

ANÁLISE ESTÁTICA DE LINHAS DE ANCORAGEM UTILIZANDO REDES NEURAIS ARTIFICIAIS

Heidi Maria Pastor de Andrade, UFAL, heidimpa@gmail.com
Michele Agra de Lemos Martins, UFAL, micheleagra@lccv.ufal.br
Eduardo Nobre Lages, UFAL, enl@lccv.ufal.br

Resumo: A exploração de petróleo e gás natural teve início com a perfuração de poços em terra. Com o avanço tecnológico, essa exploração tornou-se possível também em campos marítimos, em águas profundas e ultraprofundas, onde grandes reservas foram descobertas. Nesse cenário de exploração em meio oceânico, os deslocamentos das plataformas flutuantes são minimizados através do uso de sistemas de ancoragem eficientes, capazes de resistir às tensões provenientes das movimentações da plataforma. Nesse contexto, este trabalho apresenta um estudo voltado à análise estática de linhas de ancoragem em configuração de catenária simples. Com o intuito de alcançar maior eficiência na análise desse sistema, apresentam-se o estudo e a aplicação da metodologia de Redes Neurais Artificiais (RNA) na análise e predição da resposta estática das linhas de ancoragem. A tração e a inclinação no topo da linha são analisadas em função do comprimento e da projeção horizontal da estrutura. O uso de RNA proporciona maior eficiência às simulações por sua capacidade de aprendizado, generalização, associação e busca paralela. Nos estudos realizados, a rede apresenta valores estritamente próximos aos resultados da simulação através do Método dos Elementos Finitos. Sendo assim, pode-se afirmar que a rede é capaz de prever tração e inclinação no topo da linha de ancoragem em catenária com precisão e eficiência.

Palavras-chave: Análise estrutural; Redes Neurais Artificiais; sistemas *offshore*; linhas de ancoragem.

STATIC ANALYSIS OF MOORING LINES USING ARTIFICIAL NEURAL NETWORKS

Abstract: Oil and natural gas exploration has begun with onshore wells drilling. Due to the improvement of technological resources, nowadays this exploration can also be done offshore, in deep and ultra-deep waters, where huge oil and gas reserves were found. At offshore exploitation, mooring systems are used in order to keep the floating platform movements within limits. Such systems are able to withstand the tensions imposed by the platform movement. On that context, this work focuses on the static analysis of catenary moorings. In order to achieve greater efficiency in the analysis of this system, this paper presents the study and implementation of Artificial Neural Networks (ANN) to analyze and predict the static response of the mooring lines. The tension and the angle at the top of the line are analyzed as a function of the line length and its horizontal projection. The use of ANN provides greater efficiency to the analysis due to its capability of machine learning, pattern recognition, adaptation, generalization and data organization. Results show that the obtained network provides line responses very close to those obtained by Finite Element Method simulation. Thus, it is observed that the ANN is able to predict the tension effort and the top angle of the catenary mooring line in static analysis precisely and efficiently.

Keywords: Structural analysis; Artificial Neural Network; offshore systems; mooring lines.

1. INTRODUÇÃO

O petróleo é a fonte de energia mais utilizada do planeta. Com a contínua exploração desse hidrocarboneto, ocorreu uma diminuição significativa das reservas em terra e em lâminas d'água rasas. Com isso, a busca e exploração de reservas em águas profundas e ultraprofundas se tornaram imprescindíveis.

A exploração de petróleo *offshore* é realizada em diversos locais do mundo, como no Brasil, no Golfo do México, nos Estados Unidos, na costa Oeste da África, no Mar do Norte e, até mesmo, no Ártico. Essa forma de exploração requer o uso de estruturas submersas diferenciadas, capazes de manter a estabilidade da plataforma petrolífera mesmo diante de condições ambientais adversas.

As primeiras explorações de petróleo no solo marinho foram realizadas com plataformas fixas, cujas estruturas de sustentação eram construídas em concreto armado ou em ligas metálicas. Entretanto, à medida que a profundidade de exploração aumentou, surgiu a necessidade do uso de estruturas de ancoragem complacentes.

