação do uso de RNAs para cálculo de Bollard Pull

Com base nos modelos já existentes, foram analisadas as bibliografias em que são estimados Bollard Pull de embarcações a partir de suas características principais. Além de poucos estudos serem realizados nessa área, a dificuldade de estimar o BP de um rebocador foi um grande fator que motivou a implementação de um novo método. Apesar da formulação existente da MAN Diesel & Turbo apresentar como base embarcações em que foram realizados testes com modelos reais, ela possui suas limitações, não podendo ser aplicada para embarcações com outras características – diferentes intervalos de potência e Bollard Pull.

A rede neural é um modelo que pode ser implementado em diversas áreas, como apresentado anteriormente, e sua aplicação não possui limitações quanto à estudos não realizados, apenas é preciso que seja adotada uma estratégia de treinamento e implementação de rede para que os resultados desejados possam ser obtidos.

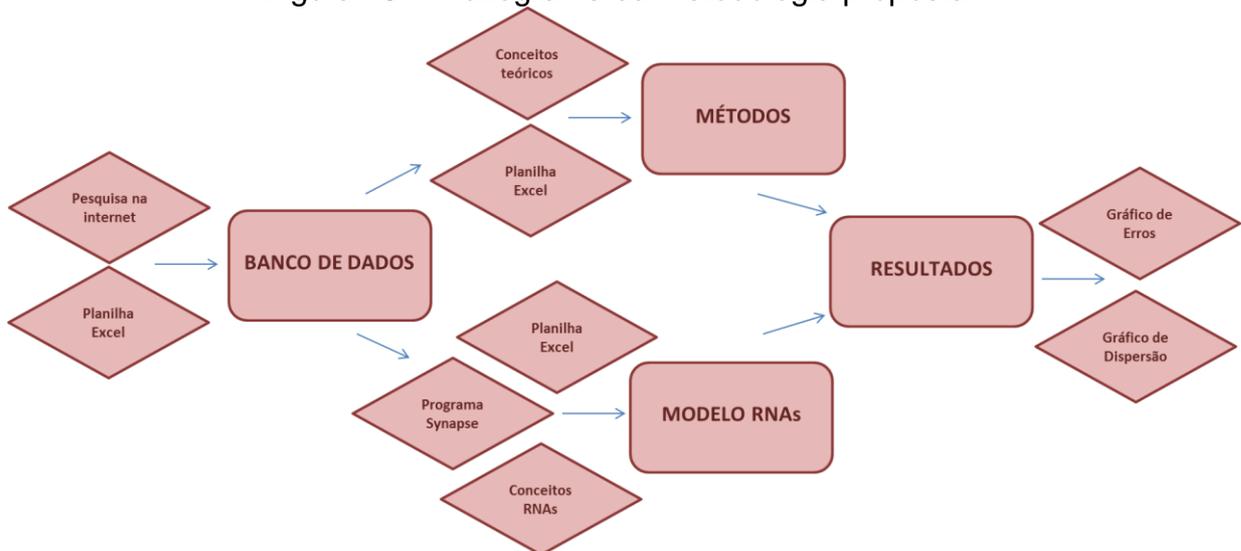
A RNA, através de sua implementação, permite que sejam utilizados diferentes modelos de embarcações, e, a partir de dados reais, é possível criar um modelo em que novos projetos possam ser realizados a partir deste estudo. Apesar de apresentar-se na teoria como melhor solução que cálculos computacionais tradicionais e ter a capacidade de solucionar problemas complexos como o caso de estudo, a rede dependerá de um banco de dados que apresente informações confiáveis e com uma grande variedade de tipos de embarcações para uma maior abrangência. Devido ao método da MAN apresentar sua equação para embarcações com sistema propulsivo twin screw, foram selecionadas apenas embarcações que apresentam esta característica.

Para que seja possível implementar utilizar as RNAs para o cálculo do BP, primeiramente é apresentada uma metodologia com destaque para as ferramentas que serão utilizadas.

3. METODOLOGIA

A implementação de um novo modelo para um determinado problema é um fator fundamental para que possam ser avançados os estudos do tema através da avaliação de sua capacidade em relação aos métodos já existentes. Para a implementação do método, de maneira inovadora, como metodologia proposta para o auxílio da solução deste problema de engenharia, foram realizadas etapas sequenciais que definem a estratégia apresentada como mais adequada, bem como as ferramentas que possibilitarão que o objetivo seja alcançado. Na Figura 18 é possível observar o fluxograma da metodologia proposta, dividida em quatro grandes etapas.

Figura 18 – Fluxograma da metodologia proposta



Fonte: Elaborado pelo autor

Como primeira etapa da metodologia, faz-se necessário uma construção de banco de dados de rebocadores que será utilizado na implementação do novo modelo, no qual são apresentados os principais dados técnicos das embarcações e variáveis que serão utilizadas no novo modelo proposto.

A partir da construção do banco de dados é realizada uma busca por modelos teóricos para a implementação de cada método no problema proposto.

Em seguida, com o auxílio do programa Synapse e de uma planilha Excel criou-se um modelo de redes neurais artificiais que estimasse o BP a partir do

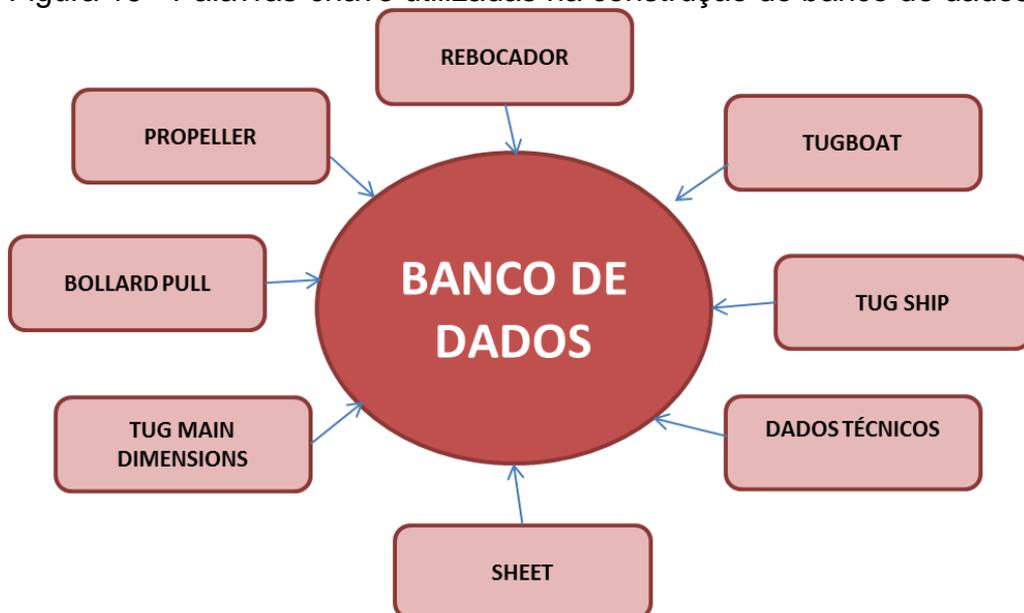
diâmetro do propulsor e da BHP (brake horse power) como dados de entrada dos rebocadores.

Por fim, os resultados obtidos através dos diferentes modelos foram comparados com o objetivo de validar o novo método e ser uma proposta mais precisa na estimativa do BP de rebocadores.

3.1 Construção do banco de dados

Nesta etapa são apresentados os resultados do levantamento de dados sobre os atributos e principais características de rebocadores. O banco de dados de embarcações foi construído parcialmente através de pesquisas na internet com a utilização de termos que pudessem facilitar as buscas. Os termos utilizados, como podem ser vistos na Figura 19, possibilitaram o levantamento de dados técnicos das embarcações.

Figura 19 - Palavras-chave utilizadas na construção do banco de dados



Fonte: Elaborado pelo autor

Apesar de serem pesquisados e encontrados embarcações para a construção do banco de dados, a grande parte de dados técnicos de embarcações foram encontradas na referência bibliográfica (SANTOS, 2016).

O objetivo da construção deste banco de dados é a obtenção de informações que permitam estabelecer padrões utilizados como dados de entrada na rede implementada. Desta maneira, como pode ser observado na Tabela 1, são apresentados rebocadores com características similares, em que os dados de relevância serão utilizados para verificação do modelo de referência. Além desta verificação inicial de precisão do método selecionado estes dados também serão introduzidos no modelo proposto das redes neurais, a fim da verificação e validação do novo modelo para estimativa do Bollard Pull.

É válido ressaltar que foram selecionados 40 rebocadores com construção até o ano de 2012 (Apêndice A) e um rebocador atual, construído em 2016 (Anexo B).

Conforme Fragoso e Cajaty (2002), a principal característica de um sistema propulsivo azimutal é o fato de os hélices não precisarem de leme para governo, pelo fato de seus propulsores possuírem a capacidade de girar os hélices em 360 graus, ou seja, estes propulsores apresentam alta capacidade de manobra quando comparados aos propulsores de eixo fixo.

Desta maneira, apesar de na prática o Bollard Pull de um rebocador está associado diretamente a manobra, pode ser compreendido conforme a teoria que a diferença dos propulsores apenas apresenta aspectos de ganhos ou perdas na manobrabilidade do rebocador mas não em sua potência de sistema propulsivo ou diâmetro do hélice, fatores estes que são considerados na estimativa do Bollard Pull e não impossibilitam a introdução de rebocadores azimutais no banco de dados.

Ainda a respeito da Tabela 1, é possível observar que a mesma apresenta todas embarcações que serão utilizadas na implementação do método da MAN e do modelo de RNAs. E no método da MAN serão implementadas as embarcações que testadas no modelo da MAN, visto que o restante de embarcações fará parte do treinamento da rede.

Tabela 1 - Banco de dados de rebocadores twin screw

Nome	Dp(mm)	BHP (HP)	BP (ton)
AZZAWIYA 6	1350	1216	16,8
THISEAS II	1300	940	12,6
AKHILL	1300	960	12,5
TARPON BAY	2200	2720	39,4
DON LUCHO	2200	2720	39,2
ARABIAN TAHR	2200	2816	38,8
RESOURCE	1500	1200	16,9
WENZINA	2600	5600	68,1
PB ENDEAVOUR	2600	5600	68,1
PB MURRUMBIDGEE	2600	5600	68,6
ADSTEAM FERRIBY	2600	5592	70,4
TARKA	1800	2200	28,5
SILIN	2350	3500	49,1
SHA'M	2350	3822	53,8
IBRAHIM 1	2350	3300	47,5
ABEILLE DALIA	2400	4930	59
ISOLA DEL TINO	2400	4930	60,1
TORNADO	2400	4200	51
SMIT GUADELOUPE	2400	4930	60,5
PB LEICHHARDT	2400	4930	58,3
SMIT CURAÇAO	2400	4626	57
PAK	2650	4525	62,6
AGBODRAFO	2650	5000	67,5
ELHAMDAB	2050	2600	34,4
ZEETIJGER	2250	3344	50,7
PAWLINA	2600	5600	67,1
KARLOO	2600	5600	69,3
KIBOKO II	2400	4626	58
SULTAN HABIB A.HOUMED	2400	4750	54,7
SMIT OWENA	2400	4930	60,3
HELIOS	2650	4750	66,1
SMIT PANTHER	3000	7268	94,7
LAMNALCO PUMA	2800	6530	75,5
STANFORD	2700	5310	66,7
SMIT RIO MUNI	2600	5605	68,1
SMIT LYNX	2600	5605	66,9
BULAT	2200	4023	48,3
WATERSTROOM	2400	5000	57,9
PILBARA NEPTUNE	2700	5000	67,3
MOSCHNYI	2000	3500	36,7
STRATHFOYLE	2200	4023	48,8

Fonte: Elaborado pelo autor

A partir da apresentação do banco de dados das embarcações é possível ser realizada uma busca por modelos de estimativa de Bollard Pull.

3.2 Busca por métodos

Para a solução do problema proposto, os métodos apresentados anteriormente que possuem uma estimativa de Bollard Pull aproximada foram descartados em virtude dos valores obtidos serem muito diferentes dos reais, como pode ser visto no Apêndice B.

