

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

JOHNE NEGRÃO TRINDADE

MODELAGEM E AVALIAÇÃO DE REDES NEURAS ARTIFICIAIS GENERALISTAS
PARA ESTIMATIVA DO COMPORTAMENTO DE LINHAS DE ANCORAGEM
FORMADAS POR MÚLTIPLOS SEGMENTOS HETEROGÊNEOS

Joinville

2024

JOHNE NEGRÃO TRINDADE

MODELAGEM E AVALIAÇÃO DE REDES NEURAS ARTIFICIAIS GENERALISTAS
PARA ESTIMATIVA DO COMPORTAMENTO DE LINHAS DE ANCORAGEM
FORMADAS POR MÚLTIPLOS SEGMENTOS HETEROGÊNEOS

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

Orientador: Dr. Thiago Pontin Tancredi

Joinville

2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Trindade, Johne Negrão

Modelagem e avaliação de redes neurais artificiais generalistas para a estimativa do comportamento de linhas de ancoragem formadas por múltiplos segmentos heterogêneos / Johne Negrão Trindade ; orientador, Thiago Pontin Tancredi, 2024.

55 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Campus Joinville,
Graduação em Engenharia Naval, Joinville, 2024.

Inclui referências.

1. Engenharia Naval. 2. Inteligência Artificial. 3. Ancoragem. 4. Offshore. 5. Catenária. I. Tancredi, Thiago Pontin. II. Universidade Federal de Santa Catarina. Graduação em Engenharia Naval. III. Título.

JOHNE NEGRÃO TRINDADE

MODELAGEM E AVALIAÇÃO DE REDES NEURAS ARTIFICIAIS GENERALISTAS
PARA ESTIMATIVA DO COMPORTAMENTO DE LINHAS DE ANCORAGEM
FORMADAS POR MÚLTIPLOS SEGMENTOS HETEROGÊNEOS

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de bacharel em Engenharia Naval, no Centro Tecnológico de Joinville, da Universidade Federal de Santa Catarina.

Joinville (SC), 01 de julho de 2024.

Banca Examinadora:

Dr. Thiago Pontin Tancredi
Orientador/Presidente
Universidade Federal de Santa Catarina

Dr. Bernardo Luis Rodrigues de Andrade
Membro
Universidade de São Paulo

Dr. Pablo Andretta Jaskowiak
Membro
Universidade Federal de Santa Catarina

Dedico este trabalho à minha família e amigos.

AGRADECIMENTOS

Agradeço à Deus, cuja sabedoria me guiou por toda essa jornada. Tudo que há de bom e mim é um reflexo de sua presença.

Agradeço à minha família, em especial aos meus pais, João e Aldilene, meu irmão Andrey, e minha namorada Beatriz, cujo apoio incondicional e conselhos foram fundamentais para que eu chegasse até aqui.

Agradeço aos meus amigos, que durante a jornada sempre se posicionaram ao meu lado, proporcionando momentos de apoio e descontração.

Agradeço aos meus amigos de faculdade, em especial Julian, Raul e Guilherme, por tornarem essa graduação mais leve e recompensadora.

Agradeço ao meu orientador, Dr. Prof. Thiago Pontin, cujo direcionamento e experiência foram essenciais para desenvolver o pensamento analítico de um engenheiro.

Agradeço ao LaSiN pelo apoio e oportunidade de aprofundar as pesquisas, contribuindo significativamente para este trabalho.

Agradeço à Petróleo Brasileiro S.A. (Petrobrás) pela disponibilização do software Exmoor, que viabilizou a realização deste trabalho.

RESUMO

A aplicação de técnicas de inteligência artificial na resolução de problemas é um dos tópicos mais discutidos atualmente, tanto no âmbito acadêmico quanto nos setores produtivos. Embora as aplicações mais populares estejam relacionadas ao processamento de texto ou imagens, o uso de redes neurais do tipo MLP é uma estratégia conhecida para a construção de modelos de interpolação para problemas de difícil solução, mas de histórico conhecido. Entre os diversos problemas de engenharia que se encaixam nesse contexto, o projeto do sistema de ancoragem de plataformas offshore que operam em águas profundas apresenta características que motivam o uso de técnicas de IA. Embora no passado o projeto de sistemas de ancoragem para plataformas operando a lâminas d'água de até 400 metros fosse baseado em métodos empíricos, os desafios impostos pela exploração de reservas localizadas a mais de 3000 metros da lâmina d'água requerem a aplicação de heurísticas racionais de projeto. Nesses casos, a quantidade de variáveis e, principalmente, de atributos de desempenho avaliados, fazem com que seja difícil estimar o comportamento de uma linha de ancoragem sujeita a diferentes condições ambientais. Tradicionalmente, tal análise é feita resolvendo o problema da catenária elástica, cuja solução só pode ser obtida por métodos numéricos que consomem segundos de processamento. Embora o tempo de resolução de uma única catenária seja inferior a um segundo, a resolução de milhares de combinações de casos e parâmetros pode resultar em um alto custo computacional, que dificulta ou até inviabiliza a aplicação de técnicas de otimização. Assim, para mitigar essa problemática, este trabalho apresenta o desenvolvimento de redes neurais do tipo MLP capazes de uma vez treinada, estimar instantaneamente o comportamento mecânico de uma linha de ancoragem para uma determinada condição de carregamento. No modelo desenvolvido, a linha é dividida em três segmentos (topo, meio e fundo), sendo as variáveis de cada segmento o comprimento relativo do segmento, o peso molhado do segmento e a tração no topo. O treinamento da rede foi dividido em 2 partes, com e sem a introdução do parâmetro de parada prévia, o qual busca atenuar a possibilidade de overtraining, fenômeno no qual as redes neurais reduzem a habilidade de generalização do problema. No total 55 redes neurais com topologias e métodos de treinamento diferentes foram desenvolvidas e analisadas. Os resultados obtidos sugerem que é possível substituir o algoritmo numérico de análise de catenária por uma única rede neural do tipo MLP.

Palavras-chave: Inteligência Artificial. Ancoragem. Offshore. Catenária.

ABSTRACT

The application of artificial intelligence techniques to problem-solving is one of the most discussed topics today, both in academic circles and productive sectors. While popular applications are often related to text or image processing, the use of Multilayer Perceptron (MLP) neural networks is a known strategy for constructing interpolation solution for complex but historically well-understood problems. Among the various engineering challenges that fit into this context, the design of anchoring systems for offshore platforms operating in deep waters presents characteristics that motivate the use of AI techniques. In the past, designing anchoring systems for platforms operating in water depths up to 400 meters relied on empirical methods. However, challenges posed by the exploration of reserves located over 3000 meters deep necessitate the application of rational design heuristics. In these cases, the numerous variables and performance attributes make it difficult to estimate the behavior of an anchor line under different environmental conditions. Traditionally, such analysis involves solving the elastic catenary problem, whose solution requires numerical methods that consume significant processing time. While the resolution time for a single catenary is less than a second, solving thousands of combinations of cases and parameters can result in high computational costs, making optimization techniques challenging or even impractical. Therefore, to mitigate this issue, this work presents the development of MLP neural networks capable of instantly estimating the mechanical behavior of an anchor line for a given loading condition once trained. In the developed model, the anchor line is divided into three segments (top, middle, and bottom), with variables for each segment including relative segment length, wet weight of the segment, and top tension. The network training was divided into two parts, with and without the introduction of early stopping parameters, which aims to mitigate the possibility of overtraining, a phenomenon where neural networks reduce their ability to generalize the problem. In total, 55 neural networks with different topologies and training methods were developed and analyzed. The results obtained suggest that it is feasible to replace the numerical catenary analysis algorithm with a single MLP neural network.

Keywords: Artificial Intelligence. Mooring. Offshore. Optimization. Catenary.

LISTA DE FIGURAS

Figura 1 – Exemplos de plataformas de petróleo	14
Figura 2 - Comparação catenária (convencional) e Taut-leg	16
Figura 3 - Cabo em configuração de catenária	17
Figura 4 - Ancoragem em catenária de unidade flutuante.....	18
Figura 5 - Variação do comprimento da linha.....	19
Figura 6 - Elemento infinitesimal da linha de ancoragem.....	19
Figura 7 - Modelagem de uma unidade de processamento básica	21
Figura 8 - Representação da topologia de rede	22
Figura 9 - Metodologia	26
Figura 10 - Ilustração dos segmentos da linha de ancoragem	29
Figura 11 - Modelo simplificado.....	33
Figura 12 - Variação do raio de ancoragem em função da tração no topo.....	34
Figura 13 - Linha de ancoragem exemplo	39
Figura 14 - Predições com linhas que fizeram parte do treinamento	40
Figura 15 - Predições com linhas não utilizadas no treinamento	41
Figura 16 - Curvas de treinamento.....	44
Figura 17 - Resultados para linhas de ancoragem conhecidas.....	45
Figura 18 - Resultado modelo 15 (linhas não utilizadas no treinamento).....	46
Figura 19 - Resultado modelo 20 (linhas não utilizadas no treinamento).....	46
Figura 20 - Resultado modelo 25 (linhas não utilizadas no treinamento).....	47
Figura 21 - Resultado modelo 34 (linhas não utilizadas no treinamento).....	47
Figura 22 - Resultado modelo 39 (linhas não utilizadas no treinamento).....	48

LISTA DE TABELAS

Tabela 1 - Divisão do comprimento restante para as amarras	32
Tabela 2 - Topologias de rede.....	34
Tabela 3 - Topologias de rede neural sem earlystopping.....	38
Tabela 4 - Topologias e épocas de treinamento praticadas	42
Tabela 5 - Síntese dos resultados.....	48
Tabela 6 - Amostra do banco de dados	55

LISTA DE ABREVIATURAS E SIGLAS

GELU – Gaussian Error Linear Unit

MLP – Multilayer Perceptron

ReLU – Rectified Linear Unit

VS Code – Visual Studio Code

EQM – Erro Quadrático Médio

TDP - Ponto de toque

SUMÁRIO

1. INTRODUÇÃO	13
1.1. OBJETIVOS	15
1.1.1. Objetivo Geral	15
2. FUNDAMENTAÇÃO TEÓRICA	16
2.1. LINHAS DE ANCORAGEM	16
2.1.1. Ancoragem em catenária	17
2.2. REDES NEURAIS	20
2.2.1. Unidade de processamento	21
2.2.2. Arquitetura da rede	21
2.2.3. Funções de ativação	23
2.2.4. Aprendizado e validação	24
3. METODOLOGIA	26
4. DESENVOLVIMENTO	29
4.1. APLICAÇÃO DA REDE NEURAL	29
4.1.1. Seleção das variáveis de entrada	30
4.2. DESENVOLVIMENTO DO BANCO DE DADOS	31
4.3. TOPOLOGIA	34
4.4. TREINAMENTO	36
4.5. TESTE DE GENERALIZAÇÃO	37
5. RESULTADOS	38
5.1. TREINAMENTO SEM CRITÉRIO DE PARADA ANTECIPADA	38
5.2. TREINAMENTO COM CRITÉRIO DE PARADA PRÉVIA	42
6. CONCLUSÃO	50
6.1. TRABALHOS FUTUROS	50
REFERÊNCIAS	52
APÊNDICE A – BANCO DE DADOS	55

1. INTRODUÇÃO

A história da evolução tecnológica é marcada por mudanças na forma como a energia é obtida para os mais diversos fins, chegando ao cenário atual onde a maior parte da matriz energética mundial advém de fontes não renováveis, tais como carvão, petróleo e seus derivados (EMPRESA DE PESQUISA ENERGÉTICA - EPE, 2022).

Em razão das particularidades envolvidas no processo de extração petrolífera, a localização das bacias sedimentares de cada país foi fator chave para guiar os seus respectivos avanços tecnológicos (PEIXOTO, 2014).

Embora tais bacias possam ser divididas em *onshore* e *offshore*, no Brasil, a maior parte das reservas petrolíferas estão localizadas para além da costa marítima, ou seja, em áreas offshore.

Em 2006 foi revelada a existência de um campo petrolífero abaixo de uma espessa camada de sal, de aproximadamente 2.000 km, chamada pré-sal, em campos com altura de lâmina d'água de mais de 3000 m (PETROBRAS, 2022).

A exploração de águas cada vez mais profundas, tornou economicamente inviável a instalação de plataformas fixas (Figura 1b), as quais limitam-se a lâminas d'água em torno de 300 m de profundidade.

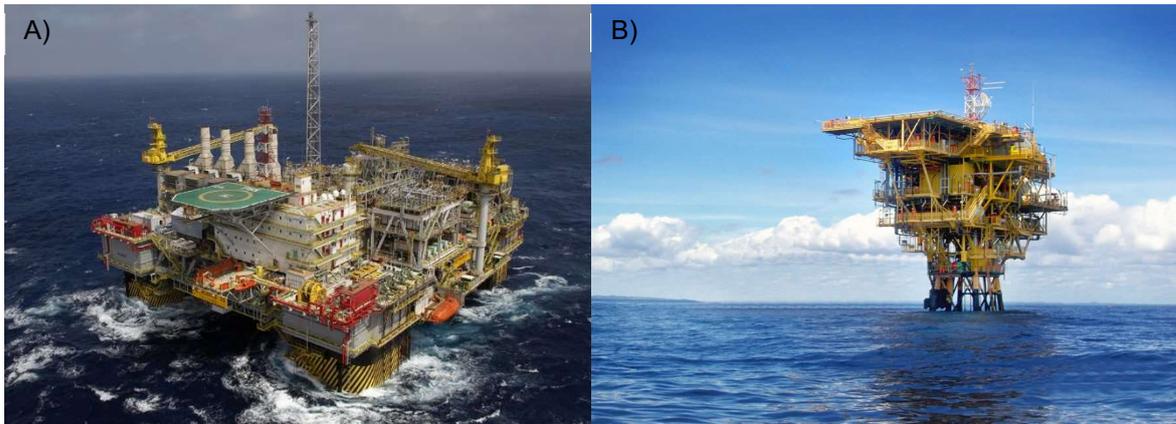
Para viabilizar a exploração de petróleo em águas profundas e ultra profundas, iniciando em 300 m e podendo chegar a profundidades maiores que 3500 m, foram desenvolvidas as plataformas flutuantes (Figura 1a). Diferentemente das plataformas fixas que são conectadas ao fundo do mar por estacas, as plataformas flutuantes têm sua localização mantida por sistemas de posicionamento dinâmico, ancoragem ou ambos.