Os sistemas de ancoragem complacentes são amplamente utilizados para a estabilização de plataformas em águas profundas e ultraprofundas. Essa estabilização ocorre por meio de linhas de ancoragem e âncoras ou estacas que transferem os esforços que agem sobre a plataforma para o solo marinho. As linhas de ancoragem podem ser utilizadas em diversas configurações; uma das configurações geométricas tradicionais das linhas de ancoragem é a catenária simples, mostrada na Figura 1.




Figura 1 – Representação de uma linha de ancoragem em catenária simples.

A simulação e análise estrutural dos sistemas de ancoragem são indispensáveis para entender o comportamento dos mesmos quando submetidos a condições ambientais características da região. Atualmente, essa análise é feita utilizando-se programas computacionais, usualmente baseados no Método dos Elementos Finitos (MEF) (e.g. BATHE, 1996) como solução matemática para o problema.

O DOOLINES (*Dynamics Of Offshore Lines*) (SILVEIRA *et al.*, 2012) é um *framework* desenvolvido em linguagem orientada a objetos que permite a análise de linhas de ancoragem utilizando o tradicional MEF. Contudo, a busca atual de petróleo em águas cada vez mais profundas tem tornado a análise de estruturas *offshore*, tais como as linhas de ancoragem, cada vez mais caras do ponto de vista computacional (GUARIZE *et al.*, 2007)

Nesse contexto, a fim de otimizar o processo de análise, as Redes Neurais Artificiais (RNA) ganham especial atenção devido à sua capacidade de aprendizado, generalização, associação e busca paralela. É realizada, neste trabalho, a aplicação de RNA para predição do comportamento estrutural de linhas de ancoragem.

O emprego de inteligência computacional na análise de estruturas *offshore* ocorre com o intuito de complementar os métodos numéricos atualmente empregados para a análise estrutural de linhas de ancoragem, possibilitando assim que a simulação aconteça sem que seja necessário o uso de sistemas robustos que são muito custosos computacionalmente.

Existem na literatura vários trabalhos que aplicam redes neurais na análise de sistemas *offshore* visando diminuir o tempo de processamento. Vasconcelos (2013), por exemplo, aplica redes na análise do trecho enterrado da linha de ancoragem. Seus resultados foram similares aos obtidos por integração numérica e o tempo de processamento foi reduzido em 20%. Tiquilloca *et al.* (1999) propõem uma metodologia para a aplicação de redes na análise

do comportamento dinâmico de sistemas de produção flutuantes para evitar as dificuldades inerentes aos métodos matemáticos tradicionais.

Alguns trabalhos utilizam ainda redes neurais para melhorar o tempo de análise utilizando o MEF. Pina (2010), por exemplo, propôs a análise estática de linhas de ancoragem e *risers* com o uso de RNA e outras metodologias de análise. Guarize *et al.* (2007) analisaram um caso real de uma linha de ancoragem composta por trechos de amarras e de cabo de poliéster, investigando a aplicabilidade de redes neurais na análise dinâmica dessas estruturas. Andrade *et al.* (2014) aplicaram redes neurais para analisar uma linha de ancoragem homogênea em catenária simples com as extremidades fixas, sendo considerado apenas o aspecto da geometria da estrutura. Uddin *et al.* (2012) aplicaram redes na predição de resposta dinâmica de linhas de ancoragem de uma plataforma do tipo *spar*.

Esses estudos baseados em redes neurais apresentam resultados simples em relação à análise realizada pelo MEF, assim como utilizado pelo DOOLINES, por exemplo. Análises baseadas em elementos finitos são capazes de gerar um cenário de análise muito mais representativo, pois permitem que a modelagem da linha de ancoragem incorpore parâmetros físicos e geométricos, além de considerar adequadamente as ações ambientais, entre outras funcionalidades.

Entretanto, em situações nas quais não há disponibilidade de tempo para realizar uma análise completa via MEF, ou até mesmo em uma fase de pré-dimensionamento, é desejável um estudo que demande menos tempo, mesmo que seja menos representativo e preciso em alguns casos. Nessas situações, o uso de Redes Neurais Artificiais apresenta-se como uma ferramenta alternativa de análise, de modo a complementar os métodos de simulação numérica de estruturas *offshore* atualmente consagrados na literatura.