O método teórico selecionado a ser implementado no banco de dados e servir de comparativo com o novo modelo criado é o método da MAN Diesel & Turbo, por ter sido o mais preciso método para estimativa do BP dentre os pesquisados.

A MAN é um dos principais fornecedores mundiais de usinas terrestres e marítimas baseadas em grandes motores a diesel e a gás. Desde 1758 no mercado, a empresa já construiu milhares de instalações à diesel em todo o mundo, em sua grande parte servindo como motores para grandes embarcações, como rebocadores (MAN Hybrid Power, 2015)

O Método da MAN utiliza o diâmetro do propulsor e o BHP (brake horse power) da embarcação como dados de entrada para estimativa do Bollard Pull e para sua implementação foi utilizada uma planilha Excel com o objetivo de minimizar o tempo dos cálculos e realizá-los de uma maneira eficiente.

3.3 Criação do Modelo de RNAs

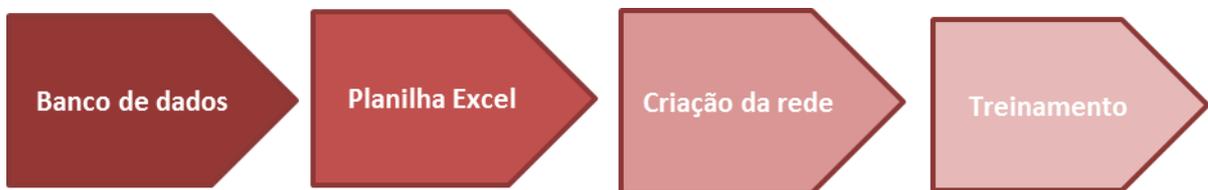
A criação de um novo modelo que deverá ser implementado baseou-se na teoria de redes neurais e como ferramenta principal foi utilizado o programa Synapse.

A partir da construção do banco de dados das embarcações, utilizou-se uma planilha Excel para organização das informações e a mesma foi introduzida como

dado de entrada do programa para que se tornasse possível a criação da rede bem como sua utilização como novo modelo.

Foram considerados como dados de entradas na rede o diâmetro do propulsor e o BHP (brake horse power) das embarcações, dados estes utilizados também no método da MAN que servirá como método de comparativo para os resultados finais. A Figura 20 ilustra a metodologia proposta do modelo criado de RNAs em suas etapas sequenciais.

Figura 20 - Etapas de implementação do modelo de RNAs



Fonte: Elaborado pelo autor

É válido reforçar que dentro destas etapas, existem diversas subetapas e, inclusive, etapas posteriores, que representam o processo criativo do novo modelo. Esta sequência auxiliará na implementação do método bem como no entendimento do processo de obtenção dos resultados.

3.4 Comparação dos resultados

Como ferramenta comparativa dos resultados encontrados através dos modelos já existentes e do modelo criado, foram utilizadas planilhas Excel, nas quais podem ser observados os erros médios entre os resultados.

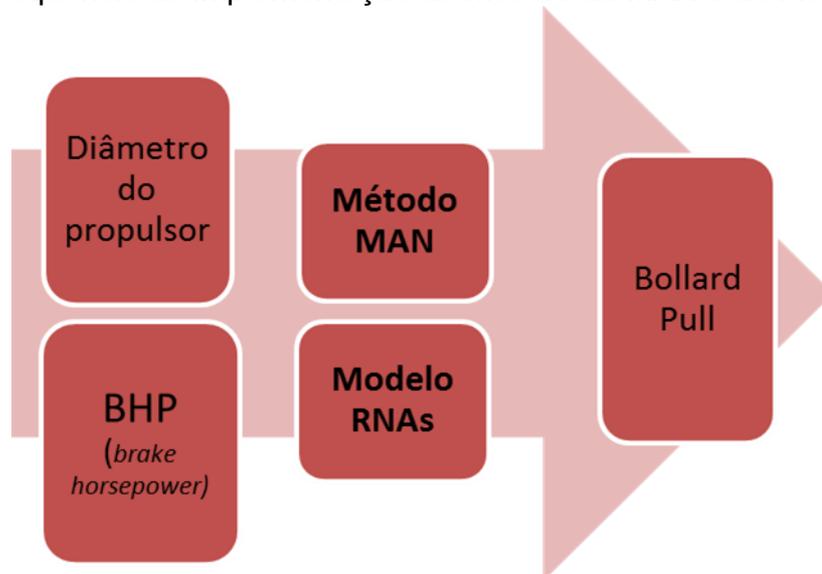
A comparação dos resultados tem como objetivo apresentar a precisão dos métodos com os dados reais. Esta comparação será apresentada através de gráficos de dispersão e de colunas, nos quais podem ser observados de forma mais didática os resultados positivos e negativos encontrados.

4. DESENVOLVIMENTO

Para que se dê sequência no desenvolvimento do estudo, primeiramente seleciona-se o método existente que será implementado no banco de dados de embarcações, para que em seguida este banco de dados também seja implementado no modelo criado com base em redes neurais artificiais.

Ambos, método da MAN e modelo de RNA, serão implementados de acordo com a Figura 21, num processo em que a partir de duas variáveis de entrada representadas por características dos rebocadores, seja possível estimar o Bollard Pull.

Figura 21 - Sequência de implementação do método da MAN e do modelo de RNAs



Fonte: Elaborado pelo autor

Faz-se necessária uma recapitulação, afirmando que o método da MAN foi desenvolvido a partir de experimentos em modelos em tanques de provas e o modelo de RNAs foi criado a partir de um determinado banco de dados de rebocadores.

4.1 Implementação do método MAN Diesel & Turbo

Para sua implementação primeiramente os dados das embarcações foram organizados em uma planilha excel como pode ser observado na Tabela 2. Foram

selecionados quatro rebocadores aleatoriamente dentre os apresentados na Tabela 1, e, também o rebocador Strathfoyle⁷, no qual os mesmos não serão considerados na implementação da rede neural como dado de entrada, apenas durante o processo de verificação e validação da rede.

Tabela 2 - Embarcações implementadas no método da MAN

Nome	Dp(mm)	BHP (HP)	BP (ton)
BULAT	2200	4023	48,3
WATERSTROOM	2400	5000	57,9
PILBARA NEPTUNE	2700	5000	67,3
MOSCHNYI	2000	3500	36,7

Fonte: Elaborado pelo autor

Utilizou-se a equação 8, para que fosse encontrada a densidade de potência e a partir dela o Bollard Pull dos rebocadores, pudesse ser estimado. Na Tabela 3 é possível visualizar os valores de BP encontrados para as quatro embarcações selecionadas aleatoriamente através do método da MAN.

Tabela 3 - Tabela com dados e BP através do modelo da MAN

Nome	Dp(mm)	BHP (hp)	BP REAL (ton)	BP MAN (ton)
BULAT	2200	4023	48,3	48,7
WATERSTROOM	2400	5000	57,9	60,1
PILBARA NEPTUNE	2700	5000	67,3	62,8
MOSCHNYI	2000	3500	36,7	42,0

Fonte: Elaborado pelo autor

A partir do resultado do Bollard Pull estimado neste método, torna-se possível a realização de um comparativo com os resultados reais e também do modelo implementado, com o objetivo de definir sua precisão.

4.2 Implementação do modelo de RNAs

Para implementação do modelo de RNAs realizou-se uma análise paramétrica dos resultados obtidos com o objetivo de estimar qual será a topologia

⁷ Visto que o banco de dados apenas contém rebocadores construídos até 2012, o rebocador Strathfoyle, fabricado em 2016, foi adicionado como verificação dos métodos de estimativa para um rebocador mais atual que os demais.

da rede que apresenta a melhor precisão nos resultados. As ferramentas utilizadas foram a planilha excel e o programa Synapse, este último responsável pelo treinamento da rede neural.

Num primeiro momento são selecionados os rebocadores que serão utilizados no treinamento e organizados numa planilha excel. Como grande parte do processo de treinamento são introduzidos os valores de entrada que são considerados no método da MAN, visto que quando os dados se limitarem à utilização do método teórico, o modelo criado também ser implementado.

O Apêndice C contém os dados que serão utilizados como entrada no programa para a realização do treinamento da RNA. Como pode ser visto, foram considerados 36 rebocadores para a criação da rede neural.

A implementação deste método requer conceitos fundamentais e princípios de funcionamento das RNAs. A partir dos conceitos fundamentais foi possível iniciar o processo de treinamento da rede neural através da ferramenta Synapse. Para uma melhor implementação do modelo deverão ser consideradas as variáveis de entrada no programa bem como analisada a precisão dos resultados reais.

Foram treinadas diferentes redes com topologias distintas em que foram variados os parâmetros: número de neurônios, número de camadas e número de ciclos.

Como pode ser visto na Figura 22, o número de camadas alternou entre uma e duas camadas. De acordo com os conceitos fundamentais apresentados no referencial teórico, como o banco de dados da rede não apresenta milhares de dados técnicos de entrada, uma rede com o número máximo de duas camadas já tem a capacidade de estimar um padrão através de seu aprendizado.

Além disso, pode-se entender que o número de camadas faz com o tempo de treinamento cresça exponencialmente, ao contrário do número de ciclos que interfere no tempo de treinamento de forma linear. Ou seja, quanto mais ciclos maior o tempo, de maneira proporcional.

Figura 22 - Possíveis topologias do modelo de RNAs



Fonte: Elaborado pelo autor

A partir dessas combinações foram criadas e treinadas quatro diferentes redes, cada uma delas para um determinado número de ciclos como descrito anteriormente.

Os resultados do treinamento das RNAs podem ser visualizados no Apêndice D. Posteriormente estes resultados são apresentados através de gráficos para que visualmente sejam perceptíveis quanto à sua aproximação dos resultados reais.

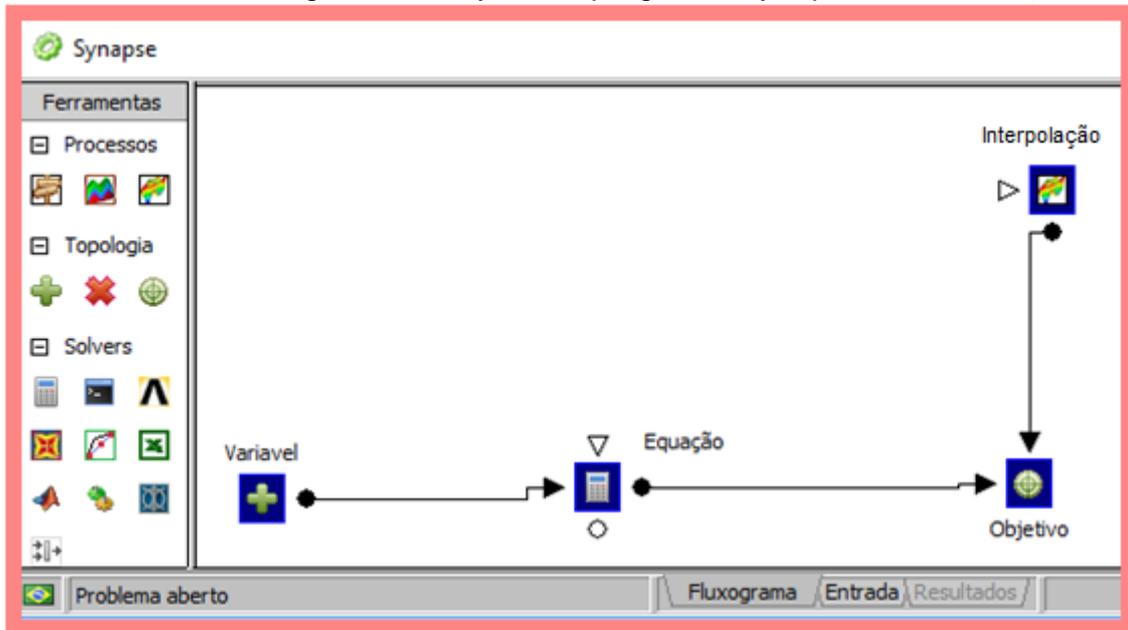
4.2.1 Programa Synapse

O programa utilizado na implementação do modelo de redes neurais artificiais foi o Synapse, destinado a Engenharia Multidisciplinar. Sua seleção se deu por sua interface ser didática e de fácil utilização, bem como apresentar o algoritmo proposto como novo modelo para o treinamento da rede neural.