A atividade exploratória de petróleo pode ser dividida em três etapas: prospecção (localizar as bacias sedimentares), perfuração (perfurar o solo até as jazidas de petróleo) e produção (extrair o material do solo) (ETESCO, 2021).

A etapa de produção normalmente é a de maior duração, podendo variar de acordo com fatores tais como o tamanho do reservatório e o número de cabeças de poço exploradas simultaneamente.

Por exemplo, o complexo Cantarell, localizado no México, deu início a fase de produção na década de 70 e, embora tenha tido sua produção progressivamente diminuída com o passar dos anos, continua ativo até hoje.

Figura 1 – Exemplos de plataformas de petróleo



A) Exemplo de plataforma flutuante. B) Exemplo de plataforma fixa.

Fonte: Banco de imagens Petrobras (2022)

Para viabilizar a operação de produção, é necessário que a plataforma tenha seu deslocamento no plano da linha d'água limitado, para assim não comprometer a integridade estrutural dos risers que fazem a extração do óleo.

Devido a longa duração da etapa de produção, a maneira economicamente mais viável para manter o posicionamento de uma plataforma offshore de produção são as linhas de ancoragem. Nesse sistema a plataforma é conectada ao solo marítimo por linhas, as quais podem ser compostas de um único material ao longo de todo seu comprimento, ou fabricadas contendo trechos de diferentes materiais.

Segundo Andrade et al. (1995), o projeto de um sistema de ancoragem deve considerar a excitação na plataforma provocada pelas mais diversas condições ambientais, geradas pela combinação de ondas, correnteza e vento; limitando o passeio da plataforma e garantindo a integridade estrutural das linhas de produção.

Segundo Rolfsen et al. (2013), o excesso de cargas ocasionadas por forças dinâmicas e condições ambientais inesperadas são as causas mais comuns de falhas que levam ao rompimento das linhas de ancoragem, resultando na amplificação dos movimentos da plataforma e no rompimento dos risers de produção.

O rompimento dos risers de produção invariavelmente resulta no derramamento de óleo no oceano, trazendo prejuízo à vida marinha, poluindo a região e possibilitando, inclusive, explosões na plataforma.

Portanto, o correto dimensionamento do sistema de ancoragem de uma plataforma é uma tarefa complexa e de extrema importância, envolvendo a

determinação dos esforços causados pelas ações ambientais, as características das linhas e a análise das diversas restrições operacionais exigidas para o sistema.

Além disso, a análise da dinâmica de sistemas offshore ancorados é uma tarefa complexa e realizada, em geral, com base em simulações no domínio do tempo, as quais requerem um alto custo computacional.

Nesse contexto, o uso de redes neurais artificiais pode ser uma abordagem promissora para acelerar as análises pois, como discutido em Tancredi (2008), tais técnicas podem, a partir de um histórico conhecido, estimar o comportamento de sistemas complexos ou de difícil modelagem, com baixo custo computacional.

1.1. OBJETIVOS

Para resolver a problemática de estimar com um menor custo computacional o raio de ancoragem de uma unidade flutuante ancorada por uma única linha composta de 3 segmentos com materiais heterogêneos, propõe-se os objetivos descritos nessa seção.

1.1.1. Objetivo Geral

Desenvolver um conjunto de redes neurais Multilayer Perceptron (MLP) que, a partir das variáveis de entrada, estime o comportamento de uma linha de ancoragem composta por três segmentos heterogêneos.

1.1.2. Objetivos Específicos

- Formular redes neurais MLP específicas para a problemática descrita;
- Produzir um banco de dados que correlacione o comportamento de uma linha de ancoragem em função das características de seus segmentos;
- Treinar as redes neurais com o banco de dados gerados;
- Avaliar e comparar o desempenho de diferentes topologias e modelos de treinamento;
- Validar os resultados produzidos a partir da rede utilizando exemplos de linhas simuladas e que não participaram do treinamento da rede.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são abordados os principais aspectos do embasamento teórico necessário para dar prosseguimento ao projeto proposto, além de introduzir os fundamentos da metodologia empregada. Entre os tópicos discutidos, destacam-se: as propriedades de uma linha de ancoragem, a modelagem da catenária e, por fim, o subsídio teórico necessário para implementação de redes neurais na resolução da problemática proposta.

2.1. LINHAS DE ANCORAGEM

As linhas de ancoragem são um conjunto de elementos que ligam a plataforma ao leito marinho, podendo ou não serem homogêneos. Sua função consiste em limitar o passeio da unidade flutuante, fornecendo forças de restauração que mantem a plataforma em sua posição, transferindo para o solo marítimo os esforços sofridos pela unidade.

Quanto a configuração geométrica, as linhas de ancoragem podem estar dispostas em catenária ou em catenária retesada (ASSIS, 2013). No limite, quando a catenária se encontra totalmente retesada, o sistema é chamado de *taut-leg*.

Figura 2 - Comparação catenária (convencional) e Taut-leg



Fonte: Ferreira et al. (2016)

Segundo Leal (2016), o sistema de ancoragem é constituído por diferentes elementos (âncora, amarras, cabos de aço, cabos sintéticos e conectores), os quais

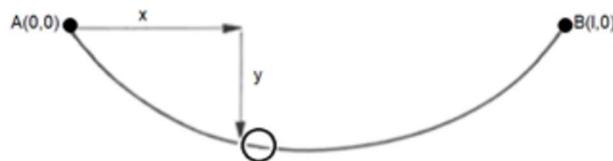
podem ser vistos na Figura 2. Embora uma descrição detalhada desses elementos fuja ao escopo deste trabalho, ela pode ser facilmente encontrada em qualquer texto sobre o assunto, como por exemplo Klippel (2022).

2.1.1. Ancoragem em catenária

O nome catenária refere-se a forma geométrica de uma linha ou corrente suspensa pelas extremidades e cuja deformação é causada apenas por seu próprio peso (Figura 3), adquirindo uma forma característica similar à observada em linhas de ancoragem e *risers* (TALAVERA, 2008).

Também chamada de ancoragem do tipo convencional, o sistema em catenária é comumente visto em unidades flutuantes que operam em águas rasas e profundas, enquanto o sistema retesado é mais comumente encontrado em plataformas que operam em águas ultra profundas.

Figura 3 - Cabo em configuração de catenária

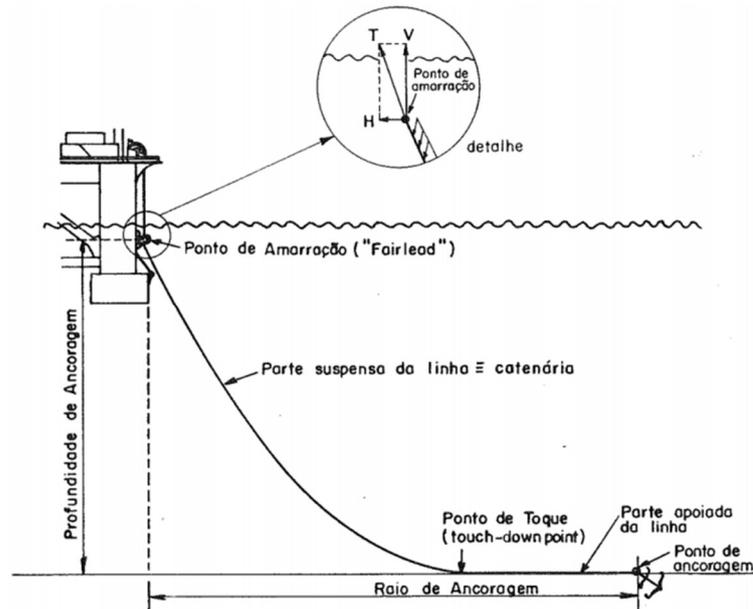


Fonte: Caughey (1974)

Em se tratando da ancoragem de plataformas offshore, a configuração em catenária possui a vantagem de não necessitar de âncoras com alto poder de penetração e agarramento, visto que uma fração da amarra fica apoiada no solo marítimo absorvendo parte dos carregamentos ambientais (MEDEIROS, 2009) e, portanto, as forças transmitidas para a âncora são majoritariamente paralelas ao solo (Figura 4).

No entanto, como discutido por Jacovazzo (2006), uma das desvantagens do sistema em catenária é o grande raio de ancoragem da plataforma, o qual decorre justamente da necessidade de parte da linha estar apoiada no fundo do oceano. De acordo com Nazário (2015), o raio de ancoragem da plataforma pode ser aumentado em decorrência de critérios mais restritos associados ao passeio da plataforma, dificultando a instalação de plataformas flutuantes próximas umas das outras.

Figura 4 - Ancoragem em catenária de unidade flutuante



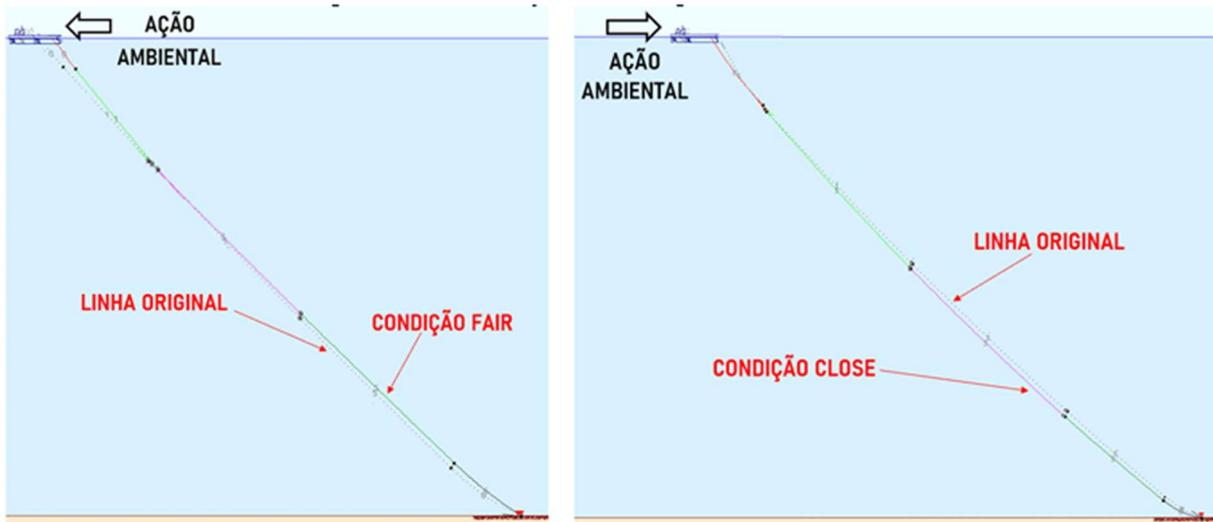
Fonte: Andrade et al. (1995)

Conforme a exploração de petróleo avança para águas ultra profundas, o peso das linhas de amarração se torna um fator limitante para o projeto, motivando o uso de cabos de fibra sintética, que substituem uma parte de cada uma das linhas de ancoragem, reduzindo o peso do sistema (ASSIS, 2013).

No entanto, mesmo nesses casos, no começo e no final das linhas ainda são utilizadas as amarras tradicionais, pois o atrito da linha com o fundo do mar e com o ponto de amarração na plataforma (fair-lead) romperiam os cabos de poliéster.

A catenária de uma linha de ancoragem é definida como a curva existente entre o ponto de toque (localizado no solo marinho) e o ponto de amarração (situado na unidade flutuante). No entanto, Segundo Gay (2012), a catenária referente ao trecho suspenso de uma linha de ancoragem apresenta uma de suas extremidades apoiada no leito do oceano e, como consequência, o ponto de contato com o solo (TDP) e a geometria da curva mudam à medida que a plataforma se movimenta (Figura 05).

Figura 5 - Variação do comprimento da linha

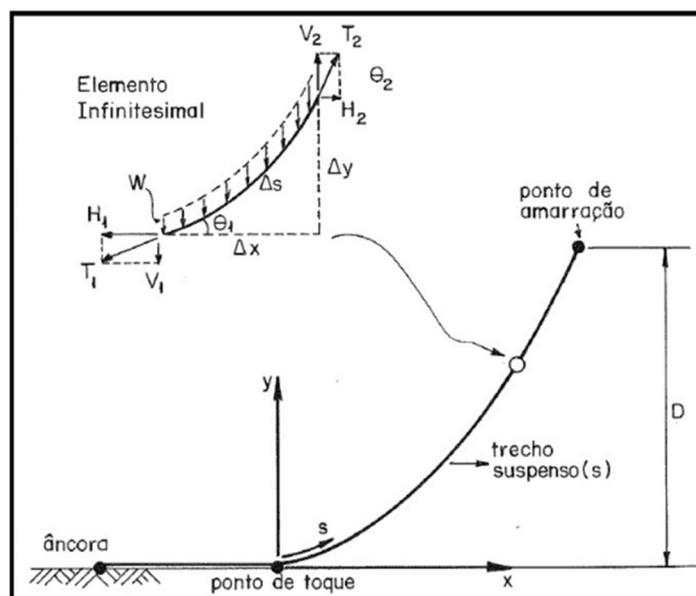


Fonte: Klippel (2022)

Nota-se que o TDP se move para longe da ancora quando a plataforma se movimenta na direção da ancora (condição near) e se aproxima da ancora quando a plataforma se movimenta para longe da ancora (condição fair).