2. REDES NEURAIAS ARTIFICIAIS

As Redes Neurais Artificiais são sistemas inteligentes que utilizam arranjos de neurônios artificiais para tomar decisões. As redes têm capacidade de aprendizado, generalização, associação e busca paralela e podem ser aplicadas em problemas que envolvem reconhecimento de padrões, ajuste de função, categorização, entre outros (e.g. BRAGA *et al.*, 2007).

Os neurônios artificiais são formados por pesos e *bias*. Os pesos mensuram a importância de cada *input* tem sobre o resultado final, ou *output*, enquanto os *bias* indicam a tendência dos resultados. O *output* é então a interpretação da operação de vários neurônios associados. Com isso, a variação dos pesos e *bias* leva a diferentes modelos de decisão.

O ajuste dos pesos e *bias* é realizado pelo algoritmo de treinamento, que os calcula utilizando o histórico de erros e pesos das iterações anteriores. Ao longo do treinamento, os valores dos erros e pesos permitem a construção da função erro, a partir do erro quadrático médio entre valores de treinamento da rede e resultados gerados pela mesma, a qual é utilizada pelo algoritmo, que passa a buscar os pesos e *bias* que levem à minimização da função erro.

Em resumo, para o caso de ajuste de função, as redes utilizam pares de entrada e saída em seu aprendizado. Durante o aprendizado ou treinamento, a rede utiliza pesos sinápticos para calcular os *outputs* com base nos *inputs*. Em cada iteração do treinamento os pesos são ajustados para que os erros diminuam na próxima iteração, até que os resultados apresentem os erros desejados.

A qualidade dos resultados depende de diversos fatores, como a qualidade e quantidade de dados disponíveis, quantidade e arranjo de neurônios, algoritmo de treinamento, entre outros. Com isso, mesmo uma rede que já apresente bons resultados pode ser otimizada, através da escolha de um arranjo desses parâmetros que levem aos menores erros.

Christiansen *et al.* (2015), por exemplo, otimiza a estrutura de uma RNA desenvolvida para simular as forças em uma linha de ancoragem. Andrade *et al.* (2014) realizam o estudo do desempenho de uma rede neural que analisa o comportamento estático linhas de ancoragem ao modificar os parâmetros da rede. Esses trabalhos colocam em evidência a importância do estudo voltado à escolha dos parâmetros da rede neural.

3. MATERIAIS E MÉTODOS

Neste trabalho são utilizadas Redes Neurais Artificiais na análise estática estrutural de linhas de ancoragem em diferentes configurações. A rede utilizada tem como variáveis de projeto o comprimento e a projeção horizontal da linha de ancoragem, e, como parâmetros de resposta, a tração e o ângulo no topo da linha.

São avaliados dois cenários em que há atuação de correnteza. As linhas de ancoragem são homogêneas e estão em configuração de catenária simples. No primeiro cenário, a linha é composta pelo mesmo material ao longo de todo o seu comprimento. No segundo cenário, ilustrado na Figura 2, considera-se que a linha é composta por dois diferentes materiais, adequadamente dispostos ao longo do seu comprimento. O comprimento das linhas L vai do ponto de contato com a plataforma até o ponto de contato com o solo ou TDP.




Figura 2 – Descrição do cenário marinho considerando a linha composta por três trechos.

A rede neural é implementada utilizando o *software* MATLAB®, com auxílio do módulo computacional *Neural Network Toolbox* (BEALE *et al.*, 2015). A geração dos dados é realizada através do DOOLINES e do MATLAB®. São implementados algoritmos no MATLAB® que geram os dados de entrada nos intervalos pré-estabelecidos e que utilizam o DOOLINES para fazer os cálculos dos dados de saída.

A projeção horizontal (H) da linha assume 15 valores uniformemente distribuídos entre 1000 e 2000 m. Para cada H são gerados 10 valores do comprimento da linha (L), também uniformemente distribuídos, variando dentro do triângulo retângulo mostrado na Figura 3, no intervalo entre $1,1 \cdot \sqrt{LDA^2 + H^2}$ e $0,9 \cdot (LDA + H)$.




Figura 3 – Intervalo de variação do comprimento da linha L .

A quantidade de dados fornecidos à rede é escolhida de acordo com os estudos realizados em Andrade *et al.* (2014). As propriedades dos materiais das linhas de ancoragem são descritas na Tabela 1. Uma das linhas é composta por poliéster em todo o seu comprimento, e a outra é composta por poliéster em 90% de seu comprimento, e o restante é igualmente dividido em suas extremidades, as quais são compostas por cordoalha de aço.