Na Figura 23 é possível visualizar o esquema de utilização do programa e suas ferramentas utilizadas na formulação de um novo problema. A ferramenta Variável representa as duas variáveis de entrada implementadas através da planilha excel, diâmetro do propulsor e BHP, respectivamente. A Equação representa o

algoritmo que irá treinar a rede. Por fim, é necessário o uso de uma ferramenta de Interpolação e Objetivo, que irão auxiliar no treinamento da rede.

Figura 23 - Layout do programa Synapse



Fonte: Elaborado pelo autor

Além dos dados de entrada do banco de dados introduzidos através de uma planilha excel, outros fatores são necessários para o início da otimização da rede dentro do Synapse. Entre eles estão o número de variáveis de entrada, número de saídas, número de camadas, número de neurônios por camada, o erro médio máximo, número de clicos máximos e o número de pontos, este último representado pela quantidade de rebocadores a serem utilizados no treinamento. Foram considerados 36 pontos, correspondente aos 36 rebocadores twin screw que participarão do treinamento da rede.

Quanto à saída do programa essa é apresentada através de uma planilha excel. Nesta planilha é possível introduzir as variáveis de entrada de outras embarcações, diâmetro do propulsor e BHP, e como saída é gerado, dentro da planilha, o resultado de Bollard Pull.

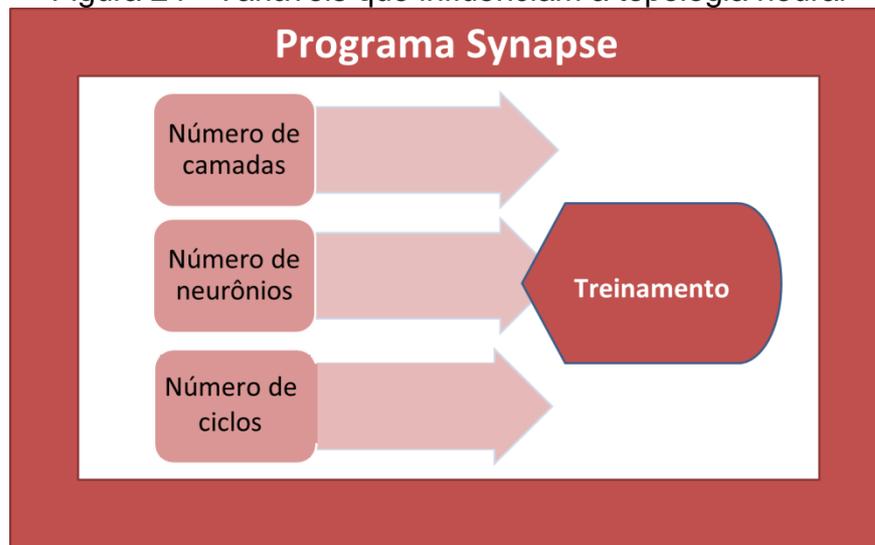
3.3.2 Análise paramétrica da topologia neural

Uma análise paramétrica da topologia neural deverá ser realizada a fim de estipular quais dos modelos de RNAs criados é, de fato, o mais efetivo. Está análise

envolverá parâmetros que são considerados no treinamento da rede neural através do programa.

Na Figura 24 é possível avaliar as principais variáveis que irão alterar a topologia da rede, cuja modificação pode gerar diferentes resultados.

Figura 24 - Variáveis que influenciam a topologia neural



Fonte: Elaborado pelo autor

Vale ressaltar que o número de entradas, número de saídas, erro médio máximo e número de pontos, foram definidos como valores padronizados para diferentes topologias de rede, conforme pode ser visualizado na Tabela 4.

Tabela 4 - Valores das variáveis como dados de entrada das RNAs

Número de entradas	2
Número de saídas	1
Erro médio máximo	0.00000000001
Número de pontos	36

Fonte: Elaborado pelo autor

O número de entradas justifica-se pelo padrão de duas variáveis de entrada no treinamento da rede, o BHP e o diâmetro do propulsor. O número de saídas é correspondente ao resultado a ser estimado, ou seja o Bollard Pull. O erro médio máximo de 0,00000000001 foi definido por ser um valor muito próximo de zero e

também apresentar-se como dado padrão (default) do programa. Por fim, o número de 36 pontos é fixado conforme citado anteriormente pois representa o número de rebocadores introduzidos através do banco de dados no treinamento.

Com o objetivo de obtenção de uma rede neural mais efetiva, será criada uma rede em que são considerados seis dados de entrada ao invés de apenas dois como no método da MAN. Além do BHP e do diâmetro do propulsor, será considerado os seguintes parâmetros de entrada dos rebocadores: comprimento total, boca total, pontal e deslocamento. O Bollard Pull é mantido como único parâmetro de saída da rede.

5. RESULTADOS

Neste capítulo primeiramente são apresentados os resultados obtidos através do método da MAN e do modelo de RNAs e, em seguida, é realizado um comparativo entre ambos.

A partir disso, é apresentada a diferença média dos resultados, analisando o comportamento dos mesmos. O método ou modelo mais preciso será o que estimar resultados mais próximos dos reais. Considerando a soma dos erros quadráticos.

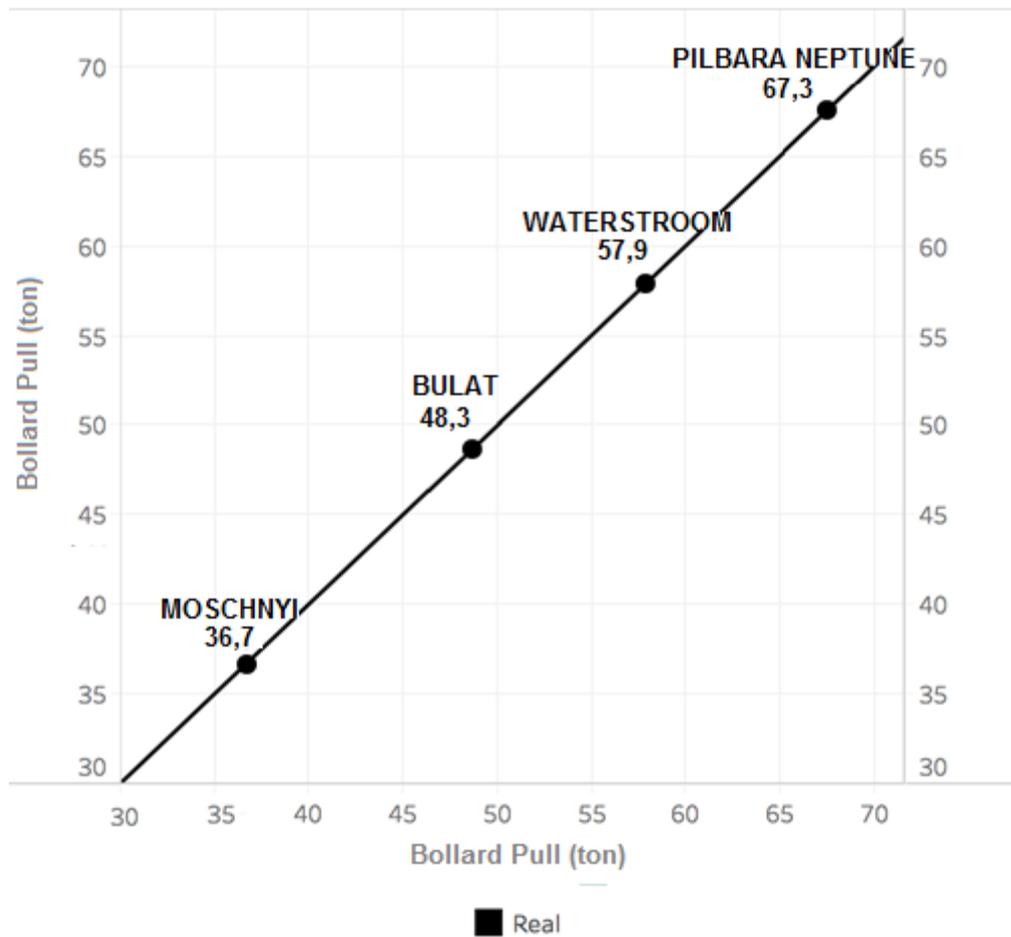
Por fim, será realizada uma análise da influência da topologia da rede neural para que seja possível interpretar e decidir qual rede que após treinada apresenta os resultados mais precisos.

5.1 Comparativo entre método da MAN e modelo de RNAs

Os resultados obtidos através da implementação do método da MAN e do modelo criado com base em redes neurais podem ser comparados entre si e com os resultados reais, de forma que visualmente seja mais fácil a identificação da precisão dos resultados.

Os resultados reais serão comparados com os estimados através da organização proposta de acordo com a Figura 25. Nela, é possível visualizar como serão dispostos os quatro rebocadores ao longo de uma diagonal real, de forma crescente, iniciando com o Moschnyi que possui um Bollard Pull de 36,7 toneladas e finalizando com o Pilbara Neptune, que possui um BP de 67,3 toneladas.

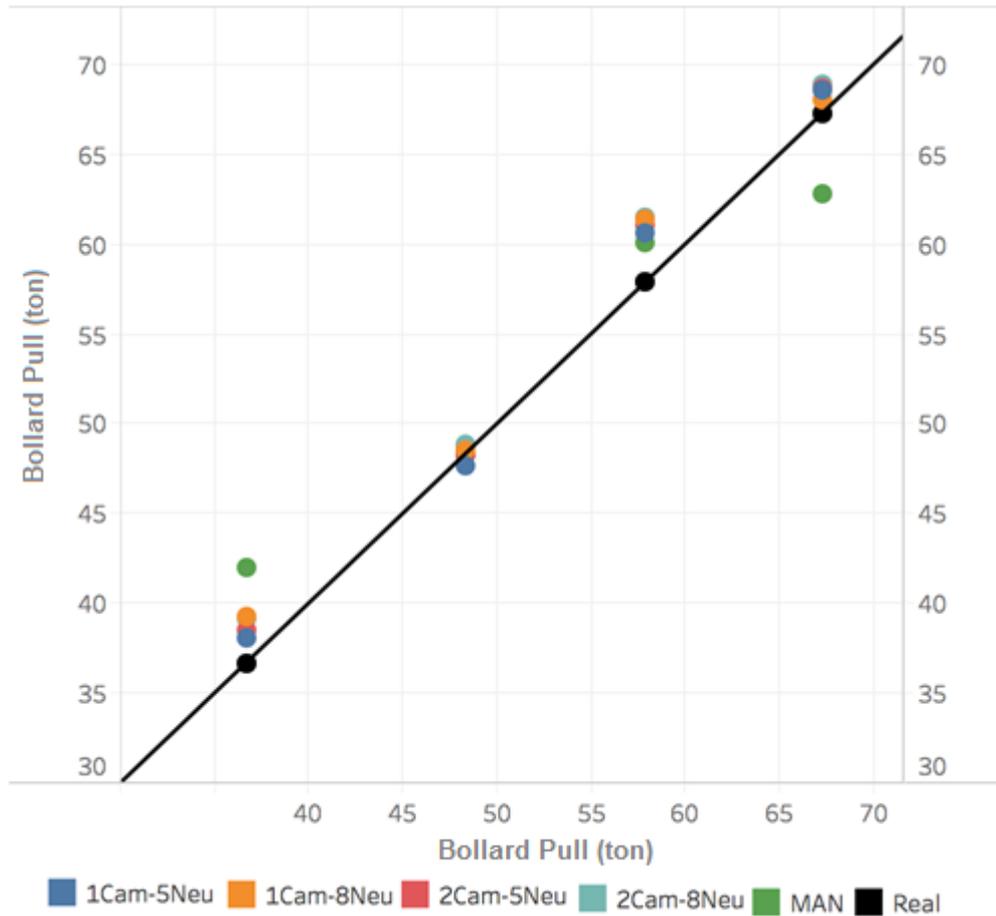
Figura 25 - Apresentação das embarcações posicionadas ao longo do gráfico de acordo com seu Bollard Pull



Fonte: Elaborado pelo autor

Como definido anteriormente na implementação do modelo de RNAs, o primeiro modelo irá utilizar um treinamento com mil ciclos. Para este determinado número de ciclos foram treinadas 4 topologias de rede: 1 camada e 5 neurônios, 1 camada e 8 neurônios, 2 camadas e 5 neurônios e 2 camadas e 8 neurônios. A Figura 26 apresenta o resultado destes treinamentos em comparação ao resultado real e também ao método da MAN.