De acordo com Nazário (2012), considerando uma linha inextensível e um leito marinho plano, a geometria de uma linha de ancoragem pode ser descrita pela Equação 1, a qual considera a discretização infinitesimal mostrada na Figura 6.

Figura 6 - Elemento infinitesimal da linha de ancoragem



Fonte: Andrade et al. (2012)

$$x = \frac{H}{w} * \left[\cosh^{-1} \left(\frac{w * y}{H} \right) + 1 \right] \quad (1)$$

Onde:

- x é a distância horizontal medida a partir do TDP (ponto de toque);
- y é a profundidade do local;
- H representa a tração horizontal;
- W é o peso linear submerso da linha.

Assumindo valores constantes de “w” e “H”, o comprimento suspenso da linha “S” pode ser obtido a partir da Equação 2:

$$S = \frac{H}{w} * \sinh \left(\frac{w * x}{H} \right) \quad (2)$$

2.2. REDES NEURAIIS

As redes neurais artificiais são técnicas computacionais que utilizam modelos matemáticos para simular a capacidade de organismos inteligentes em adquirir conhecimento através da experiência.

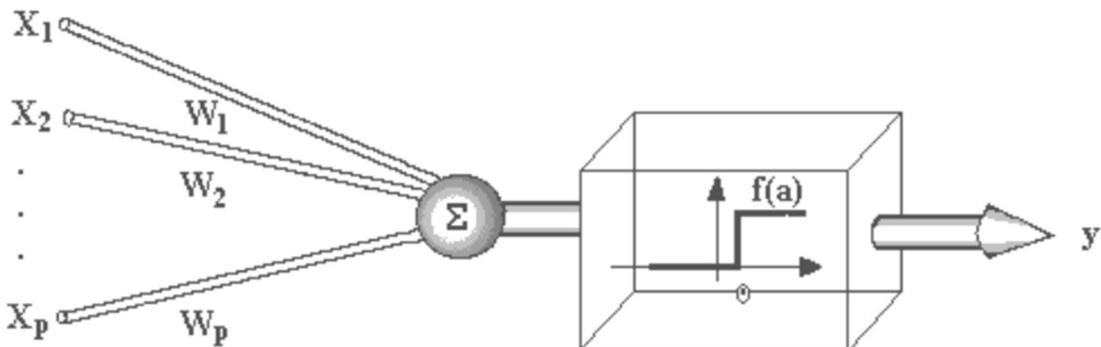
As primeiras publicações acerca desse tema introduziram os elementos fundamentais dessa teoria McCulloch e Pitts (1943), propuseram o primeiro modelo de redes neurais simulando máquinas Hebb (1949) e, por fim, propuseram o modelo Perceptron de aprendizado supervisionado Roseblatt (1958).

A grande vantagem da utilização de redes neurais artificiais consiste na capacidade que tais técnicas têm de reconhecer, associar e generalizar padrões (VELLASCO, 2007). Pois, embora em muitos casos, modelos mais simples, tais como as regressões lineares possam representar adequadamente o fenômeno de estudo, em problemas mais complexos, as redes neurais podem ser uma alternativa viável nos casos em que as técnicas tradicionais falham.

2.2.1. Unidade de processamento

Proposta pela primeira vez por McCulloch e Pitts (1943), a unidade de processamento refere-se a um elemento básico que recebe um conjunto de entradas ponderadas, executa uma operação de soma ponderada das entradas e, por fim, aplica uma função de ativação para produzir uma saída (Figura 6).

Figura 7 - Modelagem de uma unidade de processamento básica



Fonte: McCulloch (1943)

Nesse modelo, cada sinal de entrada x_i é multiplicado por um peso W_i que representa sua influência na saída da unidade. A seguir, é realizada a soma ponderada $X_i * W_i$, a qual serve como parâmetro de entrada na função de ativação definida para a unidade de processamento.

O conceito de unidade de processamento é fundamental para a construção de redes neurais, pois ela é responsável por processar informações e passá-las adiante para as camadas subsequentes. Assim, a combinação de várias unidades de processamento é a estrutura básica capaz de realizar as previsões associadas ao aprendizado de máquina.

2.2.2. Arquitetura da rede

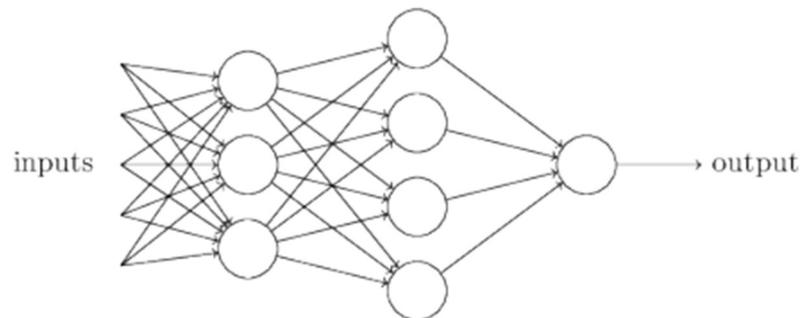
Após consolidar o que seria uma unidade de processamento, equivalente a um neurônio biológico, o próximo passo consiste na junção de várias unidades de processamento (ou neurônios), formando uma rede de processamento.

Nesse contexto, entende-se por arquitetura da rede neural a organização e conexões entre as diferentes unidades de processamento que constituem uma rede

neural. Dado que existem diferentes maneiras de estabelecer as conexões entre os neurônios, este trabalho utiliza a topologia mais comum, chamada de *Feedforward*.

Uma rede neural artificial feedforward consiste em uma série de camadas de neurônios, percorridas da camada de entrada até a camada de saída. Sendo que cada camada é composta por um conjunto de unidades de processamento, que recebem como entrada a saída de cada unidade de processamento da camada anterior. Já a primeira camada recebe como entrada os valores das variáveis usadas na modelagem do problema, formando a estrutura mostrada na Figura 7.

Figura 8 - Representação da topologia de rede



Fonte: Nielsen (2015)

Conforme pode ser visto na Figura 7, nas redes feedforward, as saídas de cada camada não são utilizadas para retroalimentar a própria rede, sendo essa uma característica das redes neurais do tipo *recorrentes* (Nielsen, 2015).

Segundo Goodfellow et al. (2015), as redes feedforward, também chamadas MLP (Multilayer Perceptron), formam a base para a maior parte das aplicações comerciais atuais de inteligência artificial, em especial aquelas associadas a previsão do comportamento de sistemas complexos.

Em se tratando de redes MLP, o modelo mais simples de arquitetura consiste em uma camada de entrada e uma camada de saída. Contudo, esse modelo não permite a rede neural identificar padrões intermediários presentes nos dados, exigindo que relações mais complexas sejam estabelecidas entre os neurônios. Para esse fim, foram cruciais os estudos desenvolvidos por Hinton (1986), pioneiro no treinamento de redes neurais com camadas ocultas.

Como discutido por Goodfellow et al. (2015), as camadas ocultas são assim chamadas por não apresentarem saídas associadas à modelagem do problema, mas

que são cruciais para o aprendizado de padrões e o estabelecimento de relações complexas entre as variáveis de entrada e de saída da rede.

O algoritmo de backpropagation, desenvolvido por Rumelhart et al. (1986), é uma técnica fundamental para treinar redes neurais com múltiplas camadas, que, segundo o autor, torna mais rápido o aprendizado da rede em comparação com as técnicas desenvolvidas anteriormente. Segundo Nielsen (2015), ainda hoje, o algoritmo de backpropagation representa uma peça fundamental para o treinamento de redes neurais artificiais.

De acordo com Tancredi (2008), o treinamento utilizando backpropagation consiste em calcular o erro entre as previsões da rede e os valores reais, o qual é propagado de volta pela rede, a partir da camada de saída, alterando os pesos das conexões usando a regra do delta generalizada e reduzindo o erro progressivamente de forma iterativa.

2.2.3. Funções de ativação

Conforme já mencionado, para cada unidade de processamento da rede neural é definida uma função de ativação utilizada no cálculo da saída daquele neurônio. Atualmente, algumas das principais funções de ativação utilizadas em unidades de processamento são:

- Função Sigmoide (Sigmoid);
- Função Tangente Hiperbólica (Hyperbolic Tangent);
- Função ReLU (Rectified Linear Unit);
- Função Softplus;
- Função GELU (Gaussian Error Linear Unit).

As funções de ativação são elementos essenciais nas redes neurais, pois fornecem não linearidade e a capacidade de representação das possíveis relações complexas existentes nos dados utilizados no treinamento.

Como discutido por Goodfellow et al. (2015), cada uma das funções de ativação possui propriedades e características distintas, influenciando diretamente na

forma como a rede neural se adapta ao contexto em que está inserida, resultando em erros maiores ou menores nas previsões realizadas.

2.2.4. Aprendizado e validação

Uma vez definidas a topologia e as funções de ativação de uma rede neural, é necessário realizar o treinamento para que o modelo possa aprender a partir dos dados de entrada. Portanto, o treinamento é um dos processos fundamentais que compõem a construção de uma rede específica para um determinado problema.

Para isso é necessário definir a forma como a máquina lidará com a base de dados, sendo que o processo de treinamento dependerá de vários fatores, como a qualidade e quantidade dos dados disponíveis, a escolha adequada dos algoritmos e a interpretação dos resultados obtidos (YANG et al. 2021).

Conforme debatido por Goodfellow et al. (2015), é possível destacar 3 modelos de aprendizado de máquina:

- **Aprendizado Supervisionado:** Algoritmo no qual o aprendizado é realizado com dados de entrada e saída, ou seja, a máquina aprende a partir de um resultado real obtido por um *supervisor*, sendo treinada de forma a tentar reconhecer os padrões existentes entre as entradas e saídas fornecidas;
- **Aprendizado não supervisionado:** Nesse modelo de aprendizado não existem rótulos disponíveis nos dados de treinamento, dessa forma a rede neural experimenta apenas as variáveis de entrada que não estão associadas a um rótulo ou valor específico. O objetivo é extrair informações e descobrir estruturas, padrões ou relações intrínsecas nos dados de entrada, sem que o *supervisor* forneça uma saída esperada;
- **Aprendizado por reforço:** No aprendizado por reforço, o modelo recebe estímulos na forma de recompensas ou punições com base em suas ações. Seu objetivo é aprender a tomar decisões que maximizem a recompensa ao longo do tempo, aprendendo a lidar com o ambiente que está inserido e suas regras.

O processo de validação é fundamental para medir o desempenho e a capacidade de generalização de uma rede neural e deve ser feito com dados não utilizados no treinamento, permitindo avaliar como o modelo irá se comportar em situações até então desconhecidas.

Uma técnica comumente utilizada no processo de validação consiste na divisão do conjunto de dados em porções utilizadas no treinamento, na validação e no teste, cujas proporções recomendadas variam para cada autor.

Por fim, Cepowski (2020) destaca que uma métrica utilizada na avaliação do desempenho de uma rede considerando o conjunto de dados não utilizado no treinamento, normalmente é baseada em uma abordagem estatística, onde o erro quadrático médio (EQM) é calculado a partir da Equação 3:

$$EQM = \frac{\sum(X_{atual} - X_{estimado})^2}{n} \quad (3)$$

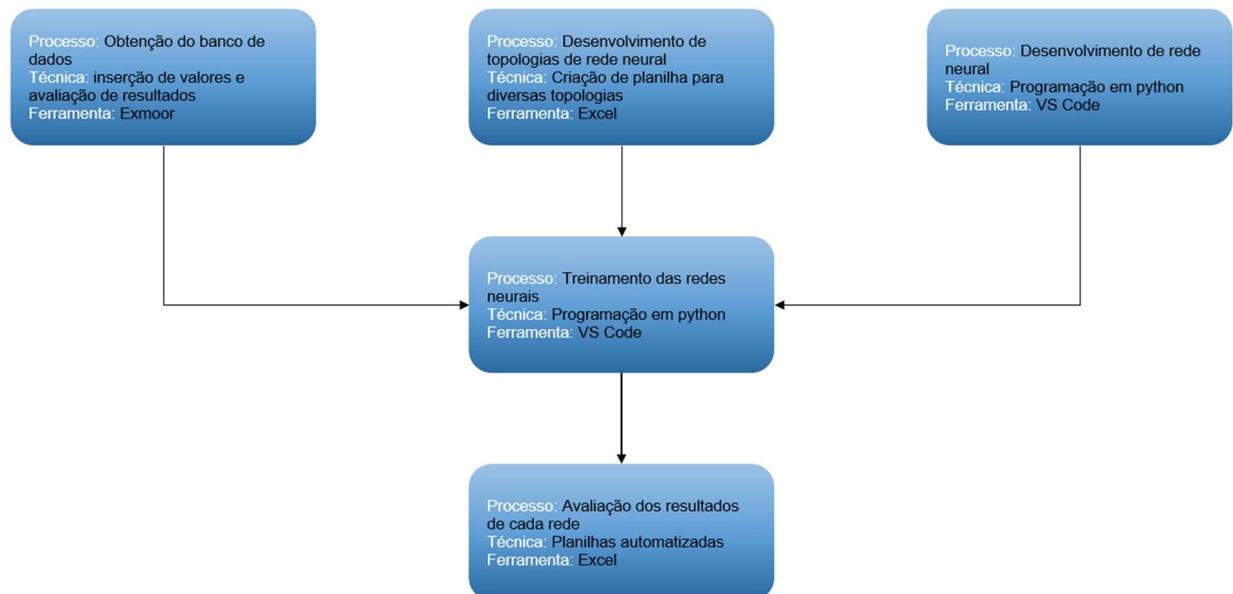
Onde:

- X_{atual} é o valor de referência;
- $X_{estimado}$ é a estimativa obtida através da rede neural treinada;
- n é o número de termos.