Tabela 1 – Descrição das propriedades do material da linha.

Material	Poliéster	Aço
Diâmetro (m)	0,1	0,191
Peso no ar (N/m)	1,9389	2,0413
Peso submerso (N/m)	1,6822	1,7759
Rigidez axial (N)	151.574	766.000
Coefficiente de arrasto	3,2	3,2
Coefficiente de massa adicional	2,6	2,6

Fonte: Lacerda (2005)

A rede implementada resolve problemas do tipo ajuste de função, e recebe pares de dados de entrada e de saída em seu treinamento. Depois de treinada, a rede é capaz de resolver o problema para a qual foi desenvolvida, sendo fornecidos a ela apenas os dados de entrada ou *inputs*. Para cada caso avaliado, implementa-se uma rede, que tem seus parâmetros variados a fim de verificar aqueles que lhe conferem um melhor desempenho.

Primeiramente varia-se o algoritmo de treinamento e, em seguida, a quantidade e o arranjo de neurônios que compõe a rede. O comportamento da RNA também é avaliado em função da mudança da proporção utilizada na distribuição de dados em validação, treinamento e teste. Por fim, é verificada a *performance* da rede ao analisar uma variável *target* por treinamento, e as duas variáveis em um só treinamento, como é feito inicialmente.

São mantidos fixos, também, ao longo dos treinamentos, a divisão de dados e o algoritmo de treinamento. Estes, irão variar apenas nas análises da influência de cada um na *performance* da rede. Nas análises, são realizados cinco treinamentos por parâmetro avaliado, a fim de minimizar os efeitos da aleatoriedade do treinamento da rede. O desempenho das redes é avaliado de acordo com os erros relativos máximos, o tempo de treinamento e o tempo de resposta da rede após o treinamento.

4. RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados de treinamentos realizados a fim de verificar as melhores características da rede neural para cada caso. Em cada subseção são realizados treinamentos em diferentes algoritmos de treinamento, arranjo de neurônios, divisão de dados e quantidade de variáveis analisadas por vez. Ao final de cada subseção, é realizado um último treinamento com uma rede com as melhores características obtidas no estudo.

4.1 Estudo do comportamento das RNA's para a resolução do caso da linha homogênea

i. Algoritmo de treinamento

Os algoritmos de treinamento calculam os pesos sinápticos da rede em cada treinamento, de modo a minimizar a função erro, que consiste na diferença entre o resultado da rede e o resultado desejado. Inicialmente, o comportamento da rede é testado com a mudança do algoritmo de treinamento entre os algoritmos *Backpropagation* Levenberg-Marquardt, *Backpropagation* de gradiente decrescente e *Scaled Conjugate Gradient*. A Tabela 2 apresenta os resultados obtidos nos treinamentos.

O algoritmo *Backpropagation* Levenberg-Marquardt utiliza a matriz jacobiana da função erro para calcular os pesos sinápticos da iteração seguinte. Já o *Backpropagation* de gradiente decrescente recalcula os pesos de modo que haja a maior diminuição possível do erro na próxima iteração (NIELSEN, 2015). O *Scaled Conjugate Gradient* funciona de modo semelhante ao *Backpropagation* de gradiente decrescente, entretanto, para calcular o peso, ele leva em consideração também o comportamento da função erro nas regiões conjugadas (ADELI & HUNG, 1994).

Tabela 2 – Comparação dos resultados do treinamento utilizando os diferentes algoritmos.

Algoritmo	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
<i>Backpropagation</i> Levenberg-Marquardt	0,003852	0,000353	23,928466	0,028385
<i>Backpropagation</i> de gradiente decrescente	172,180001	12,554209	0,379441	0,017675
<i>Scaled Conjugate Gradient</i>	3,059332	3,059332	0,546602	0,019993

Os resultados obtidos utilizando o algoritmo de treinamento *Backpropagation* Levenberg-Marquardt apresentaram erros expressivamente menores do que os resultados referentes aos outros algoritmos. Embora os tempos de treinamento e de resposta tenham sido muito maiores nesse caso, o seu uso é justificado porque apenas ele apresentou erros dentro de limites aceitáveis.

ii. Quantidade e arranjo de neurônios

Também é observada a *performance* da rede ao utilizar diferentes arranjos de neurônios. A Tabela 3 descreve as quantidades de neurônios utilizadas em cada teste; os dois primeiros testes utilizaram apenas uma camada de neurônios e os outros testes utilizaram duas camadas, sendo informada a quantidade de neurônios da primeira e da segunda camada, nessa ordem. Nessa análise, a camada externa da rede é mantida inalterada, tendo sido variados apenas os neurônios das camadas intermediárias.