Figura 26 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 1000 ciclos



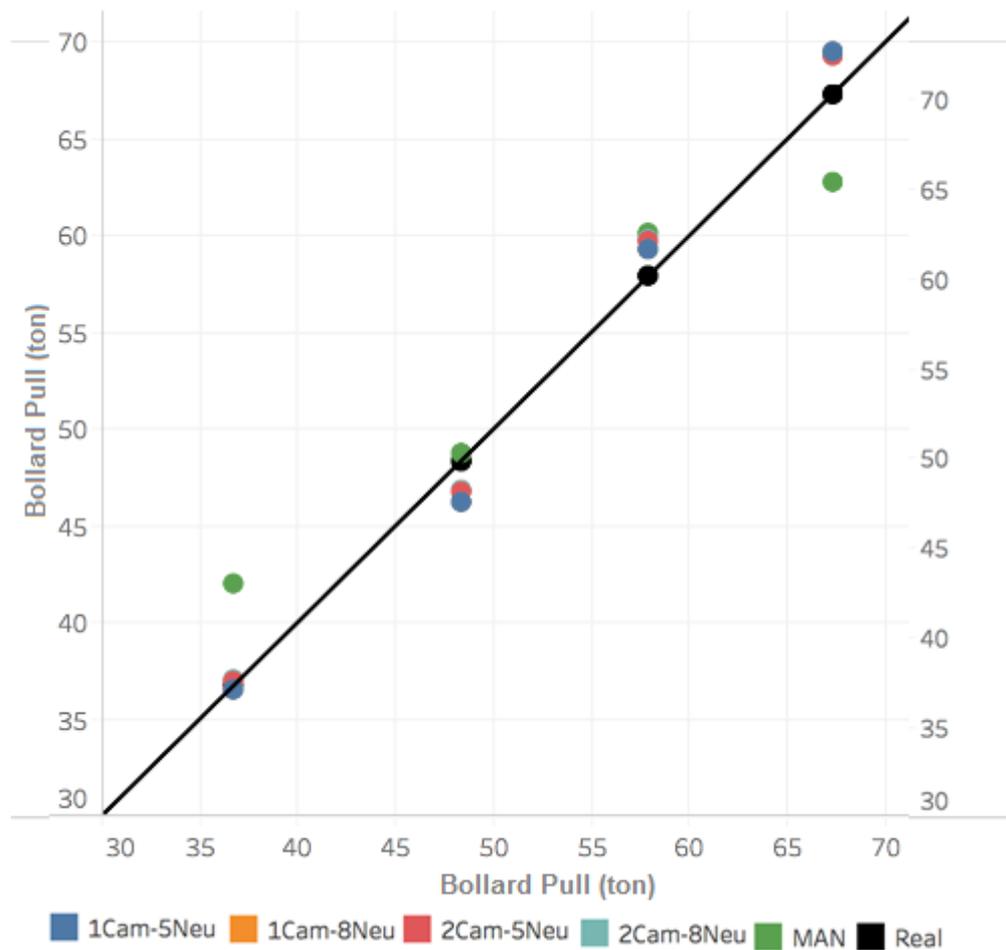
Fonte: Elaborado pelo autor

O tempo de treinamento da rede para mil ciclos com as topologias propostas durou menos de 10 segundos.

Pôde ser observado que para mil ciclos de treinamento, independente da topologia neural adotada, o modelo da rede conseguiu estimar um valor de BP do rebocador Moschnyi mais preciso que o do método da MAN. Praticamente o mesmo comportamento é percebido para o Pilbara Neptune, já que o valor de BP estimado pela MAN apresenta-se distante do real. Para o rebocador Waterstroom o método da MAN se mostrou mais preciso que todas os modelos de redes neurais e para o Bulat apresentou a mesma precisão aproximadamente, visto que foi mais efetivo que dois modelos de RNAs, representando metade dos modelos criados.

Na Figura 27 é possível observar agora o treinamento das redes com 10.000 ciclos. O tempo de treinamento foi praticamente o mesmo da rede de 1000 ciclos porém as redes já apresentaram resultados diferentes.

Figura 27 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 10.000 ciclos

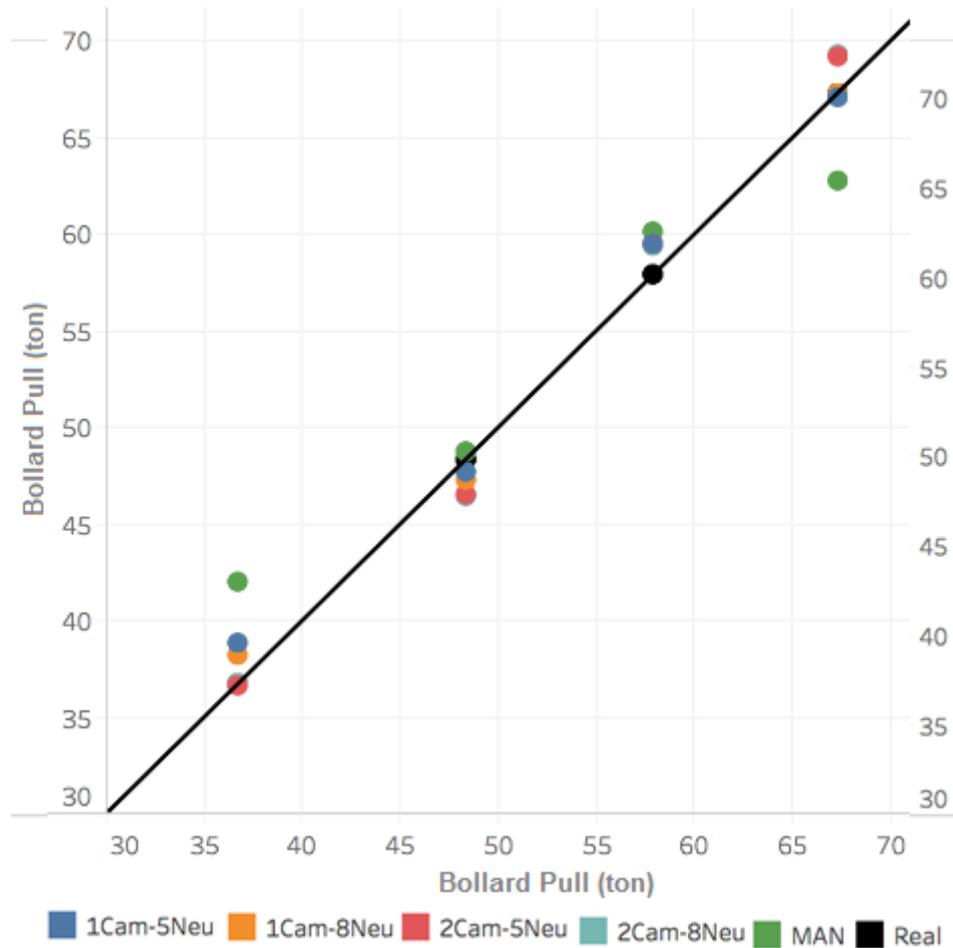


Fonte: Elaborado pelo autor

Pode ser observado que houve melhoria na precisão dos resultados das redes neurais para o rebocador Moschnyi, mostrando a convergência para o resultado real. Para o Bulat o Método da MAN se mostrou mais preciso que todos os modelos das redes, desta maneira pode-se entender que um incremento no número de ciclos não irá aumentar a precisão dos valores necessariamente. Para a estimativa do BP do rebocador Waterstroom as redes apresentaram-se em sua totalidade mais efetivas que o método da MAN e para o Pilbara Neptune apesar de todos os modelos das redes serem mais precisos que a MAN, houve uma pequena divergência dos resultados em comparação aos dados reais.

Dando sequência aos resultados das redes treinadas, na Figura 28 é possível ser observado os resultados das redes para um treinamento de cem mil ciclos. O tempo de treinamento desta rede apresentou-se praticamente similar ao das redes de mil e dez mil ciclos.

Figura 28 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 100.000 ciclos



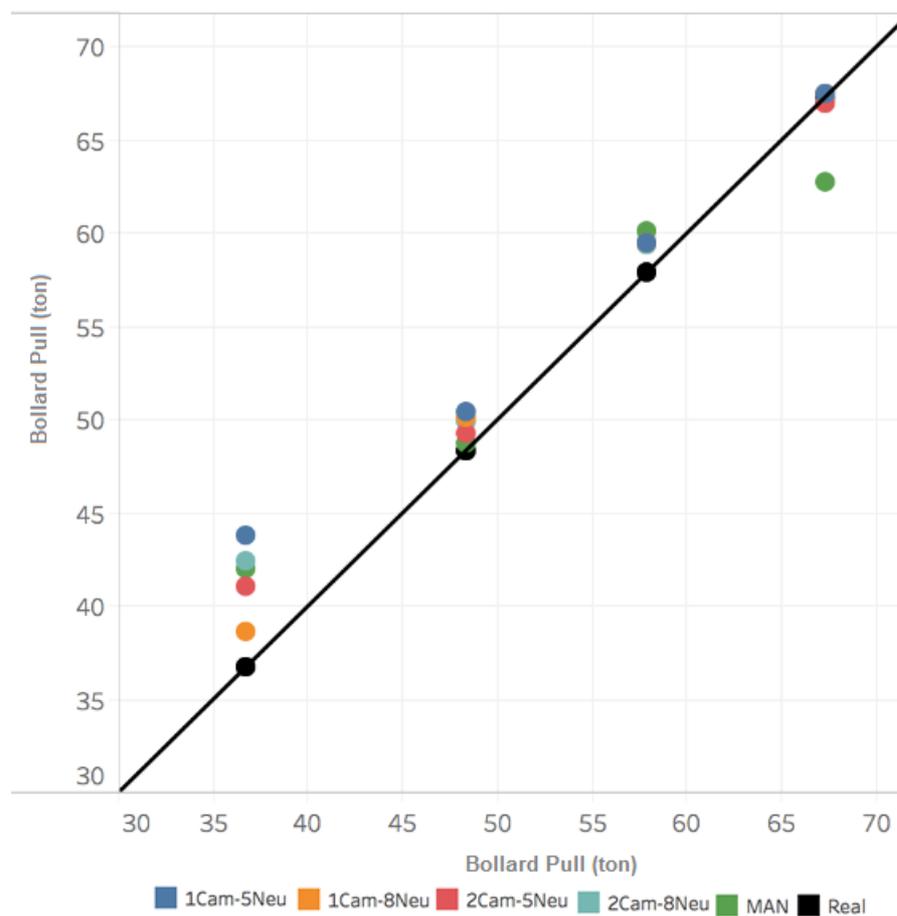
Fonte: Elaborado pelo autor

Primeiramente pode ser observado uma pequena divergência dos valores de Bollard Pull das redes para o Moschnyi quando comparado ao número de ciclos dos modelos anteriores, mas os modelos das RNAs ainda apresentam mais precisos que o método da MAN. Para o Bulat é possível observar uma pequena convergência de todas as redes mas a MAN ainda demonstra ser um método mais preciso para este rebocador. O Waterstroom também confirmou novamente que todos os modelos de redes foram mais preciso que o método de referência e o Pilbara Neptune apresentou uma convergência de valores para duas redes.

Como últimos modelos a serem criados, foram realizados treinamentos com cada uma das quatro topologias estruturais com a utilização de um milhão de ciclos. O tempo de treinamento apresentou-se um pouco maior, em torno de 100 segundos, informação esta que define a não proporcionalidade do número de ciclos com o tempo de treinamento, ou seja, com um incremento de mil vezes mais ciclos, necessariamente não levarão mil vezes mais segundos que os demais treinamentos.

Analisando a Figura 29 é possível interpretar os resultados para os modelos de redes com um milhão de ciclos de treinamento.