3. METODOLOGIA

Este capítulo tem como objetivo apresentar a metodologia adotada na execução deste trabalho, contemplando os processos, técnicas e ferramentas (Figura 8) relevantes para o desenvolvimento, treinamento e validação de redes neurais artificiais desenvolvidas para estimar o raio de ancoragem de uma linha de ancoragem constituída de três segmentos heterogêneos.

Figura 9 - Metodologia



Fonte: Autor (2024)

Seguindo a metodologia proposta, o primeiro passo consiste na criação de uma tabela contendo os dados que serão utilizados para o treinamento da rede neural. Nessa etapa é de suma importância garantir a precisão e confiabilidade dos dados que serão utilizados no aprendizado da rede neural.

Como trata-se de uma rede neural com treinamento supervisionado, o banco de dados, elaborado com auxílio da ferramenta Exmoor, deve conter tanto as variáveis de entrada, quanto os respectivos resultados obtidos na análise de cada caso.

Para o desenvolvimento deste trabalho, foi criado um banco de dados contendo um total de 879 combinações, explorando uma grande variabilidade das

variáveis de entrada, possibilitando um estudo aprofundado e a verificação do potencial das redes neurais artificiais na modelagem de problemas de ancoragem.

Paralelamente ao desenvolvimento do banco de dados que será usado no treinamento, teste e validação dos modelos, foi criada a planilha que auxiliará no estudo referente a topologia da rede. Ao todo foram escolhidas 50 topologias de rede que serão devidamente apresentadas na seção 4 desta dissertação.

A programação necessária para a leitura do banco de dados, construção da topologia e execução do treinamento de cada uma das redes estudadas, bem como os processos de validação, teste e geração dos resultados foi desenvolvida utilizando a linguagem Python, por meio da ferramenta VS Code.

Conforme discutido por Spiliopoulos e Yu (2023), antes de serem utilizados, os dados brutos extraídos do Exmoor precisam ser tratados. Neste trabalho, optou-se por normalizar cada uma das variáveis de entrada utilizando-se a Equação 4.

$$X_{normalizado} = \frac{X_{atual} - X_m}{X_{dp}} \quad (4)$$

Onde:

- X_m é a média de cada uma das características;
- X_{dp} é o desvio padrão amostral da mesma variável.

Em relação a topologia da rede, essa será constituída de sete neurônios na camada de entrada, responsáveis por receber cada uma das variáveis do banco dados e um neurônio na camada de saída. Tanto as descrições das variáveis de entrada quanto da variável de saída são apresentadas no capítulo 4 desta monografia.

No âmbito do tratamento dos dados e desenvolvimento das redes neurais, foram utilizadas as bibliotecas Pandas e TensorFlow, ambas amplamente conhecidas e utilizadas para o desenvolvimento de redes neurais.

Finalizada a construção e o treinamento da rede neural, a etapa seguinte consiste na validação, onde a precisão da rede será avaliada. Nessa etapa os resultados previstos pela rede neural são confrontados com aqueles obtidos no programa Exmoor, considerando cada um dos casos do banco de dados separados para a validação, os quais não foram utilizados no treinamento da rede.

Durante o treinamento da rede, o conjunto de dados utilizado é separado em pacotes, chamados batches, onde cada batch contém amostras do conjunto de treinamento. Essa abordagem permite calcular o erro da rede para cada batch e então realizar a correção dos pesos utilizando o algoritmo *backpropagation*. Além disso, segundo Bishop (2008), a utilização de batches contribui para a redução do consumo de memória do computador durante o processo de treinamento.

4. DESENVOLVIMENTO

Nesta seção são descritos o processo de desenvolvimento das redes neurais estudadas, bem como os resultados obtidos. Além disso, também são abordados em detalhes os processos e ferramentas mencionados no capítulo 3.

4.1. APLICAÇÃO DA REDE NEURAL

Primeiramente, faz-se necessário contextualizar o leitor acerca do ambiente para o qual as redes neurais foram desenvolvidas, bem como suas aplicações e limitações.

As redes neurais desenvolvidas neste projeto têm como premissa o fundeio de uma unidade flutuante genérica, realizado com uma única linha de ancoragem constituída de três segmentos: um trecho superior feito de corrente, um trecho médio feito de poliéster e, por fim, um novo trecho feito de corrente (Figura 9).

Figura 10 - Ilustração dos segmentos da linha de ancoragem



Fonte: Exmoor (2024)

Tal configuração foi escolhida pois, segundo Albrecht (2005), os segmentos iniciais e finais das linhas de ancoragem usualmente são constituídos por amarras

devido a capacidade desse material de resistir tanto ao contato constante das linhas com os guinchos, quanto também ao atrito da amarra com o leito marinho.

Por fim, é importante descrever as condições ambientais estabelecidas para este estudo. Nesse sentido, não foram consideradas ações de ondas, ventos e/ou correntes marinhas. Além disso, a profundidade na qual a unidade flutuante está ancorada é de 1000 metros, enquanto o comprimento total das linhas estudadas é de 1500 metros.

4.1.1. Seleção das variáveis de entrada

Nesta seção são discutidas as variáveis utilizadas na construção e treinamento das redes neurais estudadas.

Em se tratando de redes neurais com aprendizado supervisionado, é necessário estabelecer um parâmetro a ser utilizado como resultado a ser previsto. Neste projeto, o parâmetro escolhido para ser estimado pela rede neural é o raio de ancoragem da linha, o qual é definido como a distância do fair lead até o ponto de toque da linha com o solo.

Como discutido na seção 4.2, o peso molhado de cada segmento da linha de ancoragem foi estudado e avaliado como uma das características fundamentais que influenciam o raio de ancoragem de uma unidade flutuante, exercendo papel fundamental para o aprendizado de padrões e a construção de relações complexas entre as variáveis de entrada.

Conforme já mencionado, as linhas de ancoragem estudadas neste trabalho são constituídas por três segmentos compostos por materiais heterogêneos, cada qual com o seu próprio comprimento e peso molhado. A partir dessa premissa, cada segmento introduz ao modelo duas variáveis a serem utilizadas no treinamento das redes neurais estudadas: o comprimento percentual do segmento e o peso linear molhado do material.

Por fim, é necessário observar que a tração no topo está intrinsecamente ligada a geometria da catenária e, portanto, ao raio de ancoragem da linha. Devido à ausência de esforços ambientais, a tração exercida no topo de uma linha de ancoragem pode ser decomposta em uma componente vertical, a qual corresponderá ao peso molhado do trecho suspenso da linha e a componente horizontal, a qual decorre da rigidez geométrica da catenária.

É possível entender a componente horizontal da tração existente em uma linha de ancoragem como sendo a força que surge no sentido de mover a plataforma em direção ao ponto de ancoragem.

Logo, a tração no topo, juntamente com o comprimento relativo de cada segmento e seus respectivos pesos lineares molhados, tornam-se peças-chaves do modelo, estando diretamente correlacionados com o raio de ancoragem. Portanto, as sete variáveis de entrada utilizadas neste trabalho são:

- Tração no topo;
- Comprimento relativo segmento 1;
- Peso molhado segmento 1;
- Comprimento relativo segmento 2;
- Peso molhado segmento 2;
- Comprimento relativo segmento 3;
- Peso molhado segmento 3.

A partir da camada de entrada, a informação será transmitida através das camadas ocultas, chegando à camada de saída da rede, a qual é composta por um único neurônio, cuja saída refere-se ao raio de ancoragem da linha.

4.2. DESENVOLVIMENTO DO BANCO DE DADOS

Para a construção do banco de dados utilizado neste projeto, a ferramenta utilizada foi o programa Exmoor, cedido pela Petrobrás e desenvolvido em parceria com a Universidade de São Paulo (USP).

Tendo em vista a problemática discutida até o presente momento, o banco de dados foi gerado de forma a suprir as informações necessárias para que a rede consiga interpretar e entender os padrões existentes nas variáveis de entrada escolhidas e estimar adequadamente o raio de ancoragem de uma linha composta por três segmentos heterogêneos.

Lembrando que o comprimento total da linha de ancoragem foi considerado constante, para o desenvolvimento do banco de dados foram selecionados os pesos lineares molhados correspondentes a amarra do segmento superior, ao polyester do

segmento intermediário e a amarra do segmento inferior, obtidos do catálogo de materiais homologados pela Petrobrás, existente no programa Exmoor.

Para cada arranjo de materiais e seus respectivos pesos submersos, variou-se o comprimento do segmento de polyester entre 40% e 70% do comprimento total da linha, considerando intervalos de 10%. O comprimento restante foi então dividido entre o segmento inicial e o segmento final da linha, seguindo as três diferentes porcentagens enumeradas na Tabela 1.

Tabela 1 - Divisão do comprimento restante para as amarras

SEGMENTO INICIAL	SEGMENTO FINAL
1/2	1/2
1/3	2/3
2/3	1/3

Fonte: Autor (2024)

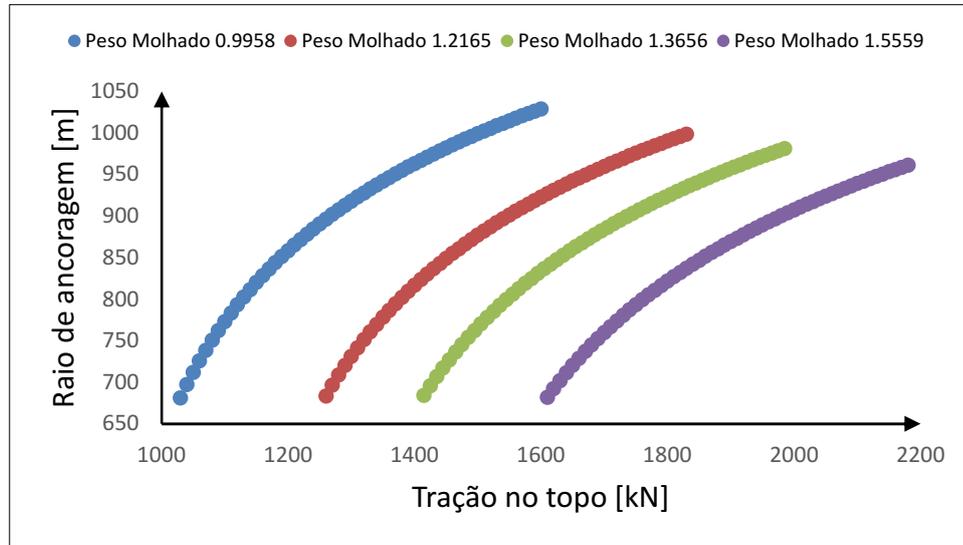
Portanto, para cada combinação de pesos molhados definida para os segmentos, foram consideradas 4 variações de comprimentos do segmento de polyester, cada qual contendo 3 variações entre o comprimento do segmento inicial e final, totalizando 12 configurações.

Por fim, para cada configuração geométrica adotada para a linha de ancoragem, foram considerados diferentes valores de tração, variando de 200 kN até o valor máximo de 3580 kN.

Com isso, foi gerado um banco de dados contendo 879 casos de fundeio, decorrentes da variação sistemática do peso molhado e do comprimento relativo dos segmentos, além da variação da tração no topo da linha. No Apêndice A é apresentada uma amostra do banco de dados construído nessa etapa do trabalho.

De forma a facilitar o entendimento do leitor acerca do banco de dados gerado, primeiramente será apresentado na Figura 10 uma versão simplificada, contendo apenas 4 configurações de linha de ancoragem, feitas de material homogêneo e com comprimentos iguais, variando apenas o peso molhado das linhas.