Tabela 3 – Resultados obtidos nos testes em que foi variado o número de neurônios.

Teste	Neurônios	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
1	5	0,002478	0,000196	17,822100	0,019774
2	10	0,023404	0,001601	10,611584	0,013472
3	5 e 5	0,010292	0,00082	15,756613	0,025687
4	10 e 10	0,002693	0,00032	27,80552	0,025840
5	5 e 10	0,002579	0,00021	29,960504	0,025130
6	10 e 5	0,005769	0,00102	25,098723	0,027190

Todos os erros encontrados estão dentro dos padrões aceitáveis, de modo que o melhor resultado escolhido foi o do teste 2 que apresentou o menor tempo de treinamento e de resposta.

iii. Distribuição de dados nos conjuntos de treinamento, validação e teste

É testado o comportamento da rede ao alterar a distribuição dos dados de treinamento entre os conjuntos de validação, treinamento e teste. Os conjuntos de validação e teste são mantidos com a mesma quantidade de dados, de modo que a distribuição dos dados varia conforme mostrado na Tabela 4.

Tabela 4 – Distribuição de dados em treinamento, validação e teste avaliados.

Análise	Treinamento (%)	Validação (%)	Teste (%)
1	60	20	20
2	70	15	15
3	80	10	10
4	90	5	5
5	100	0	0

A Tabela 5 mostra a média dos resultados obtidos ao treinar a rede variando a distribuição de dados.

Tabela 5 – Resultados obtidos nos testes em que foi variada a distribuição de dados.

Análise	Treinamento, validação e teste (%)	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
1	60, 20 e 20	0,015185	0,001674	17,877391	0,017645
2	70, 15 e 15	0,025083	0,001930	13,183498	0,018110
3	80, 10 e 10	0,022308	0,002126	13,683562	0,020456
4	90, 5 e 5	0,088603	0,013850	12,138129	0,019161
5	100, 0 e 0	0,037795	0,004895	14,220645	0,018843

Embora tenha o maior tempo de treinamento, a análise 1 apresentou os melhores resultados pois obteve o menor tempo de resposta e o menor erro em relação às duas variáveis avaliadas.

iv. Quantidade de variáveis *target* analisadas por vez

É avaliado o comportamento dos resultados da rede ao analisar as variáveis *target* em um único treinamento e em treinamentos separados. A Tabela 6 mostra os resultados do treinamento da rede analisando as duas variáveis no mesmo treinamento, e também a análise da tração de topo T e do ângulo de topo α individualmente.

Tabela 6 – Resultados da rede analisando uma ou as duas variáveis em cada treinamento

Variáveis	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
T e α	0,024522	0,002148	9,390842	0,019480
α	–	0,000076	9,004756	0,015964
T	0,000524	–	6,329721	0,017265

Os treinamentos em que as variáveis são analisadas individualmente apresentam erros substancialmente menores do que aqueles em que as duas variáveis *target* são analisadas ao mesmo tempo.

v. Treinamento da rede

Após os treinamentos experimentais, é realizado o treinamento da rede com as características que levaram a melhores resultados. Para o caso da linha homogênea, a rede é implementada utilizando o algoritmo *Backpropagation* Levenberg-Marquardt, com dez neurônios na camada intermediária, e com 60% dos dados utilizados para treinamento, 20% para validação e 20% para teste.

Nesse treinamento, as duas variáveis são estudadas ao mesmo tempo, pois os sucessivos treinamentos das redes são realizados a fim de obter o menor tempo de resposta, com o menor erro possível. As análises utilizando apenas uma variável *target* por vez levou a erros menores, entretanto só vale a pena ser feita a análise individual quando há necessidade de maior precisão nos resultados.

Tabela 7 – Resultados da rede obtida para a resolução do caso da linha homogênea.