Figura 29 - Comparativo de resultados entre RNAs X MAN x REAL treinando as redes neurais com 1.000.000 ciclos



Fonte: Elaborado pelo autor

É possível perceber que para o primeiro rebocador à esquerda do gráfico, o Moschnyi, os valores divergiram e pela primeira vez dois modelos das RNAs mostraram-se menos preciso que o método da MAN. Para o Bulat, os resultados mostraram uma oscilação, não convergindo para os valores reais e demonstrando

aproximadamente a mesma imprecisão. Os resultados do rebocador Waterstroom continuaram sendo mais precisos que os da MAN e para o Pilbara Neptune houve um maior convergência de valores, aproximando-se ainda mais dos resultados reais e demonstrando mais precisão que o método da MAN.

A partir destes resultados de Bollard Pull obtidos através da implementação do método de referência e do modelo criado também é possível realizar um comparativo através da diferença média de resultados.

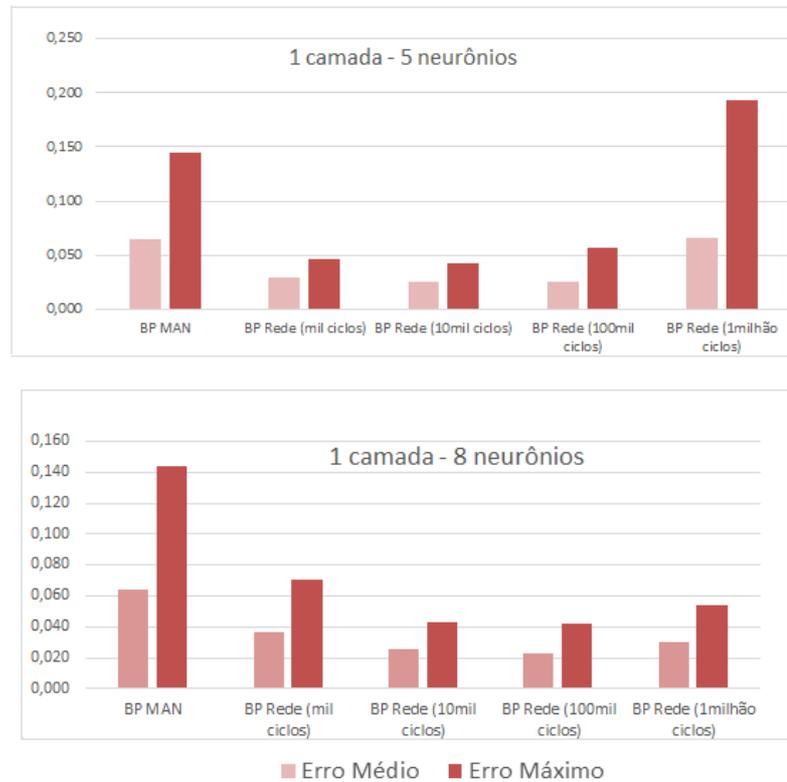
5.2 Diferença média dos resultados

Como outra alternativa de análise dos resultados obtidos e de um comparativo entre si é possível a utilização do erro médio e erro máximo como critério de decisão do método ou modelo mais preciso.

Para a criação dos gráficos com os erros, foram utilizados resultados obtidos a partir da implementação do método da MAN e do modelo de redes neurais artificiais, bem como um comparativo com os resultados reais apresentados através do banco de dados.

Primeiramente serão avaliados os erros médios das redes que se apresentam com um neurônio, como pode ser visto na Figura 30.

Figura 30 - Erro médio e erro máximo do método da MAN e dos modelos RNAs com 1 camada



Fonte: Elaborado pelo autor

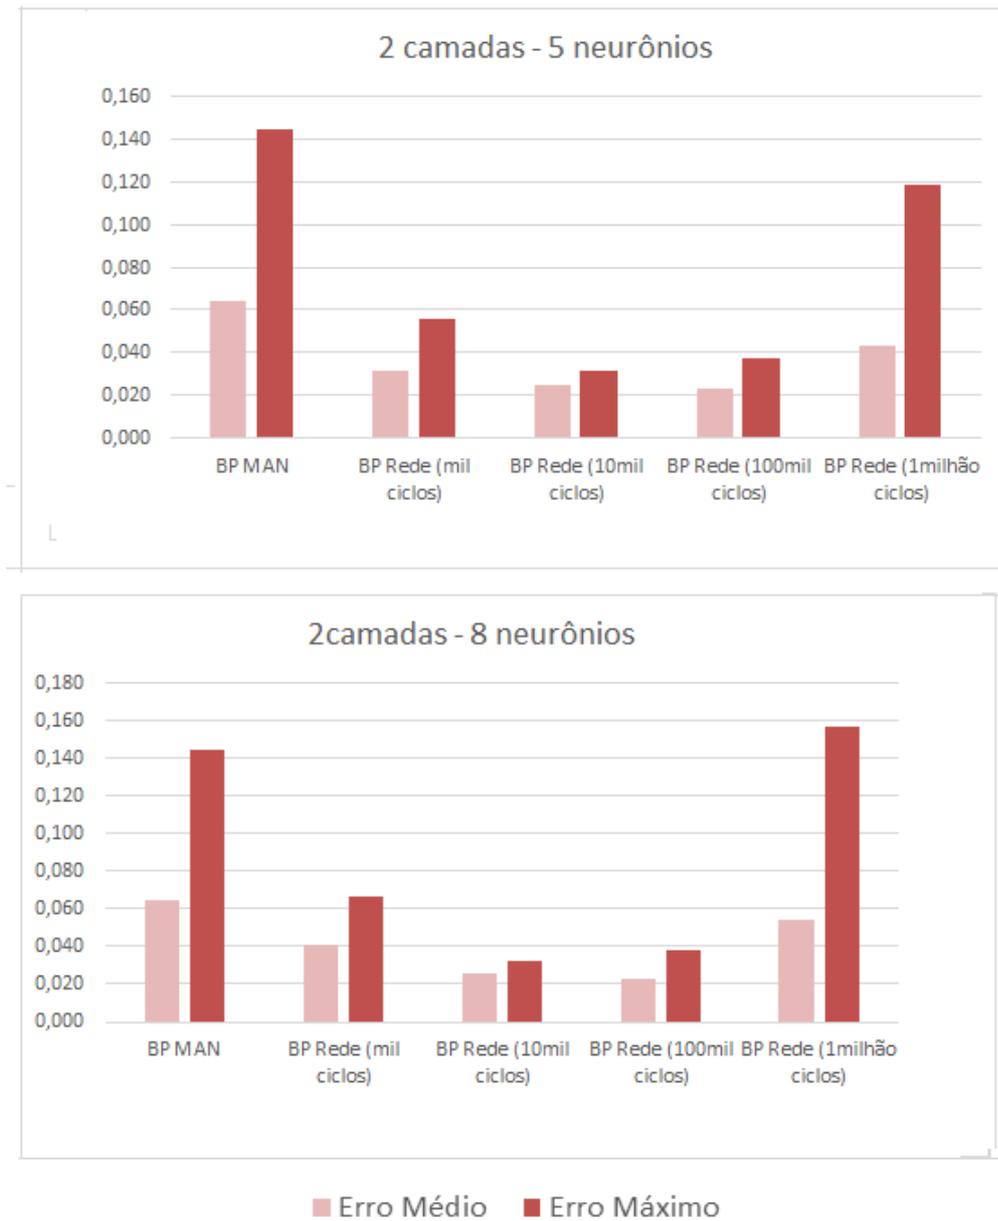
Analisando a Figura 30 é possível interpretar que as RNAs com dez mil e cem mil ciclos de treinamento apresentaram, em números gerais, os menores erros médios e erros máximos.

Realizando um comparativo entre as diferentes topologias, podemos observar que para a rede com oito neurônios, o erro médio e o erro máximo da rede com um milhão de ciclos, baixou consideravelmente, apresentando mais precisão.

Além disso podemos entender que os modelos de RNAs são mais interessantes por apresentarem menor erro que o método da MAN.

Na Figura 31 é possível visualizar os erros médios e máximos para as redes com duas camadas.

Figura 31 - Erro médio e erro máximo do método da MAN e dos modelos RNAs com 2 camadas



Fonte: Elaborado pelo autor

Pode-se interpretar que para as redes treinadas com um milhão de ciclos o erro médio tende a ser aproximado do Método da MAN, e, novamente, para as redes treinadas com dez mil e cem mil ciclos os erros médios e máximos apresentam-se como os menores, em números gerais.

A partir da interpretação dos erros médios das redes e do comparativo dos resultados obtidos com os resultados reais, é possível realizar uma análise da influência da topologia na rede.

5.3 Verificação dos métodos para um rebocador atual

Com o objetivo de verificar a eficácia do método da MAN e do modelo de RNAs, foi selecionado um rebocador construído no ano de 2016, visto que os demais rebocadores do banco de dados foram construídos entre os anos de 2004 e 2012, como pode ser visto na tabela A.3 do Apêndice A.

As especificações técnicas do rebocador atual selecionado, o Strathfoyle, foram retirados do banco de dados da Damen Shipyard Group (2017), como pode ser visto no Anexo B.

O Bollard Pull do Strathfoyle foi estimado através do método da MAN e do modelo de redes neurais artificiais para uma topologia da rede de 2 camadas e 8 neurônios, num treinamento de 100 mil ciclos, como pode ser visto na Tabela 5.

Tabela 5 – Estimativa de Bollard Pull para um rebocador atual

STRATHFOYLE	Diâmetro do propulsor (mm)	BHP (Hp)	Ano de Fabricação
	2200	4023	2016
	BP -REAL (tn)	BP - MAN (tn)	BP - RNAs (tn)
	45,7	48,71	45,96
	Erro	Erro MAN	Erro RNA
		0,066	0,006

Fonte: Elaborado pelo autor

A partir disto é possível observar que o erro do método da MAN foi aproximadamente dez vezes maior que o erro do modelo das RNAs, e se apresentou próximo ao erro médio dos rebocadores do banco de dados de embarcações até o ano de 2012.

5.4 Análise da influência da topologia

A partir dos resultados apresentados para diversas topologias é possível concluir que o número de camadas e neurônios de uma rede depende do tipo de treinamento e do banco de dados utilizado.

Analisando as Figuras do tópico de Resultados, algumas hipóteses quanto à topologia das redes neurais, podem ser observadas. As mais relevantes são:

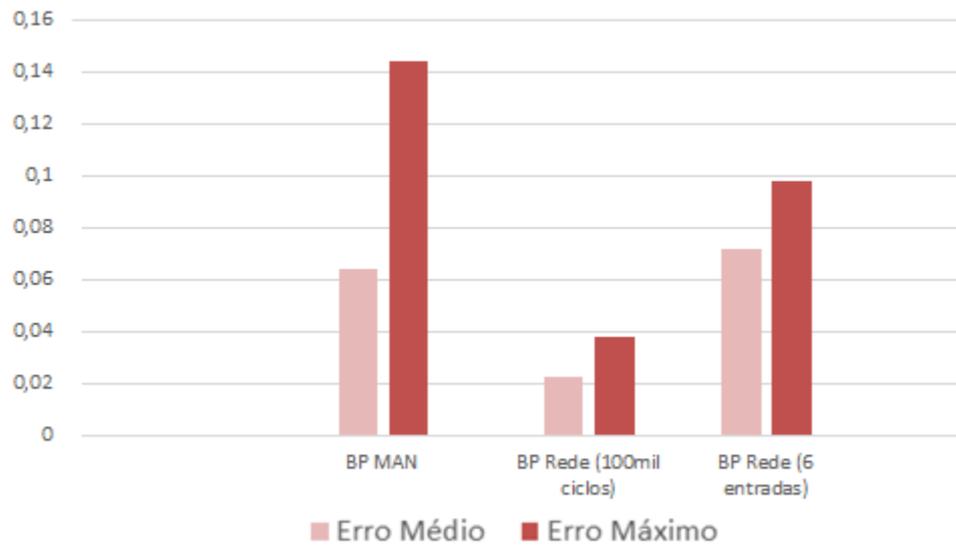
- O incremento do número de ciclos para redes com 2 camadas tende a ser mais efetivo que para redes com apenas 1 camada;
- Um incremento muito alto no número de ciclos pode levar à um overtraining, reduzindo a capacidade de generalização e podendo apresentar divergência na rede;
- De certa forma, se for utilizado um banco de dados pequeno, diferentes topologias de rede podem apresentar pouca diferença de resultados, ou seja, quanto maior o banco de dados, maior influência diferentes topologias terão. Esta hipótese foi concluída após ter sido um realizado um treinamento prévio da rede com 33 pontos e definitivo com 36 pontos;
- Um menor número de neurônios gerar um fenômeno denominado underfitting, levando a rede a não convergir durante o seu treinamento.