Figura 11 - Modelo simplificado



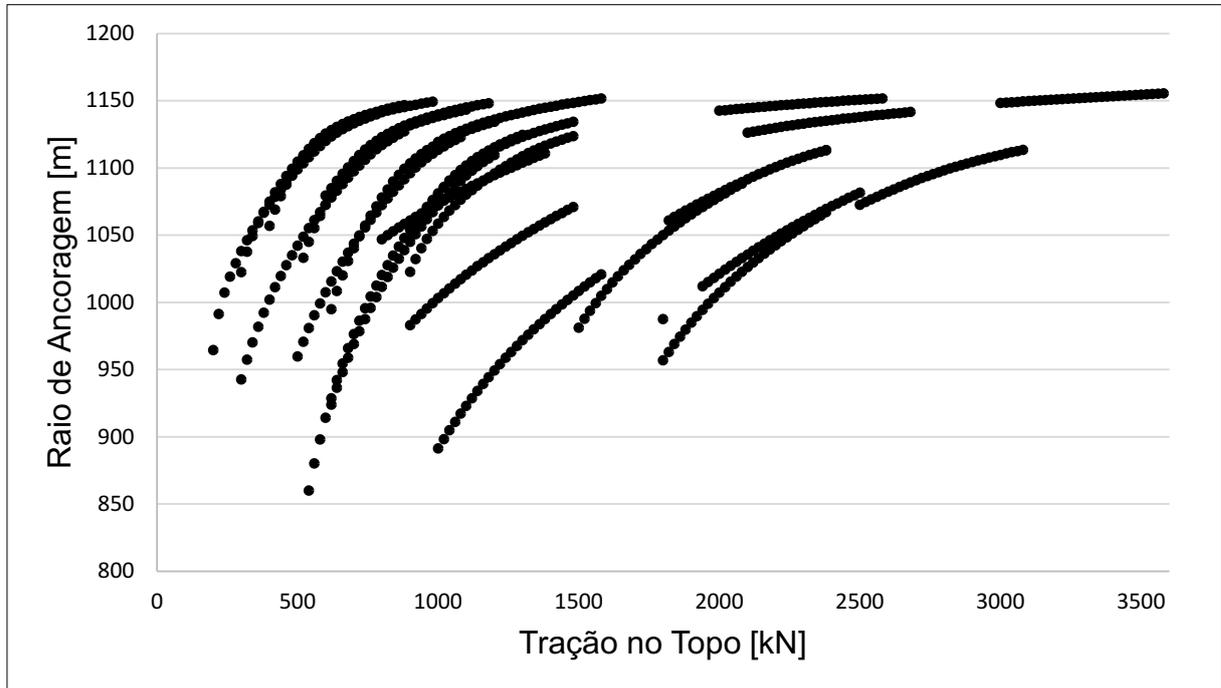
Fonte: Autor (2024)

É importante notar que cada peso molhado considerado, dado em kN/m, resulta em uma forma completamente diferente quando comparada à outras linhas de ancoragem. Assim, é possível concluir que o peso molhado de cada segmento é uma das principais características que influenciam o raio de ancoragem e, portanto, devem fazer parte das variáveis de entrada da rede neural.

Conforme já mencionado, o banco de dados construído para esse projeto utilizando o Exmoor contém 879 casos, dos quais 149 configurações de linha foram separadas antes do treinamento.

Na Figura 11 são plotados os 730 casos utilizados no treinamento, onde o eixo horizontal representa a tração no topo, enquanto o eixo vertical corresponde ao raio de ancoragem. Por fim, cada curva representada na figura refere-se a uma mesma configuração geométrica, onde os pontos diferem devido ao valor da tração aplicada no topo da linha.

Figura 12 - Variação do raio de ancoragem em função da tração no topo



Fonte: Autor (2024)

4.3. TOPOLOGIA

Para a determinação da topologia das redes neurais estudadas, foi desenvolvida uma tabela Excel, a qual é lida pelo algoritmo de treinamento escrito em Python. Nessa tabela são definidos: o número de identificação do modelo, o número de camadas ocultas da rede, o número de neurônios em cada camada oculta e o número de épocas de treinamento da rede. Assim, cada linha da Tabela 2 representa um modelo de rede neural estudado neste trabalho.

Tabela 2 - Topologias de rede

Modelo	Camadas Ocultas	Neurônios	Épocas
1	4	8	100000
2	4	16	100000
3	4	32	100000
4	4	64	100000
5	4	128	100000
6	6	8	100000
7	6	16	100000
8	6	32	100000
9	6	64	100000
10	6	128	100000

11	8	8	100000
12	8	16	100000
13	8	32	100000
14	8	64	100000
15	8	128	100000
16	10	8	100000
17	10	16	100000
18	10	32	100000
19	10	64	100000
20	10	128	100000
21	12	8	100000
22	12	16	100000
23	12	32	100000
24	12	64	100000
25	12	128	100000
26	16	8	100000
27	16	16	100000
28	16	32	100000
29	16	64	100000
30	16	128	100000
31	18	8	100000
32	18	16	100000
33	18	32	100000
34	18	64	100000
35	18	128	100000
36	20	8	100000
37	20	16	100000
38	20	32	100000
39	20	64	100000
40	20	128	100000
41	22	8	100000
42	22	16	100000
43	22	32	100000
44	22	64	100000
45	22	128	100000
46	24	8	100000
47	24	16	100000
48	24	32	100000
49	24	64	100000
50	24	128	100000

Fonte: Autor (2024)

Observando a Tabela 2, é possível constatar que foi realizada uma variação sistemática do número de camadas ocultas e da quantidade de neurônios em cada camada. Dessa forma, este estudo abrangeu 50 topologias diferentes, buscando encontrar a topologia com melhor desempenho.

Ainda relacionado a topologia das redes, estudos preliminarmente mostraram que a função de ativação GELU possivelmente é aquela que melhor se adaptou ao problema modelado, quando comparada com as funções ReLU, Swish e Softplus

Diante desses resultados, este trabalho considerou apenas a função de ativação GELU em todas as topologias estudadas.

4.4. TREINAMENTO

Nesta seção será discutido a forma como foi conduzido o treinamento de cada uma das redes neurais estudadas, incluindo os parâmetros necessários para a execução dessa tarefa.

Para a etapa de treinamento, o banco de dados foi embaralhado de forma aleatória e dividido em um conjunto de treinamento e um conjunto de teste, na proporção de 80% para o conjunto de treinamento e 20% para o conjunto de teste.

O conjunto de treinamento, como o nome sugere, foi utilizado somente para o treinamento das redes neurais, enquanto o conjunto de teste é utilizado apenas para a avaliação das redes treinadas.

Em relação as épocas de treinamento enumeradas na Tabela 2, a cada época, o modelo é apresentado a todo o conjunto de treinamento. Portanto, quando o modelo é treinado por 100 épocas, isso quer dizer que todo o conjunto de treinamento foi utilizado 100 vezes.

Isso implica que, quanto mais o modelo é treinado com um determinado banco de dados, maior é a probabilidade dele se adaptar e reconhecer os padrões existentes naquele conjunto amostral.

Com isso, existe a possibilidade de o modelo apresentar um problema de *overtraining*. Nessa situação o modelo, ao ser apresentado repetidas vezes ao mesmo conjunto de treinamento, passa a memorizar os dados, apenas ligando diretamente uma entrada a uma saída, sem identificar os padrões ali presentes.

Dessa forma, um modelo com *overtraining* perde parte ou toda a capacidade de generalização do problema, funcionando unicamente para os casos presentes no conjunto de dados ao qual foi apresentado.

Para mitigar esse problema, é possível definir que, se o modelo não apresentar melhora no desempenho após 10 épocas seguidas, o treinamento pode ser encerrado antecipadamente, sem que todas as épocas tenham sido concluídas.

Segundo Bishop (2008), o critério de parada antecipada representa uma estratégia capaz de atenuar o fenômeno de overtraining, evitando que as redes percam a capacidade de generalização do problema.

Assim, é possível separar o treinamento das redes em duas abordagens. Na primeira, o treinamento só para quando o número de épocas definido é alcançado. Já na segunda, o treinamento é interrompido quando o critério de parada antecipada (*earlystopping*) é alcançado.

4.5. TESTE DE GENERALIZAÇÃO

Por fim, destaca-se que, para o teste de generalização das redes desenvolvidas, foi construído um banco de dados separado do conjunto de treinamento e teste, com linhas compostas de segmentos com pesos molhados diferentes de todas as linhas existentes no banco de dados original.

5. RESULTADOS

Nesta seção são apresentados os resultados do treinamento e das análises acerca da capacidade preditiva e de generalização das redes neurais estudadas. Neste sentido, os resultados são segmentados respeitando as duas abordagens de treinamento discutidas na seção 4.4. Na primeira, o treinamento prossegue até que o número de épocas alcance o limite estabelecido, enquanto na segunda, o treinamento prossegue até que o critério de parada antecipada seja alcançado.

É importante destacar que, os erros quadráticos médios (EQM) apresentados neste capítulo referem-se a média dos erros quadráticos calculados para cada um dos casos pertencentes ao conjunto de validação, ou seja, pertencentes aos 20% do banco de dados original que não foram utilizados no treinamento das redes neurais.

Já o termo erro quadrático, refere-se ao quadrado da diferença entre a previsão obtida com uma determinada rede neural e o respectivo resultado obtido utilizando o programa Exmoor,

5.1. TREINAMENTO SEM CRITÉRIO DE PARADA ANTECIPADA

Para o treinamento sem critério de parada antecipada, foram separados os dados de 5 topologias de redes neurais para serem analisados. Os resultados referentes a cada topologia estudada, juntamente com seu respectivo número de épocas de treinamento, são listados na Tabela 3.

Tabela 3 - Topologias de rede neural sem earlystopping

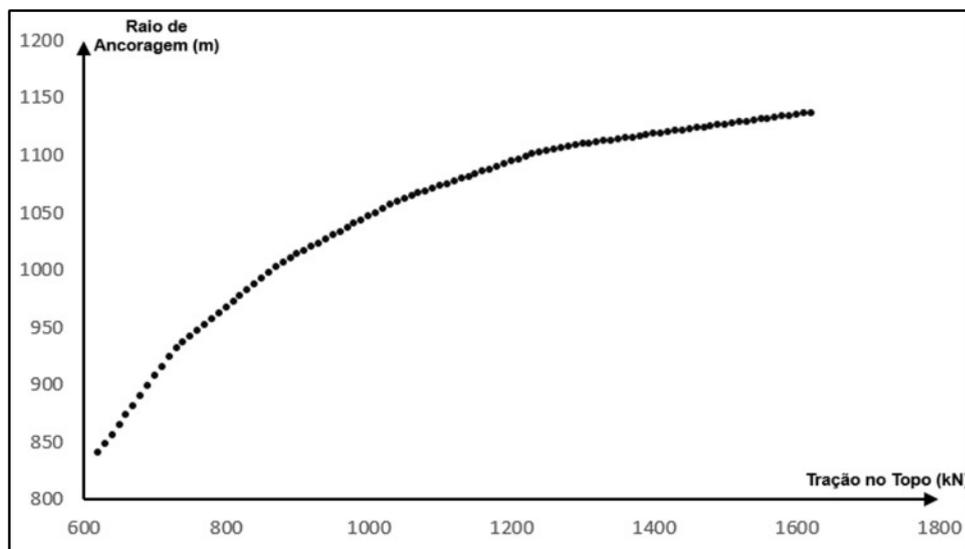
Modelo	Camadas Ocultas	Neurônios	Épocas	EQM
1	5	64	100000	0,098
2	6	64	100000	4,867
3	4	128	100000	0,394
4	5	128	100000	0,089
5	6	128	100000	0,535

Fonte: Autor (2024)

Em relação a separação do banco de dados entre conjunto de treinamento e conjunto de validação, é importante observar a natureza dos dados usados no aprendizado da rede neural e como o modelo aprende a partir deles.

Por exemplo, considerando uma linha de ancoragem genérica composta de 3 segmentos, cada um com seu devido comprimento relativo e respectivo peso molhado, a variação do raio de ancoragem em função da tração no topo da linha é mostrada na Figura 12.

Figura 13 - Linha de ancoragem exemplo



Fonte: Autor (2024)

Assim, se o banco de dados for composto unicamente pelos pontos mostrados na Figura 12, durante a construção da rede neural, esses dados serão embaralhados e separados em um conjunto de treinamento e em um conjunto de validação.

Nesse caso, nota-se que, mesmo havendo a separação dos dados em dois conjuntos, os pontos utilizados no conjunto de validação são similares aos pontos utilizados no treinamento, permitindo que a rede generalize o problema com bastante precisão, estimando corretamente o valor para casos não utilizados no treinamento.

No entanto, quando a rede neural tenta prever os resultados para uma linha cuja configuração geométrica não participou do conjunto de treinamento, a tendência é que os resultados se afastem consideravelmente da realidade.

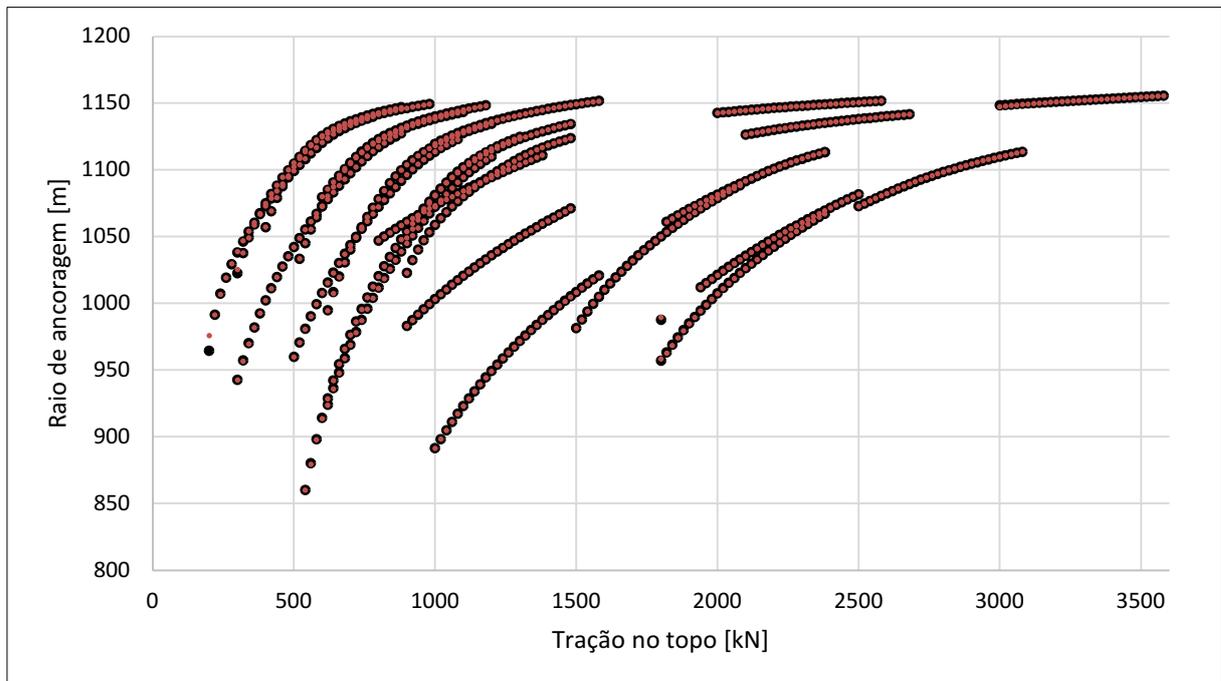
Logo, a avaliação do erro quadrático médio de uma rede neural mede a capacidade do modelo de reconhecer os padrões existentes, ou seja, a capacidade de interpolar corretamente o comportamento dentro de um banco de dados conhecido.