Treinamento	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
1	0,025363	0,001304	9,646670	0,010216
2	0,003805	0,000294	13,679164	0,010643
3	0,004885	0,000391	13,876804	0,010876
4	0,010946	0,000882	13,899081	0,010379
5	0,072022	0,005134	1,956199	0,010655
Média	0,023404	0,001601	10,611584	0,013472

4.2 Estudo do comportamento das RNA's para o caso da linha com três trechos

São realizados os mesmos estudos expostos na Seção 3.1, porém para avaliar o comportamento das Redes Neurais Artificiais na resolução de um problema mais complexo, em que as extremidades da linha são compostas por cordoalha de aço, e o restante do comprimento da rede é de poliéster.

i. Algoritmo de treinamento

O desempenho da rede é avaliado com a mudança do algoritmo de treinamento, utilizando os mesmos algoritmos utilizados anteriormente. Os resultados obtidos com os diferentes algoritmos estão dispostos na Tabela 8.

Tabela 8 – Comparação dos resultados do treinamento utilizando os diferentes algoritmos.

Algoritmo	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
<i>Backpropagation</i> Levenberg-Marquardt	0,000650	0,000047	7,487685	0,016576
<i>Backpropagation</i> de gradiente decrescente	376,117757	15,726396	0,201406	0,016687
<i>Scaled Conjugate Gradient</i>	3,235644	0,261553	0,220432	0,016452

Os resultados da rede que utiliza o algoritmo de treinamento *Backpropagation* Levenberg-Marquardt apresentam erros nitidamente menores do que os resultados referentes aos outros algoritmos, assim como ocorreu para a rede treinada para a resolução do problema com uma linha homogênea. Os tempos de treinamento e de resposta também foram muito maiores utilizando esse algoritmo, entretanto, como apenas esse treinamento apresentou erros dentro de limites aceitáveis, seu uso é justificado.

ii. Quantidade e arranjo de neurônios

Os resultados obtidos nos treinamentos da rede com a quantidade e arranjo de neurônios variando estão sumarizados na Tabela 9.

Tabela 9 – Resultados obtidos nos testes em que foi variado o número de neurônios.

Teste	Neurônios	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
1	5	0,002264	0,000141	2,138940	0,015454
2	10	0,063326	0,004533	1,068093	0,015740
3	5 e 5	0,051048	0,005645	2,220247	0,016694
4	10 e 10	0,038879	0,003440	1,809093	0,015963
5	5 e 10	0,002432	0,000202	4,540334	0,016566
6	10 e 5	0,019053	0,000905	3,691086	0,016587

As análises realizadas nos testes 1 e 5 apresentaram erros menores do que as demais análises. Contudo, o teste 1 apresentou os menores erros e também o menor tempo de treinamento e de resposta. Com isso, o melhor resultado escolhido foi o do teste 1. Nota-se que a arquitetura escolhida para a rede, que foi uma camada intermediária composta por cinco neurônios, é diferente da apontada na análise realizada para a resolução do caso da linha homogênea, em que também foi empregada uma camada intermediária, mas com dez neurônios.

iii. Distribuição de dados nos conjuntos de treinamento, validação e teste

Os conjuntos de dados de treinamento, validação e teste têm seu tamanho variando de acordo com os valores mostrados na Tabela 4, apresentada na Seção 3.1. A Tabela 10 mostra a média dos resultados obtidos ao treinar a rede variando a distribuição de dados:

Tabela 10 – Resultados obtidos nos testes em que foi variada a distribuição de dados.

Análise	Treinamento, validação e teste (%)	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
1	60, 20 e 20	0,192320	0,011003	1,418650	0,015398
2	70, 15 e 15	0,026988	0,001863	1,880108	0,015559
3	80, 10 e 10	0,040565	0,002921	1,677579	0,015604
4	90, 5 e 5	0,124193	0,004285	0,854262	0,015473
5	100, 0 e 0	0,000097	0,000010	2,533455	0,015588

A análise 5, realizada com 100% dos dados no conjunto de treinamento, apresentou os melhores resultados em relação aos erros e aos tempos de treinamento e resposta. Entretanto, segundo Braga *et al.* (2007), as etapas de teste e validação são de suma importância para a garantia da qualidade dos resultados. Por isso optou-se por utilizar a divisão de dados da análise 2, que apresentou o segundo melhor resultado de erros percentuais.

iv. Quantidade de variáveis *target* analisadas por vez

A Tabela 11 dispõe os resultados do treinamento da rede avaliando as variáveis, T e α ao mesmo tempo no treinamento, e em treinamentos separados.