Além das hipóteses analisadas com base nos resultados, outras conclusões podem ser entendidas quanto à topologia, a partir do entendimento teórico e da implementação da rede. Entre elas, pode-se entender que o grande responsável pela precisão da rede é o banco de dados, ou seja, quanto maior for o banco de dados da rede, maior será sua capacidade de generalização.

Com o objetivo de analisar outros parâmetros de influência da topologia da rede, foi criada uma rede com seis parâmetros de entrada ao invés de apenas os dois do método implementado pela MAN. Esta rede foi criada com o objetivo de investigar se o acréscimo de variáveis de entrada, num mesmo banco de dados, possibilita resultados mais precisos.

Como pode ser visto na Figura 32, o erro médio e o erro máximo de uma rede com mais variáveis de entrada apresentou-se maior, o que permite compreender que para melhor a rede seria necessário utilizar mais rebocadores e não mais informações dos rebocadores já existentes. Vale ressaltar em outros casos uma maior quantidade de variáveis de entrada pode gerar melhores padrões e consequentemente melhores resultados, mas para o caso aplicado isto não se mostrou como verdade.

Figura 32 – Comparativo de precisão da rede neural com 6 variáveis de entrada
2camadas - 8 neurônios



Fonte: Elaborado pelo autor

Por fim, entende-se que por mais que seus conceitos fundamentais não sejam triviais em um primeiro contato com o tema, existe uma grande facilidade de implementação do método independente das topologias que serão utilizadas.

6. CONSIDERAÇÕES FINAIS

Apresentou-se neste trabalho o desenvolvimento de um modelo de redes neurais artificiais destinado a estimar a capacidade de reboque de um rebocador como uma função do diâmetro do propulsor e da potência instalada. Os pesos e limites de ativação de cada neurônio das redes com duas e seis variáveis de entrada podem ser observados no Apêndice E.

Entende-se que os objetivos propostos foram alcançados. Após uma breve introdução sobre o tema, o trabalho descreveu a criação de uma rede cuja eficiência e precisão superaram o atual modelo de referência para estimativa de BP de um rebocador do tipo twin screw.

A partir da pesquisa realizada e da implementação dos métodos, após uma verificação dos resultados é possível concluir que o modelo criado de redes neurais artificiais foi validado e pode servir como novo método de referência para estimativa do Bollard Pull de rebocadores twin screw.

Especificando o uso de redes neurais foi possível analisar a importância que da topologia estrutural e das estratégias adotadas ao longo dos treinamentos da rede.

Sendo um modelo não utilizado, podemos observar que a sua inovação deve-se à falta de estudos na área bem como da necessidade de projetos de novos rebocadores.

É possível observar que para estimativa de um rebocador atual, conforme foi utilizado na análise dos resultados, o modelo de redes neurais artificiais apresentou-se eficaz visto que seu erro foi aproximado do erro médio do modelo de RNAs para os rebocadores do banco de dados até 2012 (Apêndice A) e inferior ao erro médio do método da MAN.

A maior dificuldade encontrada para desenvolver esse trabalho foi a interpretação dos conceitos de redes neurais artificiais, tema não abordado no âmbito de graduação em engenharia naval e nada trivial quando comparado às formulações físicas mais tradicionais. Entretanto, as RNAs apresentam-se como um tema motivador, principalmente pela capacidade de emprego em qualquer área.

6.1 Trabalhos Futuros

Com o objetivo da obtenção de melhorias no modelo criado e da busca por aplicações em outros tipos de embarcações, são realizadas algumas recomendações. Estas sugestões têm como objetivo dar sequência no estudo do trabalho proposto despertando o interesse de pessoas relacionadas diretamente ou indiretamente com o tema.

Por conseguinte, em prol das pesquisas futuras, recomenda-se:

- Desenvolver estudos sobre a viabilidade de implementação de redes neurais para estimativa do Bollard Pull de outros sistemas propulsivos de rebocadores;
- Aplicar a prática do modelo proposto para o projeto de um rebocador real;
- Analisar que impactos a implementação do método de redes neurais para estimativa do Bollard Pull irão causar, bem como quais mudanças ocorrerão, no custo final de um rebocador;

REFERÊNCIAS

- ALLAN, R.G. **Tugs and Towboats**. Ship Design & Construction, Volume 2. 2012.
- ANTONELI, G.C.; NEITZEL, I. **Aplicação de redes neurais artificiais na indústria de fios de algodão**. Bauru, São Paulo. 2015.
- BALAKRISHNAN, K.P. **Technological and Economic Advancement of Tug Boats**. International Conference on Emerging Trends in Engineering & Management (ICETEM). 2016.
- BARRETO, J.M. **Introdução às Redes Neurais Artificiais**. Florianópolis. Laboratório de Conexão e Ciências Cognitivas, UFSC. 2002.
- BRUNING, A. **Bollard Pull Standard**. Challenging wind and waves. 2014.
- CAMPOS, T.E. **Problemas de generalização**. 2000. Disponível em: <<http://www.vision.ime.usp.br/~teo/publications/qualificacao/node8.html>>. Acesso em: 14 nov. 2017.
- CANDIDO, I. **Projeto Integrado de Sistema Propulsivo com Requisito de Tração Estática**. Rio de Janeiro. Projeto Final, UFRJ. 2012.
- CARDOSO, A.A. **Redes Neurais Artificiais na avaliação de concentração de tensões em juntas tubulares soldadas**. São Paulo. 1999.
- CAVA, F. **Concreto Armado – “Pré-dimensionamento de vigas”**. 2016. Disponível em: <<https://alemdainercia.wordpress.com/2016/09/01/concreto-armado-pre-dimensionamento-de-vigas/>>. Acesso em: 10 nov. 2017.
- Damen. **Navio polivalente rebocador costeiro**. 2017. Disponível em: <<http://www.nauticexpo.com/pt/prod/damen/product-25691-390511.html>> Acesso em: 23 nov. 2017.
- Damen Shipyards Group. **Azimuth Stern Drive Tug 2310 –Strathfoyle**. 2017. Disponível em: http://products.damen.com/-/media/Products/Images/Clusters-groups/Tugs/ASD-Tugs/ASD-Tug-2310/Deliveries/Product-Sheet/Product_Sheet_Damen_ASD_Tug_2310_YN512917_STRATHFOYLE.pdf> Acesso em: 05 dez 2017.
- DIAZ, J. **A Giant Bow Suspended Over A Ship**. 2014. Disponível em: <<https://www.gizmodo.com.au/2014/12/amazing-photo-of-a-giant-bow-hanging-over-a-giant-ship/>> Acesso em: 10 nov 2017.
- FINNOCHIO, M.A.F. **Noções de Redes Neurais Artificiais**. UTFPR. 2014.
- FRAGOSO, O.A.; CAJATY, M. **Rebocadores Portuários**. Rio de Janeiro: Conselho Nacional de Praticagem. 2002.

GERENT, J.P. **A Simulação Analógica de Manobras Não Tripuladas de Navios na Otimização de Projetos e Operações Portuárias**. São Paulo. 2010.

HAYKIN, S. **Neural Networks - A Comprehensive Foundation**. Hamilton, Canadá. 2005.

HILERA, J.R.; MARTINEZ, V.J. **Redes Neuronales Artificiales**. Madrid, Espanha. 2000.

IncoFios. **Fio Algodão Penteado**. 2017. Disponível em: <<http://www.incofios.com.br/pt/produtos/fio-algoduuu-penteado/>>. Acesso em: 10 nov. 2017.

IST/FUNDEC. **Cálculo da Resistência de ligações soldadas de estruturas metálicas em curso da FUNDEC**. 2015. Disponível em: <<https://www.engenhariacivil.com/calculo-resistencia-ligacoes-soldadas-estruturas-metalicas-2015>> Acesso em: 10 nov. 2017.

Key Word Suggest. **Image Gallery: Ship Propeller**. 2017. Disponível em: <http://keywordsuggest.org/gallery/938477.html>> Acesso em: 23 nov. 2017

KIRESEL, D. **A Brief Introduction to Neural Networks**. Dkriesel.com. 2005

LASTIRI, C.P.; PAULETTI, R.M.O. **Aplicação de Redes Neurais Artificiais à Engenharia de Estruturas**. Jornadas Sud-Americanas de Ingeniería Estructural. 2004.

LOPES, D. B. P. **Uso de rede neural artificial aplicada à classificação automática de descontinuidades em chapas de compósito laminado de alumínio e epóxi reforçado por fibra de vidro**. Campina Grande, Paraíba. VI Congresso Nacional de Engenharia Mecânica. 2010.

MAN Diesel & Turbo. **Propulsion of Offshore Support Vessels**. 2011.

MAN Hybrid Power. **Engines supporting wind power**. 2015.

MARCONI, M.A.; LAKATOS, E.M. **Fundamentos da Metodologia Científica**. São Paulo. 2003.

Maritime Journal. **Vessel Launch Prince Rock**. 2004. Disponível em: <http://www.maritimejournal.com/news101/vessel-build-and-maintenance/vessel-launch/vessel_launch_prince_rock>. Acesso em 12 out. 2017.

MILATIAS, G. **Introdução aos materiais compósitos**. 2014. Disponível em: <<http://www.omundodausinagem.com.br/?p=5418>>. Acesso em: 10 nov. 2017.

MISZEWSKI, J. **Pchaz kanalowry i manewrowy**. 2013. Disponível em: <http://www.graptolite.net/Facta_Nautica/Renifer-0-01.html> Acesso em: 23 nov. 2017.

Pacific Marine. **Azimuth Propeller.** 2017. Disponível: <<http://www.pacificmarine.net/engineering/propeller-and-propeller-shaft/azimuth-propeller.htm>> Acesso em: 23 nov. 2017.

REGUEIRO, C.V. **Modelos Básicos de Redes Neuronales Artificiales.** Universidad de A Coruña. 1995.

Rimorchiatori Riuniti. **Serviço de Reboque Portuário.** 2017. Disponível em: <<http://www.rimorchiatori.com/pt-br/servico-de-reboque-portuario/>>. Acesso em: 16 ago. 2017.

RUELA, A.S. **Redes Neurais Feedforward e Backpropagation.** Departamento de computação, Universidade Federal de Ouro Preto. 2012.

SANTOS, K.S.Y. **Modelo de Síntese e Otimização para o Projeto de Concepção de Rebocadores Portuários.** São Paulo. 2016.

SCHEIN, D. **Uma Metodologia para o Dimensionamento de Frota de Rebocadores em Terminais Portuários: Uma Aplicação ao Porto Rio Grande.** Universidade Federal do Rio Grande – FURG, Escola de Engenharia. 2010.

SEGATTO, E.C. **Redes Neurais Aplicadas a relés diferenciais para transformadores de potência.** Sba Controle e Automação. 2008.

SÁEZ, A. **Bremen.** 2010. Disponível em: <<http://oportodagradosa.blogspot.com.br/2010/05/bremen.html>> Acesso em: 23 nov. 2017.

SILVA, E.; OLIVEIRA, A.C. **Dicas Para a Configuração de Redes Neurais.** 2007.

Sincomam. **Estaleiro de Santa Catarina entrega rebocador portuário financiado pelo FMM.** 2015. Disponível em: <<http://www.sincomam.com.br/index.php/estaleiro-de-santa-catarina-entrega-rebocador-portuario-financiado-pelo-fmm/>> Acesso em: 23 de nov. de 2017.

SOUZA, K.B. **Ferramentas de Análise Inteligente Aplicadas ao Planejamento e Controle da Construção Naval.** Rio Grande. 2011.

Surveyor's Lexicon. **Marine Surveyor's Lexicon.** 2002. Disponível em: <<http://www.surveyorslexicon.com/index.php?RefNum=2023>>. Acesso em: 22 out. 2017

TANCREDI, T.P. **Otimização Multidisciplinar Distribuída aplicada a Projetos de Engenharia.** USP, São Paulo. 2008.