Já a capacidade de generalização da rede está ligada a capacidade do modelo de prever o comportamento para casos originalmente não existentes no banco de dados.

Neste projeto, a capacidade de generalização da rede avaliou a aptidão do modelo para generalizar os padrões de aprendizado e as complexas relações entre as variáveis de entrada e de saída para configurações geométricas de linhas de ancoragem que não foram utilizadas na etapa de treinamento.

Dessa forma, ao avaliar os valores de EQM mostrados na Tabela 4 para as redes neurais onde não havia o parâmetro de parada prévia, é possível observar uma ótima adequação do modelo ao conjunto de treinamento, tal como pode ser visto na Figura 13.

Figura 14 - Predições com linhas que fizeram parte do treinamento



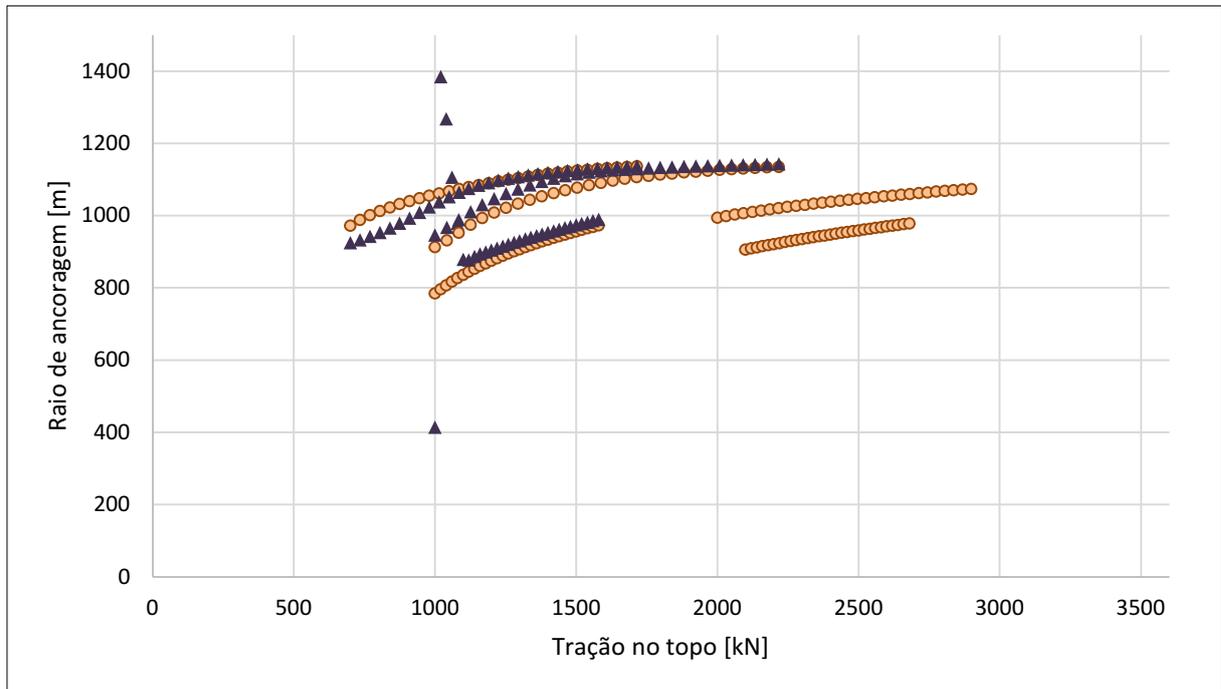
Fonte: Autor (2024)

Onde:

- Pontos em preto são resultados considerados reais obtidos através do Exmoor;
- Pontos em vermelho são resultados da previsão da rede neural dado os mesmos dados de entrada.

Entretanto, quando o desempenho do modelo é avaliado considerando-se linhas de ancoragem para as quais a rede não sofreu exposição prévia, observam-se desvios inaceitáveis que, inclusive, fogem da escala do gráfico, tal como pode ser visto na Figura 14.

Figura 15 - Predições com linhas não utilizadas no treinamento



Fonte: Autor (2024)

Onde:

- Pontos em amarelo representam os resultados obtidos no Exmoor;
- Triângulos em roxo indicam os resultados obtidos usando a rede neural treinada considerando os mesmos dados de entrada.

O modelo neural cujos resultados foram mostrados nas Figuras 13 e 14 é o modelo 4 apresentado na Tabela 3, o qual possui 5 camadas ocultas, 128 neurônios em cada camada e que foi treinado por 100.000 épocas.

É importante salientar que, as linhas de ancoragem analisadas na Figura 14 têm características geométricas distintas daquelas existentes no banco de dados construído e que foi dividido em conjunto de treinamento e de validação. Portanto, os valores referentes as variáveis de entrada extrapolam os intervalos do banco de dados, visando desafiar a capacidade preditiva das redes.

Nota-se que, apesar dessa rede neural apresentar um EQM de 0,089 (Tabela 4), ou seja, possuir uma alta precisão e confiabilidade de predição para as linhas que participaram do treinamento, quando confrontada com valores de entrada de linhas de ancoragem que não participaram do treinamento, sua capacidade de generalizar os padrões mostrou-se comprometida, revelando eventuais problemas de *overtraining*.

5.2. TREINAMENTO COM CRITÉRIO DE PARADA PRÉVIA

Diferentemente da abordagem anterior, nessa abordagem todos os modelos foram treinados considerando a existência de um critério de parada prévia (*earlystopping*), o qual interrompe o treinamento se o desempenho da rede não melhorar ao longo de 10 épocas seguidas.

Devido ao critério de parada, nenhum dos 50 modelos treinados concluiu as 100.000 épocas de treinamento, tendo seu processo de treinamento interrompido prematuramente. Na Tabela 5 são apresentadas as topologias e os resultados referentes ao treinamento, considerando a existência do critério de parada antecipada, de cada uma das topologias estudadas.

Tabela 4 - Topologias e épocas de treinamento praticadas

Modelo	Camadas Ocultas	Neurônios	Épocas	EQM
1	4	8	213	5.351
2	4	16	111	3.110
3	4	32	79	3.244
4	4	64	103	3.864
5	4	128	95	7.052
6	6	8	133	9.477
7	6	16	125	13.098
8	6	32	43	6.561
9	6	64	51	3.326
10	6	128	40	9.392
11	8	8	108	8.508
12	8	16	50	7.994
13	8	32	75	2.910
14	8	64	37	3.915
15	8	128	43	4.926
16	10	8	49	17.355

17	10	16	93	4.812
18	10	32	74	5.071
19	10	64	40	5.206
20	10	128	50	2.933
21	12	8	82	6.606
22	12	16	87	2.616
23	12	32	66	4.151
24	12	64	69	5.305
25	12	128	51	7.977
26	16	8	140	8.927
27	16	16	65	9.595
28	16	32	73	4.990
29	16	64	43	3.826
30	16	128	30	17.955
31	18	8	101	3.274
32	18	16	83	5.606
33	18	32	67	7.682
34	18	64	31	3.166
35	18	128	48	6.848
36	20	8	94	2.472
37	20	16	96	4.358
38	20	32	46	3.575
39	20	64	36	6.968
40	20	128	31	14.482
41	22	8	59	3.791
42	22	16	49	6.444
43	22	32	33	5.042
44	22	64	31	9.058
45	22	128	52	11.484
46	24	8	65	6.573
47	24	16	64	5.713
48	24	32	38	4.963
49	24	64	23	7.528
50	24	128	33	7.329

Fonte: Autor (2024)

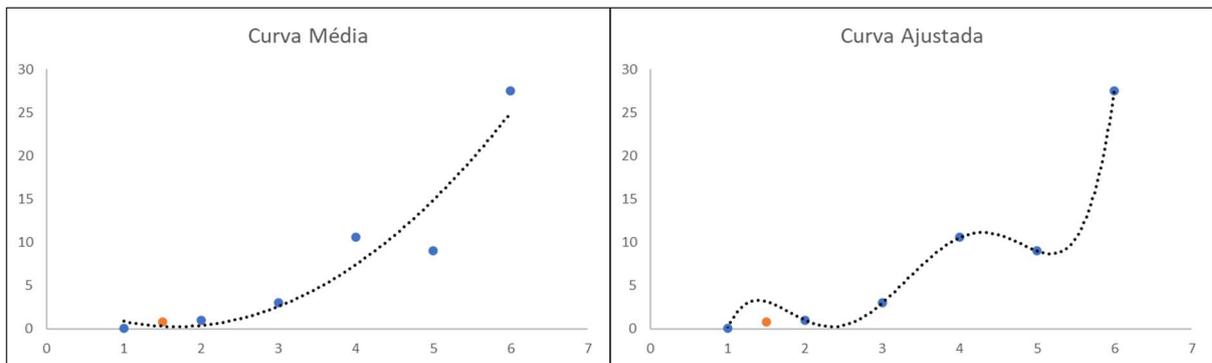
Em relação ao EQM obtido no treinamento das redes sem critério de parada prévia, é possível observar um aumento dos valores de erro para os modelos com *earlystopping* (Tabelas 4 e 5).

Tal fato deve-se à diminuição no número de épocas de treinamento efetivamente realizadas, pois, dessa forma, a rede realizou um menor número de ajustes para identificar os padrões e estabelecer as conexões apropriadas. No entanto, espera-se que essas redes apresentem uma maior capacidade de generalização do problema, em virtude da redução do fenômeno de *overtraining*.

O compromisso entre a precisão na estimativa dos pontos utilizados no treinamento e o aumento da capacidade de generalização de um modelo, pode ser melhor compreendido observando-se a Figura 16. A esquerda tem-se uma “curva média” que tem um erro quadrático maior para os pontos utilizados no treinamento (azuis), ao passo que na direita tem-se uma “curva ajustada” que não possui erro quadrático em relação aos pontos utilizados no treinamento (azuis).

No entanto, quando ambos os modelos vistos na Figura 16 são apresentados a um novo ponto, não utilizado no treinamento (laranja), o modelo com melhor ajuste apresenta um erro maior do que o modelo de ajuste médio, justamente pela melhor capacidade de generalização desse modelo.

Figura 16 - Curvas de treinamento

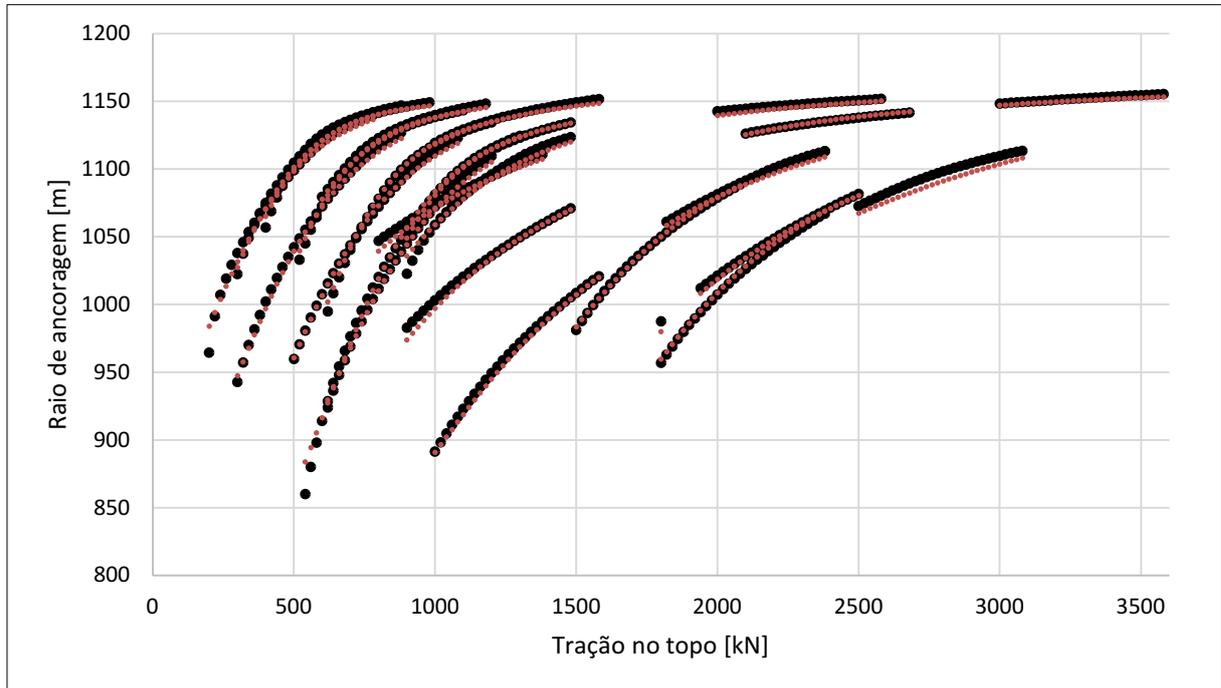


Fonte: Autor (2024)

Entre as 50 topologias apresentadas na Tabela 6, os modelos 15, 20, 25, 34 e 39 foram selecionados para um estudo aprofundado por apresentarem melhores capacidades de generalização, tal como será discutido a seguir.