Tabela 11 – Resultados da rede analisando uma ou as duas variáveis em cada treinamento.

Variáveis	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
T e α	0,024522	0,002148	9,390842	0,019480
α	–	0,003312	0,366857	0,015405
T	0,007175	–	1,552807	0,017952

Os treinamentos em que foi feita a análise individual de cada variável *target* também apresentaram erros menores do que aqueles em que as variáveis foram analisadas ao mesmo tempo, com tempos de respostas próximos quando a análise era feita com uma ou com as duas variáveis *target*. Com isso, a análise das variáveis individualmente só vale a pena quando há necessidade de alta precisão de resposta.

v. Treinamento da rede

Para o caso da linha formada por três trechos de materiais distintos, a rede é implementada utilizando o algoritmo *Backpropagation* Levenberg-Marquardt, com cinco neurônios na camada intermediária, e com 70% dos dados utilizados para treinamento, 15% para validação e 15% para teste. As duas variáveis são estudadas ao mesmo tempo nesse treinamento.

Tabela 12 – Resultados da rede obtida para a resolução do caso da linha com três trechos.

Treinamento	Erro T (%)	Erro α (%)	Tempo de treinamento (s)	Tempo de resposta (s)
1	0,000895	0,000720	2,428191	0,015116
2	0,006185	0,006010	0,939489	0,015543
3	0,002475	0,002300	2,455358	0,015776
4	0,000574	0,000399	2,449397	0,015279
5	0,001118	0,000943	2,421566	0,015555
Média	0,002249	0,002074	2,138800	0,010554

4.3 Análise dos resultados

De acordo com os testes realizados, verifica-se que os parâmetros da rede que levam a resultados melhores são os mesmos apenas para o algoritmo de treinamento e para a quantidade de variáveis. Em ambos os casos apenas o algoritmo de treinamento *Backpropagation* Levenberg-Marquardt levou a erros aceitáveis.

A análise com uma variável por vez levou a erros aceitáveis, porém o tempo demandado é significativamente maior do que o necessário para a análise das duas variáveis no mesmo treinamento. Como os treinamentos das redes são realizados a fim de obter o menor tempo de resposta, a análise das duas variáveis foi realizada no mesmo treinamento.

A quantidade de neurônios e a distribuição de dados obtidos foram diferentes nos dois casos. Os melhores resultados do caso da linha homogênea foram obtidos nos treinamentos em que é utilizada uma rede com uma camada intermediária com 10 neurônios. Os melhores resultados em relação à divisão de dados ocorreram quando foram utilizados 60% dos dados para treinamento, 20% para validação e 20% para teste.

Os melhores resultados do caso da linha composta por três trechos foram aqueles cujo treinamento utilizou uma rede formada por uma camada intermediária com 5 neurônios e com uma divisão de dados com 70% dos dados para treinamento, 15% para validação e 15% para teste.

4.3.1 Qualidade dos resultados obtidos utilizando as redes neurais

A Tabela 13 contrasta o tempo médio de resposta da rede com o tempo médio de processamento demandado pelo DOOLINES para a resolução de um problema, e expõe os erros obtidos para as variáveis T e α . A comparação dos tempos de resposta é feita considerando os resultados das redes descritos na Tabela 11 e na Tabela 12.

Tabela 13 – Comparação dos resultados da rede com os resultados do DOOLINES.

Caso	Tempo DOOLINES (s)	Tempo RNA (s)	Erro T (%)	Erro α (%)
Trecho único	39,8017	0,013472	0,023404	0,001601
Três trechos	513,1571	0,010554	0,002249	0,002074

Em ambos os casos, o tempo médio de resposta da rede é substancialmente menor do que o tempo de processamento demandado pelo DOOLINES. Essa redução de tempo é obtida de modo que a qualidade dos resultados é mantida, pois os erros relativos máximos calculados são pouco significativos devido à sua ordem de grandeza.