TANCREDI, T.P.; ANDRADE, B.L.R. **Multiobjective Optimization of Tugboats.** Laboratório de Otimização e Projeto Integrado. São Paulo. 2013.

THEODORIS, S. **Pattern Recognition.** Academic Press, USA. 1999.

U.S Towing Navy Towing Manual. **SL740-AA-MAN-010**. Published by direction of Commander, Naval Sea Systems Command. 2002.

VELDE, M.V. **Voith Schneider Propeller Simulation**. 2009. Disponível em: <<http://www.theartofdredging.com/voithschneider.htm>> Acesso em: 23 nov. 2017.

VELLASCO, M.M.B.R. **Redes Neurais Artificiais**. Laboratório de Inteligência Computacional Aplicada. 2007.

Workboatsales.com. **31.1m Single Screw Tug For Sale**. 2017. Disponível em: <<http://www.workboatsales.com/vessel/31-1m-single-screw-tug-for-sale/>>. Acesso em: 14 out. 2017.

ZURADA, J.M. **Introduction to Artificial Neural Systems**. West Publishing Company. 1992.

ANEXO A

Tabela A.1 – Dados utilizados para treinamento da rede neural do Caso I

Dados de entrada do problema						Dados de saída esperados			
M (kg*m)	V (kg)	N (kg)	Zn (cm)	b (cm)	Cc/ca	h (cm)	A _s (cm ²)	A _s ' (cm ²)	A _{sw} (cm ²)
3000,00	1000,00	1000,00	5,00	15,00	40,00	26,70	5,67	0,62	2,10
4000,00	1000,00	1000,00	5,00	15,00	40,00	30,10	6,59	0,62	2,10
5000,00	1000,00	1000,00	5,00	15,00	40,00	33,20	7,36	0,62	2,10
6000,00	1000,00	1000,00	5,00	15,00	40,00	35,90	8,09	0,62	2,10
7000,00	1000,00	1000,00	5,00	15,00	40,00	38,40	8,76	0,62	2,10
8000,00	1000,00	1000,00	5,00	15,00	40,00	40,80	9,35	0,62	2,10
3000,00	2000,00	1000,00	5,00	15,00	40,00	26,70	5,67	0,62	2,10
4000,00	2000,00	1000,00	5,00	15,00	40,00	30,10	6,59	0,62	2,10
5000,00	2000,00	1000,00	5,00	15,00	40,00	33,20	7,36	0,62	2,10
6000,00	2000,00	1000,00	5,00	15,00	40,00	35,90	8,09	0,62	2,10
7000,00	2000,00	1000,00	5,00	15,00	40,00	38,40	8,76	0,62	2,10
8000,00	2000,00	1000,00	5,00	15,00	40,00	40,80	9,35	0,62	2,10
3000,00	3000,00	1000,00	5,00	15,00	40,00	26,70	5,67	0,62	3,31
4000,00	3000,00	1000,00	5,00	15,00	40,00	30,10	6,59	0,62	2,67
5000,00	3000,00	1000,00	5,00	15,00	40,00	33,20	7,36	0,62	2,22

Onde,

M = momento fletor; V = força cortante; N = força normal; Zn = ponto de aplicação da força N; b = base da seção transversal; Cc/Ca = custo de m³ de concreto/custo de m³ de aço; h = altura da seção transversal; A_s = armadura positiva; A_s' = armadura negativa; A_{sw} = armadura de cisalhamento.

Tabela A.2 – Faixa de valores de entrada da rede para determinar a qualidade do fio

Variável	Valor mínimo	Valor máximo
Micronaire (µg/in ²)	3,21	4,37
Uniformidade (%)	77,90	86,23
Comprimento (mm)	27,77	30,86
Resistência (gf/tex)	27,60	33,73
Maturidade	0,8390	0,9110
SFI (%)	6,47	11,33
Alongamento (%)	6,05	10,03
Umidade (%)	5,60	9,65
Rotação (rpm)	11.052	12.277
Peão de estiragem	27	40
Coefficiente de torção	3,63	3,99

Tabela A.3 – Banco de dados utilizados no Caso V

Partes	WL* Plano	WL* Vert	Largura(t)	Volume(m3)	Número de painéis	Número de Subconjunto s
P1	78.0	50.9	58.7	247.5	3.0	6.0
P2	44.7	16.8	44.0	180.2	2.0	3.0
p3	44.7	16.8	44.0	180.2	2.0	3.0
P4	40.7	20.3	39.9	184.1	2.0	3.0
P5	40.7	20.3	39.9	184.1	2.0	3.0
P6	23.3	18.9	35.6	262.7	4.0	6.0
P7	23.3	18.9	35.6	262.7	4.0	6.0
P8	64.5	53.0	38.3	332.6	3.0	3.0
P9	64.5	53.0	38.3	332.6	3.0	3.0
P10	70.0	31.5	39.4	169.9	3.0	3.0
P11	62.8	38.7	39.4	169.9	3.0	3.0
P12	70.8	31.5	33.6	144.0	3.0	3.0
P13	70.8	31.5	33.6	144.0	3.0	3.0
P14	141.8	27.9	36.8	172.8	4.0	6.0
P15	120.0	28.9	35.4	176.3	3.0	5.0
P16	58.0	51.0	41.0	510.0	1.0	3.0
P17	58.0	51.0	41.0	510.0	1.0	3.0
P18	80.0	57.0	49.0	519.0	3.0	6.0
P19	27.0	9.0	16.0	176.0	1.0	6.0
P20	27.0	9.0	29.0	192.0	1.0	3.0
P21	36.0	13.0	33.0	276.0	1.0	6.0
P22	26.0	22.0	39.0	780.0	1.0	6.0
P23	24.0	12.0	32.0	144.0	1.0	0
P24	12.0	6.0	26.0	123.0	1.0	0
P25	17.0	8.0	23.0	97.0	1.0	0
P26	9.0	4.0	17.0	86.0	1.0	0
P27	24.0	12.0	32.0	144.0	1.0	0
P28	12.0	6.0	26.0	123.0	1.0	0
P29	17.0	8.0	23.0	97.0	1.0	0
P30	9.0	4.0	17.0	86.0	1.0	0

ANEXO B

Figura B – Dados do rebocador Strathfoyle

AZIMUTH STERN DRIVE TUG 2310 "STRATHFOYLE"	
GENERAL	
Yard number	512917
Delivery date	December 2016
Basic functions	Towing and mooring
Classification	Bureau Veritas I Ⓢ HULL • MACH Tug Unrestricted Navigation AUT UMS
Flag	U.K.
Owner	Londonderry Port and Harbour Commissioners
DIMENSIONS	
Length overall	22.73 m
Beam overall	10.43 m
Depth at sides	4.50 m
Draught aft	4.81 m
Displacement	409 t
TANK CAPACITIES	
Fuel oil	61.6 m ³
Fresh water	7.9 m ³
Sewage	2.9 m ³
Dirty oil	1.9 m ³
Lubrication oil	1.9 m ³
Bilge water	0.9 m ³
Lub. oil (auxiliaries)	0.9 m ³
PERFORMANCES	
Bollard pull ahead	48.8 t
Bollard pull astern	45.7 t
Speed ahead	12.5 kn
Speed astern	12.1 kn
PROPULSION SYSTEM	
Main engines	2x Caterpillar 3512C TA HD+/C
Total power	3000 bkW (4023 bhp) at 1600 rpm
Azimuth thrusters	Rolls Royce US 205 MK1
Clutches (on-off type)	Rolls Royce "Built in" type
Propeller diameter	2200 mm
Forced ventilation	50.000 m ³ /h
AUXILIARY EQUIPMENT	
Generator sets	2x Caterpillar C4.4 T, 230/400 V, 64.5 kVA, 50 Hz
Bilge pumps	2x Sterling SIHI AKHA 5101, 20 m ³ /h
Fuel pumps	2x Sterling SIHI AOHA 3101, 4.5 m ³ /h
Fuel filters	2x Nelson filters incl. water separator
Cooling system	Box cooling + anti-growth system
Hydraulic system	Double main engine driven pumps
DECK LAY-OUT	
Anchor	2x 360 kg Pool (High Holding Power)
Anchor/towing winch	Hydraulically driven split drum, pull 18 ton up to 11 m/min and slack rope speed up to 33 m/min, 130 ton brake
Towing hook aft	Mampaey, SWL 650 kN
Crane	Heila HLM 20-3S
Winch on crane	2000 kg
Towing winch aft	Hydraulically driven two speed winch, pull 18 ton up to 11 m/min and slack rope speed up to 22 m/min, 130 ton brake
Fendering	Cylinder rubber bow fender above W-block fender, rubber fender at sides, cylinder fenders aft and on the fore ship lugs are fitted for 7 heavy fender tyres
ACCOMMODATION	
For 4 persons, completely insulated and finished with durable modern linings, acoustical ceiling in the wheelhouse and floating floors. Air-conditioned accommodation with one cabin above main deck and two cabins below deck, galley/mess, sanitary facilities and switchboard room.	
NAUTICAL AND COMMUNICATION EQUIPMENT	
Searchlight	Pesch 1000 W
Radar system	Furuno FAR 2117
Chart plotter	OLEX 3D
Compass	Magnetic Kotter
Autopilot	Simrad AP-70
GPS	Furuno GP-170
Echosounder	Furuno FE-800
VHF radio telephone	2x Sailor Compact 6222, 1x with DSC
VHF hand-held	2x Jotron Tron TR-20
Navtex	Furuno NX-700A
AIS	Furuno FA-150
EPIRB	Jotron Tron 60S
Sart	Jotron Tron Sart 20
Anemometer	Observer, Windsonic OMC 115

APÊNDICE A

Tabela A.1 – Banco de dados utilizado na implementação do método da MAN e do modelo de rede neural - Parte 1/3

	LOA	LPP	BOA	BM	D	T	T aft	Des	BP	V	BHP	Potencia	RPM
	m	m	m	m	m	m	m	tonns	t	nos	HP	kW	
AZZAWIYA 6	16,56		5,54		2,54	2,04	2,21	87	16,8	11,2	1216	907	1800
THISEAS II	16,89		5,29		2,51	1,88	2,18	84	12,6	10,50	940	701	1800
TARPON BAY	18,70		8,06		2,75	2,09	2,25	198	12,5	8,90	960	716	1800
MAK	22,64		7,84		3,74	3,23	3,5	260	39,4	12,1	2720	2030	1800
DON LUCHO	22,64		7,84		3,74	3,44	3,71	279	39,2	12,2	2720	2030	1800
ARABIAN TAHF	22,64		7,84		3,74	3,33	3,6	268	38,8	12,1	2816	2101	1800
RESOURCE	22,65		8,00	8,00	2,99	2,00	2,00	160	16,9	10,90	1200	896	1800
BULAT	22,73		10,43		4,5	3,69	4,79	398	48,3	12,2	4023	3002	1800
WENZINA	24,47		11,33		4,6	3,188	5,31	455	68,1	13,5	5600	4179	1800
PB ENDEAVOL	24,47		10,7		4,6	3,282	5,47	483	68,1	12,8	5600	4179	1800
PB MURRUMBI	24,47		10,7		4,6	3,27	5,45	477	68,6	12,9	5600	4179	1800
ADSTEAM FEF	24,55		11,49		4,6	3,24	5,4	490	70,4	13,2	5692	4173	1800
MOSCHNYI	25,86		8,94		4,3	3,3	4,3	420	36,7	12,7	3500	2612	1800
TARKA	26,02		9,10		3,60	2,65	2,65	381	28,5	11,50	2200	1642	1800
SILIN	26,09		7,94		4,05	2,665	3,84	240	49,1	12,8	3500	2612	1800
SHAM	26,16		7,94		4,05	3,62	3,91	363	53,8	13,1	3822	2852	1800
IBRAHIM 1"	26,16		8,54		4,05	3,61	3,9	387	47,5	12,6	3300	2463	1800
ABEILLE DALI	28,67		10,43		4,6	3,54	4,74	519	59	13,6	4930	3679	1800
ISOLA DEL TIN	28,67		10,43		4,6	3,47	4,67	520	60,1	13,8	4930	3679	1800
TORNADO	28,67		10,43		4,6	3,48	4,68	550	51	12,7	4200	3134	1800
WATERSTROO	28,67		10,43		4,6	3,5	4,7	532	57,9	13,8	5000	3731	1800
SMIT GUADEL	28,67		10,43		4,6	3,63	4,83	570	60,5	13,7	4930	3679	1800
PB LEICHHARC	28,67		10,43		4,6	3,66	4,86	591	58,3	13,5	4930	3679	1800
SMIT CURAÇA	28,75		10,59		4,6	3,71	4,91	541	57	13,3	4626	3452	1800
PAK	29,16		8,84		4,4	4,09	4,42	495	62,6	13,3	4525	3377	1800
AGBODRAFO	29,24		8,84		4,4	4,31	4,64	551	67,5	13,5	5000	3731	1800
ELHAMDAB	30,00		8,84		4,40	4,35	4,35	481	34,4	11,90	2600	1940	900
ZEETIJGER	30,08		9,1		4,4	3,2	3,2	350	50,7	12	3344	2496	1800
PILBARA NEP1	30,6		11,2		5	3,81	5,16	680	67,3	13,2	5000	3731	750
PAWLINA	30,6		11,2		5	3,56	4,86	635	67,1	13,4	5600	4179	1800
KARLOO	30,6		11,24		5	3,45	4,75	597	69,3	13,5	5600	4179	1800
KIBOKO II	30,82		10,2		4,8	3,6	4,8	525	58	13,5	4626	3452	1800
SULTAN HABIE	30,82		10,2		4,8	3,66	4,88	602	54,7	12,9	4750	3545	1800
SMIT OWENA	30,82		10,2		4,8	3,88	5,08	640	60,3	13,5	4930	3679	1800
HELIOS	31,91		8,84		4,4	3,95	4,28	624	66,1	13,4	4750	3545	1800
SMIT PANTHEF	32,14		13,29		5,5	4,93	6,43	1035	94,7	14,3	7288	5424	1000
LAMNALOO PL	32,14		13,29		5,5	4,62	6,02	998	75,5	14,2	6630	4873	1000
STANFORD	32,22		11,24		5	4,15	5,5	840	66,7	14,2	5310	3963	750
SMIT RIO MUNI	32,22		11,24		5	4,16	5,46	804	68,1	13,8	5605	4183	1800
SMIT LYNX	32,22		11,24		5	4,07	5,37	790	66,9	13	5605	4183	1800