Para avaliar a capacidade de predição dos modelos selecionados, na Figura 15 é mostrada uma comparação entre os resultados previstos pelo modelo 25 e aqueles obtidos utilizando o programa Exmoor. Dado que, entre os 5 modelos selecionados, esse é aquele de maior EQM, é possível inferir que os demais casos apresentam um comportamento ainda mais aderente entre os resultados obtidos com a rede neural e os dados pertencentes ao conjunto de treinamento.

Figura 17 - Resultados para linhas de ancoragem conhecidas



Fonte: Autor (2024)

Onde:

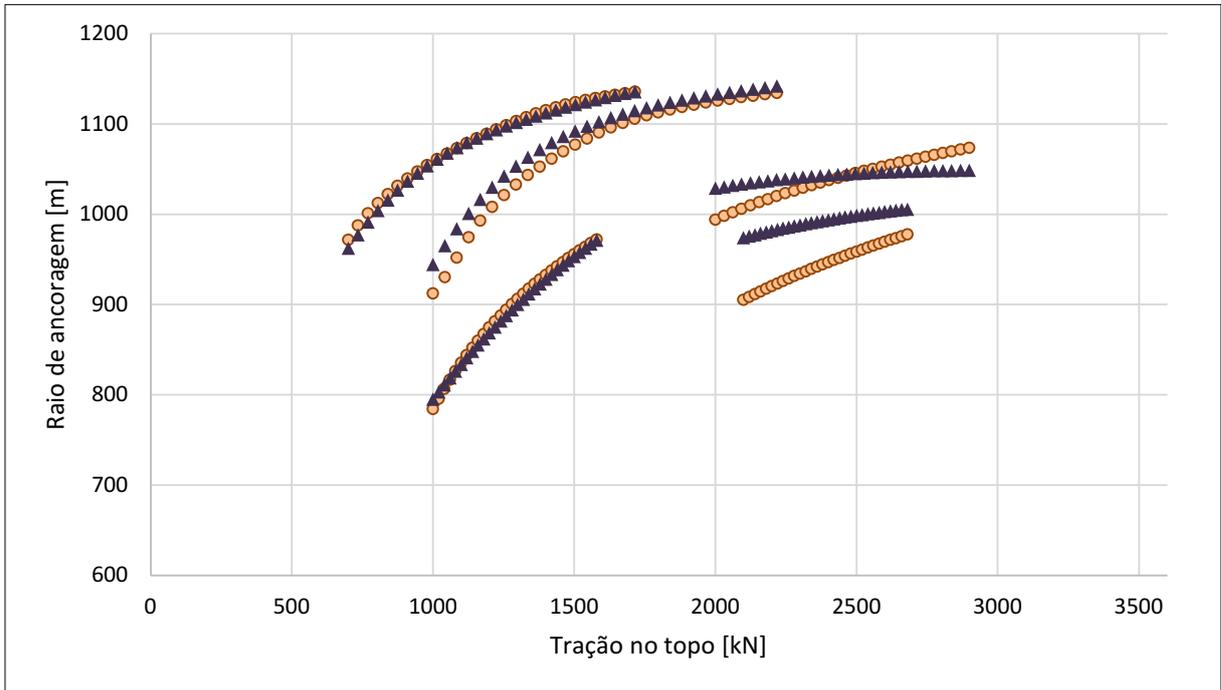
- Pontos pretos são os valores obtidos pelo Exmoor;
- Pontos vermelhos são os valores obtidos utilizando a rede neural treinada considerando os mesmos dados de entrada.

Nesse caso, é possível observar que alguns pontos se distanciam dos valores de referência mais do que quando foi utilizado o processo de treinamento sem a aplicação do critério de parada antecipada (Figura 13).

Tal fato também é facilmente constatado observando que o maior valor do EQM foi de 4,86 para o treinamento sem o critério de parada prévia e de 17,9 com a aplicação do critério de parada prévia. Apesar disso, o maior erro absoluto para esses dados foi de 23,9 metros, o que representa 1,59% do comprimento da linha de ancoragem.

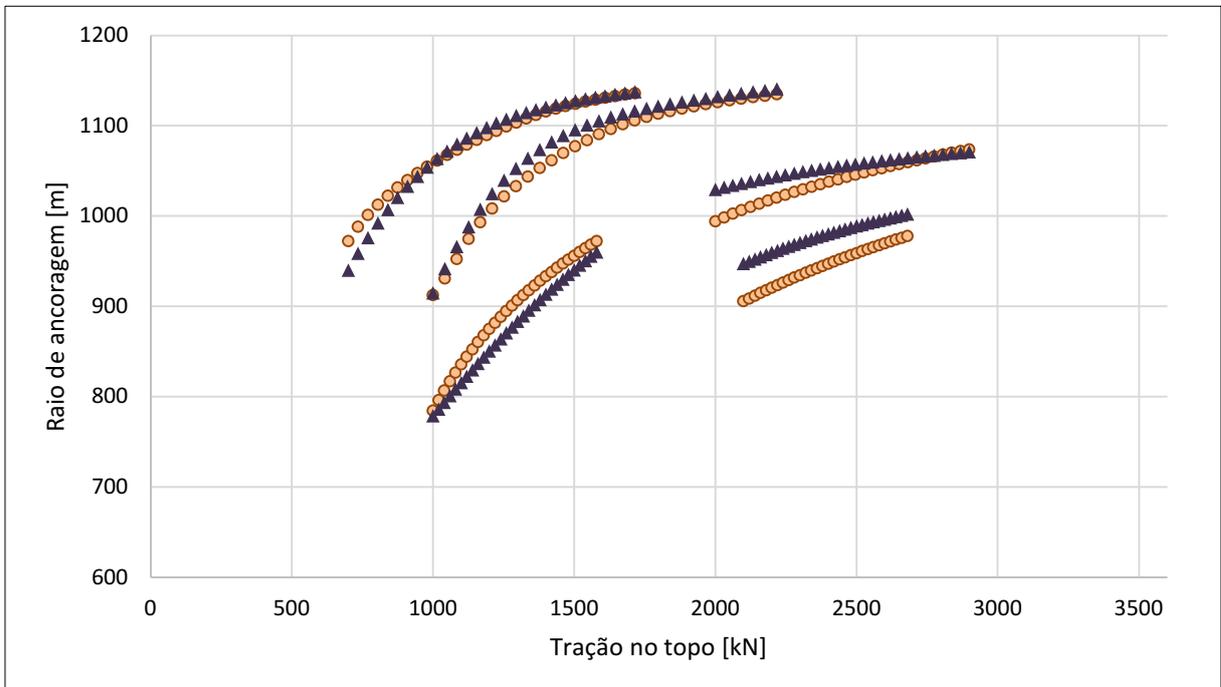
Já para a avaliação da capacidade de generalização dos modelos, foram utilizadas as mesmas linhas estudadas na verificação da capacidade de generalização das redes treinadas sem o critério de parada, ou seja, configurações de linhas completamente novas e que não foram utilizadas no treinamento. Os resultados obtidos nessa etapa são apresentados nas Figuras 16, 17, 18, 19 e 20.

Figura 18 - Resultado modelo 15 (linhas não utilizadas no treinamento)



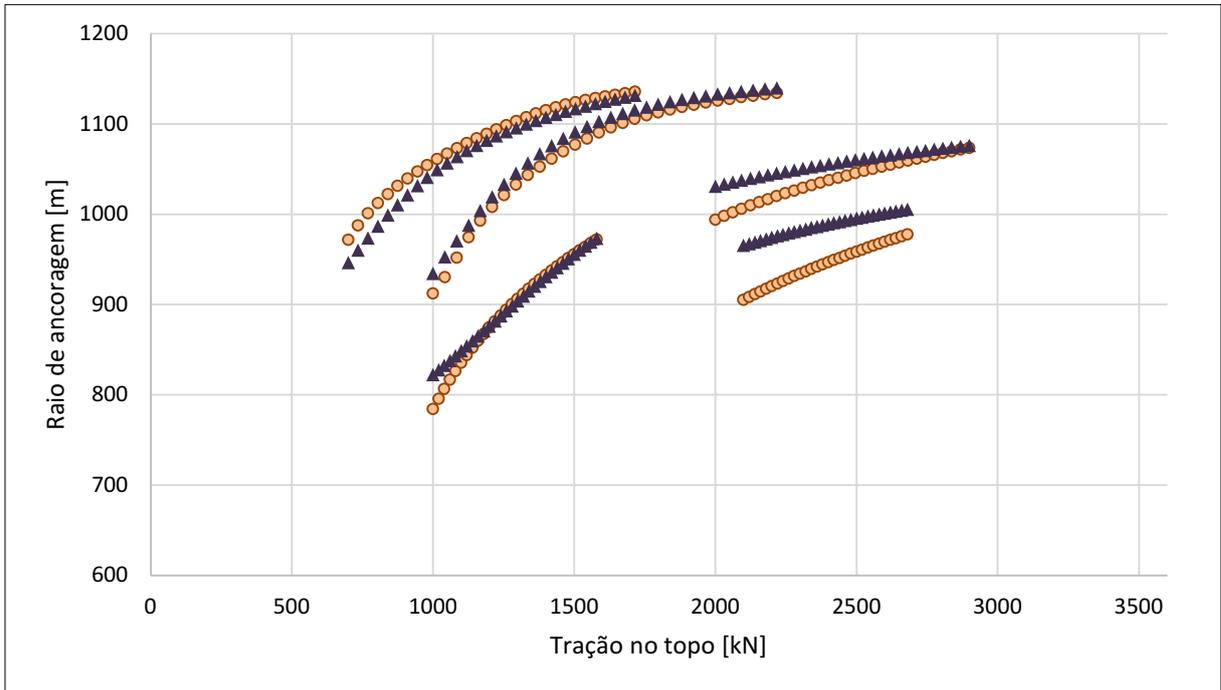
Fonte: Autor (2024)

Figura 19 - Resultado modelo 20 (linhas não utilizadas no treinamento)



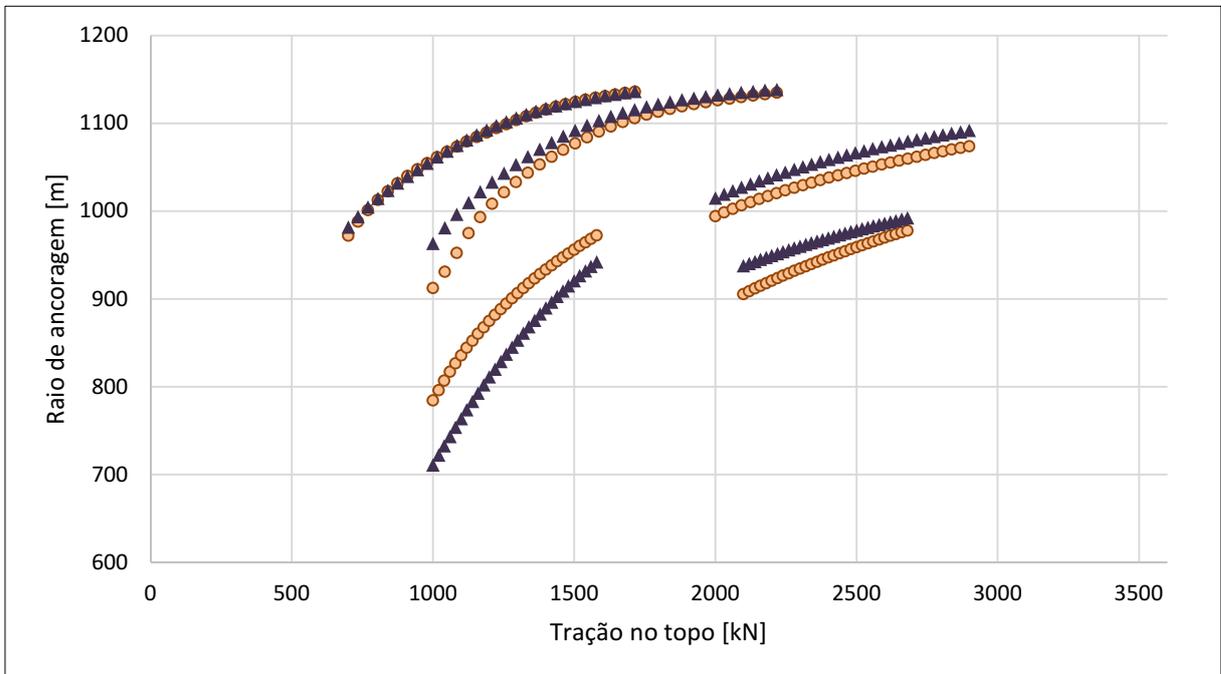
Fonte: Autor (2024)

Figura 20 - Resultado modelo 25 (linhas não utilizadas no treinamento)