5. CONCLUSÕES

Dada a grandeza dos erros obtidos nas análises realizadas, pode-se afirmar que a RNA é capaz de prever o comportamento da tração e da inclinação no topo de uma linha de ancoragem em catenária simples a partir dos valores do comprimento e da projeção horizontal da linha. O tempo de resposta da rede é inferior ao tempo demandado para uma simulação utilizando o DOOLINES, *framework* que utiliza o Método dos Elementos Finitos para análise de estruturas *offshore*. Entretanto, a análise realizada pela rede é restrita ao cenário do caso estudado e depende da análise com o MEF para que seja realizado o seu treinamento. O DOOLINES é capaz de fazer análises estáticas e dinâmicas para diversos tipos de linha de ancoragem, submetidas a carregamentos como correnteza e onda, fornecendo resultados mais completos. O fato de as redes neurais serem capazes de resolver o problema analisado

favorece o uso dessa ferramenta em análises mais complexas, que são muito mais custosas computacionalmente e demandam um elevado tempo de simulação.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal de Alagoas (UFAL), à Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), através do PRH40/UFAL, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelas concessões das bolsas de iniciação científica, de mestrado e de produtividade em pesquisa, respectivamente.

REFERÊNCIAS

ADELI, H.; HUNG, S. L. “Machine learning neural networks, genetic algorithms, and fuzzy systems”, John Wiley & Sons Inc, New York, NY USA, 1994.

ANDRADE, H. M. P.; MARTINS, M. A. L.; LAGES, E. N. “*Análise de Linhas de Ancoragem de Sistemas Offshore utilizando Redes Neurais Artificiais*”. XXXV Iberian Latin-American Congress on Computational Methods in Engineering, Fortaleza, Ceará, Brasil, 2014.

BATHE, K. J. M. “Finite Elements Procedures”. Nova Jersey: Prentice-Hall, 1996.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. “Neural network toolbox: MATLAB user’s guide”, The MathWorks, Inc., 2015.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. “Redes Neurais Artificiais – Teoria e Aplicações”, 2ª Edição, LTC, Rio de Janeiro, RJ, Brasil, 2007.

CHRISTIANSEN, N. H.; VOIE, P. E. T; WINTHER, O.; HØGSBERG, J. “Optimization of neural networks for time-domain simulation of mooring lines”. Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment, 2015.

GUARIZE, R.; MATOS, N. A. F.; SAGRILO, L. V. S.; LIMA, E. C. P. “Neural networks in the dynamic response analysis of slender marine structures”, Applied Ocean Research, v. 29, issue 4, p. 191-198, 2007.

LACERDA, T. A. G. “Análise de Sistemas de Ancoragem de Plataformas Flutuantes”, Trabalho Final de Curso, UFRJ, Rio de Janeiro, RJ, Brasil, Março de 2005.

NIELSEN, M. A. "Neural Networks and Deep Learning", Determination Press, 2015, disponível em: < <http://neuralnetworksanddeeplearning.com/chap1.html> > Acesso em julho de 2015.

PINA, A. A. “Metodologias de análise, síntese e otimização de sistemas para produção de petróleo *offshore* através de metamodelos e enxame de partículas”, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, Dezembro de 2010.

SILVEIRA, E. S. S.; LAGES, E. N.; FERREIRA, F. M. G. “DOOLINES: an object-oriented framework for non-linear static and dynamic analyses of offshore lines”. *Engineering with Computers*, v. 28, issue 2, p. 149-159, 2012.

TIQUILLOCA, J. L. M.; MORISHITA, H. M.; SIMÕES, M. G. “Análise dinâmica de sistemas de produção flutuantes de petróleo através de Redes Neurais Artificiais”. 4º SBAI - Simpósio Brasileiro de Automação Inteligente, São Paulo, SP, 08-10 de Setembro de 1999.

UDDIN, M. A.; JAMEEL, M.; RAZAK, H. A.; ISLAM, A. B. M. S. “Response Prediction of Offshore Floating Structure using Artificial Neural Network”. *Advanced Science Letters*, v. 14, p. 186-189, 2012.

VASCONCELOS, T. D. L., “Modelagem Computacional da Interação entre o Solo Marinho e a Linha de Ancoragem Enterrada”, Trabalho de Conclusão de Curso, UFAL, Maceió, AL, Brasil, Março de 2013.