Tabela A.2 – Banco de dados utilizado na implementação do método da MAN e do modelo de rede neural - Parte 2/3

	Reducao Motor		Oil Tank m3	Fresh W m3	Propulsor	Dprop mm
AZZAWIYA 6	4.5:1	2x Caterj	14,2	14,2	2 nozzles	1350
THISEAS II	5.04 : 1	2x Caterj	13,70	0,70	2 nozzles	1300
TARPON BAY	4.56:1	2x Caterj	54,10	15,40	2 nozzles	1300
MAK	5.95 : 1	2x Caterj	37	8,7	2 nozzles	2200
DON LUCHO	5.95 : 1	2x Caterj	36,8	8,6	2 nozzles	2200
ARABIAN TAHF	5.95 : 1	2x Caterj	36,8	8,6	2 nozzles	2200
RESOURCE	4.29:1	2x Caterj	44,00	6,90	2 nozzles	1500
BULAT		2x Caterj	60	8	2	2200
WENZINA		2x Caterj	74,8	8,6	2	2600
PB ENDEAVOL		2x Caterj	74,8	8,6	2	2600
PB MURRUMBI		2x Caterj	74,8	8,6	2	2600
ADSTEAM FER		2x Caterj	74,8	7,5	2	2600
MOSCHNYI		2x Caterj	72,1	12,1	2	2000
TARKA	5.421:1	2x Caterj	126,80	30,30	2 nozzles	1800
SILIN	7.09:1		81,8	12,2	2 nozzles	2350
SHA'M	7.087 : 1	2x Caterj	80,7	12,2	2 nozzles	2350
IBRAHIM 1*	7.476:1	2x Caterj	73,9	12,1	2 nozzles	2350
ABEILLE DALIA		2x Caterj	96,5	14,9	2	2400
ISOLA DEL TIN		2x Caterj	100,8	14,9	2	2400
TORNADO		2x Caterj	96,5	14,9	2	2400
WATERSTROO		2x Caterj	96,9	14,9	2	2400
SMIT GUADEL(C		2x Caterj	100,1	14,9	2	2400
PB LEICHHARC		2x Caterj	102,1	15,3	2	2400
SMIT CURAÇA		2x Caterj	96,9	14,1	2	2400
PAK	7.45:1	2x Caterj	145,1	21	2 nozzles	2650
AGBODRAFO	7.526:1	2x Caterj	135,1	20,6	2 nozzles	2650
ELHAMDAB	3.905 : 1	2x MAN	93,60	20,60	2 nozzles	2050
ZEETJGER	6.44:1	2x Caterj	174,9	40,9	2 nozzles	2250
PILBARA NEPT		2x Niigat	107,3	28,8	2	2700
PAWLINA		2x Caterj	93,2	28,8	2	2600
KARLOO		2x Caterj	89,7	28,7	2	2600
KIBOKO II		2x Caterj	136,6	63,2	2	2400
SULTAN HABIE		2x Caterj	135,3	61,9	2	2400
SMIT OWENA		2x Caterj	136,6	19,2	2	2400
HELIOS	7.455:1	2x Caterj	225,8	47,7	2 nozzles	2650
SMIT PANTHEF		2x Caterj	200	65,6	2	3000
LAMNALCO PU		2x Berge	200	65,6	2	2800
STANFORD		MAK 6M	171,6	56,8	2	2700
SMIT RIO MUNI		Caterpilla	148,4	57	2	2600
SMIT LYNX		Caterpilla	171,7	56,2	2	2600

Tabela A.3 – Banco de dados utilizado na implementação do método da MAN e do modelo de rede neural - Parte 3/3

	Pas	Passo	Bow T	Bow B	Year	IMO	Decks	Antepa
				BHP				
AZZAWIYA 6	3	fixed	Leme		2012		1	4
THISEAS II	3	Fixo	Leme	2x 25 r	2005		1	4
TARPON BAY		Fixo	Leme		2005		1	4
MAK	4	fixed	Leme		2006		1	3
DON LUCHO	4	fixed	Leme		2008		1	3
ARABIAN TAHF	4	fixed	Leme		2008		1	3
RESOURCE	4	fixed		1 100	2010		1	3
BULAT		AZIMUTI	AZIMUTH		2009		1	3
WENZINA	5	AZIMUTI	AZIMUTH		2006		1	5
PB ENDEAVOL	5	AZIMUTI	AZIMUTH		2010		1	4
PB MURRUMBI	5	AZIMUTI	AZIMUTH		2010		1	4
ADSTEAM FER	5	AZIMUTI	AZIMUTH		2005		1	4
MOSCHNYI	5	AZIMUTI	AZIMUTH		2006		1	3
TARKA	4	Fixo		1 120	2004		1	4
SILIN	4	fixed	Leme		2005		1	5
SHA'M	4	fixed	Leme		2008		1	4
IBRAHIM 1"	3		Leme		2012		1	4
ABEILLE DALIA		AZIMUTI	AZIMUTH		2007		1	6
ISOLA DEL TIN		AZIMUTI	AZIMUTH		2007		1	4
TORNADO		AZIMUTI	AZIMUTH		2008		1	5
WATERSTROO		AZIMUTI	AZIMUTH		2008		1	5
SMIT GUADEL		AZIMUTI	AZIMUTH		2009		1	4
PB LEICHHARL		AZIMUTI	AZIMUTH		2010		1	5
SMIT CURAÇA	5	AZIMUTI	AZIMUTH		2005		1	5
PAK	4	fixed	Leme		2005		1	4
AGBODRAFO	3	fixed	Leme		2010		1	3
ELHAMDAB	3	fixed	Leme		2006		1	4
ZEETJGER	4	fixed		1 250	2010		1	3
PILBARA NEPT		AZIMUTI	AZIMUTH		2005		1	6
PAWLINA		AZIMUTI	AZIMUTH		2006		1	5
KARLOO		AZIMUTI	AZIMUTH		2011		1	6
KIBOKO II	5	AZIMUTI	AZIMUTH		2004		1	4
SULTAN HABIE	5	AZIMUTI	AZIMUTH		2006		1	4
SMIT OWENA	5	AZIMUTI	AZIMUTH		2006		1	4
HELIOS	3	fixed	Leme		2004		1	3
SMIT PANTHEF	4	AZIMUTH			2009		1	4
LAMNALCO PU	4	AZIMUTI	AZIMUTH		2011		1	4
STANFORD		AZIMUTI	AZIMUTH		2005		1	4
SMIT RIO MUNI		AZIMUTI	AZIMUTH		2008		1	5
SMIT LYNX		AZIMUTI	AZIMUTH		2010		1	6

APÊNDICE B

Tabela B.1 – Estimativa de Bollard Pull com métodos aproximados

Nome	BP Real	Modelo 2.2.2.1	Modelo 2.2.2.2	Modelo 2.2.2.3	Modelo 2.2.2.4
BULAT	48,3	45,1	56,3	13,8	40,2
WATERSTROOM	57,9	69,1	70,0	24,1	40,3
PILBARA NEPTUNE	67,3	79,0	70,0	24,9	40,4
MOSCHNYI	36,7	42,1	49,0	16,1	40,3

APÊNDICE C

Tabela C.1 – Dados técnicos dos rebocadores que serão treinados na RNA

D propulsor (mm)	BHP (HP)	Bollard Pull (ton)
1350	1216	16,8
1300	940	12,6
1300	960	12,5
2200	2720	39,4
2200	2720	39,2
2200	2816	38,8
1500	1200	16,9
2600	5600	68,1
2600	5600	68,1
2600	5600	68,6
2600	5592	70,4
1800	2200	28,5
2350	3500	49,1
2350	3822	53,8
2350	3300	47,5
2400	4930	59
2400	4930	60,1
2400	4200	51
2400	4930	60,5
2400	4930	58,3
2400	4626	57
2650	4525	62,6
2650	5000	67,5
2050	2600	34,4
2250	3344	50,7
2600	5600	67,1
2600	5600	69,3
2400	4626	58
2400	4750	54,7
2400	4930	60,3
2650	4750	66,1
3000	7268	94,7
2800	6530	75,5
2700	5310	66,7
2600	5605	68,1
2600	5605	66,9

APÊNDICE D

Tabela D.1 – Resultados dos treinamentos das RNAs para cada grupo de ciclos

1 mil ciclos	1cam-5neu	1cam-8neu	2cam-5neu	2cam-8neu	MAN	REAL
BULAT	47,61	48,57	48,33	48,81	48,7	48,3
WATERSTROOM	60,63	61,39	61,11	61,50	60,1	57,9
PILBARA NEPTUNE	68,61	68,01	68,74	68,88	62,8	67,3
MOSCHNYI	38,02	39,30	38,54	39,15	42,0	36,7

10 mil ciclos	1cam-5neu	1cam-8neu	2cam-5neu	2cam-8neu	MAN	REAL
BULAT	46,25	46,24	46,77	46,86	48,7	48,3
WATERSTROOM	59,26	59,24	59,74	59,79	60,1	57,9
PILBARA NEPTUNE	69,53	69,49	69,26	69,26	62,8	67,3
MOSCHNYI	36,56	36,54	36,99	37,07	42,0	36,7

100 mil ciclos	1cam-5neu	1cam-8neu	2cam-5neu	2cam-8neu	MAN	REAL
BULAT	47,65	47,31	46,49	46,44	48,7	48,3
WATERSTROOM	59,51	59,50	59,47	59,34	60,1	57,9
PILBARA NEPTUNE	67,11	67,26	69,19	69,25	62,8	67,3
MOSCHNYI	38,81	38,23	36,68	36,72	42,0	36,7

1 milhão ciclos	1cam-5neu	1cam-8neu	2cam-5neu	2cam-8neu	MAN	REAL
BULAT	50,44	50,08	49,26	49,90	48,7	48,3
WATERSTROOM	59,45	59,46	59,50	59,33	60,1	57,9
PILBARA NEPTUNE	67,49	67,51	66,95	67,12	62,8	67,3
MOSCHNYI	43,78	38,68	41,05	42,44	42,0	36,7