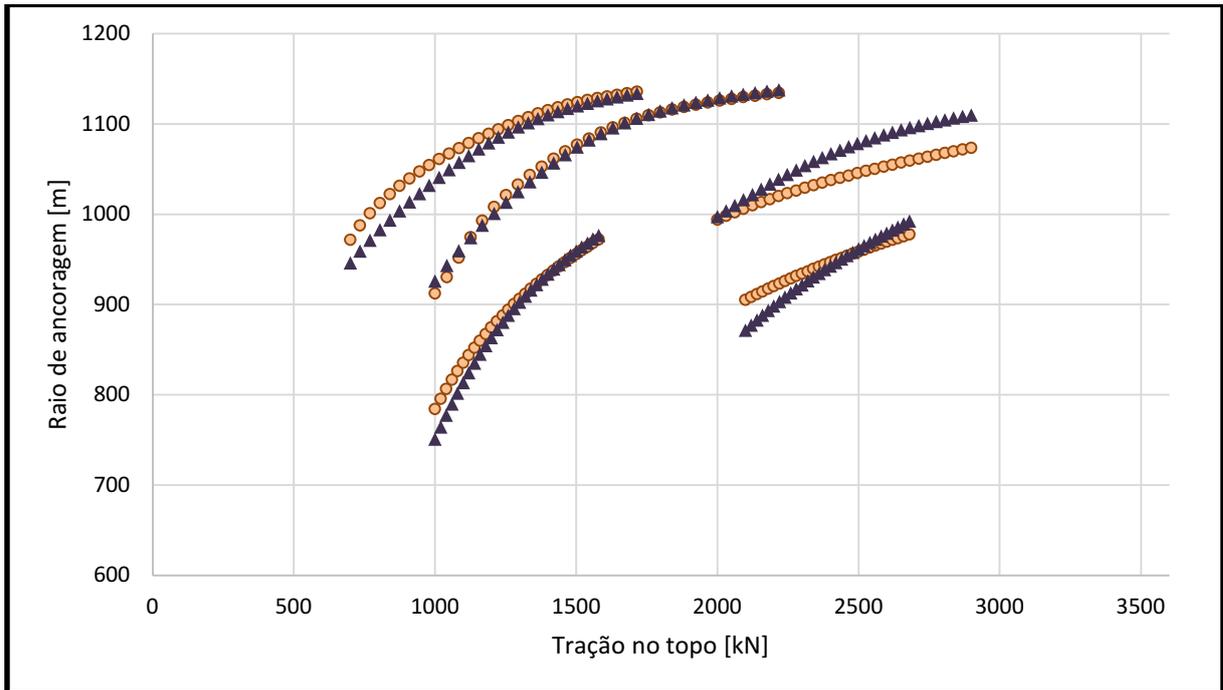
Fonte: Autor (2024)

Figura 21 - Resultado modelo 34 (linhas não utilizadas no treinamento)



Fonte: Autor (2024)

Figura 22 - Resultado modelo 39 (linhas não utilizadas no treinamento)



Fonte: Autor (2024)

Onde:

- Pontos em amarelo representam os resultados obtidos no Exmoor;
- Triângulos roxos representam os resultados obtidos utilizando as redes neurais treinadas considerando os mesmos dados de entrada.

Por fim, na Tabela 8 são sintetizados os principais resultados referentes aos 5 modelos escolhidos para o estudo de generalização.

Tabela 5 - Síntese dos resultados

Modelo	Maior erro abs. [m]	Maior erro abs. relativo * [%]	Erro médio [m]	Erro médio relativo ** [%]
15	68,98	4,59	17,10	1.14%
20	41,83	2,78	17,40	1.16%
25	60,33	4,02	18,20	1.21%
34	74,06	4,93	23,07	1.54%
39	37,07	2,47	13,43	0.90%

* Relação entre o maior erro absoluto e o comprimento total da linha (1500 metros).

** Relação entre erro médio e o comprimento total da linha (1500 metros).

Fonte: Autor (2024)

Logo, é possível analisar que, apesar de haver um aumento do erro quadrático médio para o conjunto de treinamento, a introdução do critério de parada antecipada resultou em modelos neurais com predições cujos erros foram inferiores a 2% do comprimento da linha de ancoragem.

Já em relação ao estudo de generalização, os modelos sem o critério de parada antecipada mostraram-se incapazes de generalizar os padrões aprendidos durante o treinamento, restringindo sua performance apenas para configurações de linhas de ancoragem similares aquelas presentes no conjunto de treinamento.

Por outro lado, os modelos nos quais o critério de parada antecipada foi aplicado apresentaram resultados completamente diferentes, sendo mais aptos para estimar o raio de ancoragem de linhas de ancoragem com configurações geométricas diferentes daquelas utilizadas na fase de treinamento.

Além disso, o custo computacional para o treinamento de redes neurais com a aplicação do critério de parada antecipada foi consideravelmente menor do que o treinamento de redes sem a aplicação desse critério.

Com isso, entende-se que a aplicação de um critério de parada antecipada é uma prática recomendada para atenuar a possibilidade de *overtraining*, mantendo a capacidade do modelo para generalizar o problema de forma satisfatória, mesmo no caso de linhas cujas geometrias não foram utilizadas no treinamento.

Por fim, é importante ressaltar que, como mostrado na seção 4.2, o peso molhado é uma característica que afeta diretamente o comportamento de uma linha de ancoragem, levando a mudanças bruscas no raio de ancoragem, mesmo que os valores das demais variáveis sejam mantidos.

6. CONCLUSÃO

Neste trabalho, foi apresentado o processo de desenvolvimento e avaliação de 55 topologias de redes neurais utilizadas na modelagem de um mesmo problema, cujo treinamento foi separado em redes com e sem critério de parada antecipada.

As premissas utilizadas consideram a análise de uma única linha de ancoragem composta por 3 segmentos heterogêneos. Todas as linhas estudadas são compostas por um segmento superior constituído de amarras, um segmento central de polyester e um segmento inferior também constituído de amarras. Além disso, o comprimento total da linha, somados os 3 segmentos, é de 1500 metros. Por fim, a profundidade da lâmina d'água escolhida para o estudo é de 1000 metros.

Ao todo foram considerados 7 parâmetros de entrada para o modelo: o peso linear molhado e o comprimento relativo de cada segmento, bem como a tração no topo da linha, os quais foram variados sistematicamente a fim de produzir um banco de dados a ser utilizado no treinamento e na validação das redes neurais estudadas. Já o parâmetro a ser previsto pelas redes neurais foi o raio de ancoragem da linha, o qual foi calculado numericamente usando o programa Exmoor.

Por fim, a partir de um banco de dados contendo 730 combinações, foram treinadas 55 topologias de redes usando duas abordagens de treinamento. A partir dos resultados obtidos, foram discutidas a capacidade de generalização, a eficiência computacional e a precisão dos resultados obtidos para cada modelo estudado, comparando-os com outras 149 combinações que não estiveram presentes no treinamento.

Conclui-se que este trabalho alcançou os objetivos propostos e representa mais um passo em direção ao uso da inteligência artificial para o projeto integrado de sistemas offshore.

6.1. TRABALHOS FUTUROS

Durante este trabalho, mostrou-se de grande valor a realização de testes considerando diferentes funções de ativação, os quais foram realizados buscando uma melhor adequação do modelo neural ao problema estudado. Assim, como trabalho futuro, sugere-se entender o motivo da melhor adequação de cada função de

ativação no contexto da problemática tratada neste trabalho, tornando essa escolha ainda mais assertiva.

A partir dos resultados obtidos, para evitar os problemas de generalização observados, entende-se que o próximo passo seja a realização de uma expansão significativa do banco de dados, abrangendo um número maior de configurações de linhas de ancoragem, tornando a rede, a um só tempo, mais precisa e flexível, podendo ser utilizada nos mais diferentes problemas de ancoragem.

REFERÊNCIAS

- ALBRECHT, C. H. **Algoritmos evolutivos aplicados à síntese e otimização de sistemas de ancoragem**. 2005. Tese (Doutorado em Engenharia Oceânica) – Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.
- ANDRADE, B. L. R.; BRINATI, H. L.; MORISHITA, H. M. **Sistema de ancoragem e posicionamento**: v. 1. 1995. Monografia (Especialização em Engenharia Naval e Oceânica) – Escola Politécnica, Universidade de São Paulo, São Paulo, 1995.
- ASSIS, J. **Sistemas de ancoragem de plataformas**: Manuseio de âncoras em águas profundas. 2013. Monografia (Aperfeiçoamento para oficiais de náutica da marinha mercante) — Centro de Instrução Almirante Graça Aranha, Rio de Janeiro. 2013.
- BISHOP, C.M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.
- CEPOWSKI, T. The prediction of ship added resistance at the preliminary design stage by the use of an artificial neural network. **Ocean Engineering**, v. 195, n. 106657, 2020.
- EMPRESA DE PESQUISA ENERGÉTICA. **Matriz energética e elétrica**. Brasília, 2022. Disponível em: <https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>. Acesso em: 15 maio 2023.
- ETESCO. **Extração de petróleo**: Como é feito esse processo?. São Paulo, 2021. Disponível em: <https://etesco.com.br/extracao-de-petroleo-como-e-feito-esse-processo>. Acesso em: 20 maio 2023.
- FERREIRA, F. M. G. **Otimização de Sistema de Ancoragem Equivalente em Profundidade Truncada**. 2016. Tese (Doutorado em Engenharia Civil) – Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco, Recife. 2016.
- GAY NETO, A. **Estabilidade estrutural da configuração estática de risers em catenária**. 2012. Tese (Doutorado em engenharia de controle e automação mecânica) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2012.
- GOODFELLOW I.; BENGIO Y.; COURVILLE A. **Deep learning**. 2016. Massachusetts: MIT press. 2016
- JACOVAZZO, B. M. **Comparação entre sistemas de ancoragem “Taut-Leg” e convencional para unidades flutuantes ancoradas na exploração de petróleo offshore**. 2006. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.
- KLIPPEL, P. **Estudo paramétrico do sistema de ancoragem de uma plataforma FPSO**. 2022. Trabalho de Conclusão de Curso (Graduação em Engenharia Naval) – Centro Tecnológico de Joinville, Universidade Federal de Santa Catarina, Joinville, 2022.
- LEAL, G. S. **Avaliação de metodologia de projeto de sistemas de ancoragem de plataformas flutuantes em relação à fadiga**. 2016. Dissertação (Mestrado em

Engenharia Oceânica) – Instituto Alberto Luiz Coimbra, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2016.

MCCOLLOCH, W.S; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biology, Vol.5, 1943

MEDEIROS, A. R. **Ancoragem e fundação offshore**. 2009. 74 f. Dissertação (Mestrado) – Instituto Alberto Luiz Coimbra, Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.

NAZÁRIO, V. C. **Modelagem de sistemas de ancoragem utilizando catenária inelástica**. 2015. 73 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Naval) – Centro Tecnológico de Joinville, Universidade Federal de Santa Catarina, Joinville, 2015.

NIELSEN, M. **Neural Networks and Deep Learning**. 2015. Disponível em: <https://static.latexstudio.net/article/2018/0912/neuralnetworksanddeeplearning.pdf>. Acesso em: 10 jun. 2023.

PEIXOTO, R. H. **Estudo da tecnologia e processos de extração em poços de petróleo**. 2014. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Guaratinguetá, 2014.

PETROBRAS. **Pré-Sal**. Rio de Janeiro, 2022. Disponível em: <https://petrobras.com.br/pt/nossas-atividades/areas-de-atuacao/exploracao-e-producao-de-petroleo-e-gas/pre-sal>. Acesso em: 20 jun 2023.

ROLFSEN, J.; HAUGEN, S.; EEN, V.; THORSEN, H.; SELJELID, J.; STEIRO, T.; VINNEM, E.; ANTORSEN, S. **Causal relationships and measures associated with structural and maritime incidents on the Norwegian Continental Shelf**. Petroleum Safety Authority Norway, Noruega, 2013.

RUMELHART, D.; HINTON, G.; WILLIAMS, R. **Learning representations by back-propagation errors**. Nature, Vol. 323, pp. 533–536, 1986.

TALAVERA, L. M. B. **Parábola e Catenária: História e Aplicações**. 2008. 96 f. Dissertação (Mestrado em matemática) – Escola politécnica, Universidade de São Paulo, São Paulo, 2008.

TANCREDI, T. P. **Otimização multidisciplinar distribuída aplicada a projetos de engenharia**. 2008. Tese (Doutorado em Engenharia Naval e Oceânica) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2008.

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

YANG, Y. et al. Research on accurate prediction of the container ship resistance by rbfnn and other machine learning algorithms. **Journal of Marine Science and Engineering**, v. 9, n. 4, p. 376, 2021.

YU, J.; SPILIOPOULOS, K. **Normalization effects on deep neural networks**. 2023. V. 5. Departamento de Matemática e Estatística, Universidade de Boston, Boston, EUA.

APÊNDICE A – Banco de dados

Tabela 6 - Amostra do banco de dados

Top traction	Anchor radius	Length 1	Water Weight1	Length n1	Length 2	Water Weight2	Length n2	Length 3	Water Weight3	Length n3
540	860.17	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
560	880.32	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
580	898.21	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
600	914.30	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
620	928.91	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
640	942.27	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
660	954.58	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
680	965.98	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
700	976.58	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
720	986.48	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
740	995.76	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
760	1004.49	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
780	1012.72	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
800	1020.52	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
820	1027.92	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
840	1034.95	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
860	1041.65	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
880	1048.04	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
900	1054.16	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
920	1060.03	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
940	1065.65	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
960	1071.06	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
980	1076.26	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
1000	1081.27	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
1020	1086.11	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
1040	1090.71	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
1060	1094.86	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
1080	1098.63	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3
1100	1102.06	450	0.9958	0.3	600	0.0315	0.4	450	0.9958	0.3

Fonte: Autor (2024)