

UTILIZAÇÃO DE REDE NEURAL ARTIFICIAL NA OBTENÇÃO DAS INFLUÊNCIAS PARA ACRÉSCIMOS DE TENSÃO VERTICAL NO SOLO DEVIDO A CARREGAMENTOS EXTERNOS

Luiz Alan Costa de Andrade¹

Marcos Antonio da Silva²

Resumo

O presente artigo mostra uma aplicação de uma ferramenta visando facilitar a resolução de problemas de engenharia civil, especificamente da obtenção da influência para acréscimos de tensão no solo devido a carregamentos externos sem o uso de ábacos, parâmetro muito importante na avaliação da estabilidade das obras de engenharia. Esta ferramenta chama-se Rede Neural Artificial (RNA) e foi criada devido o contraste entre o processamento do cérebro humano e os computadores. O objetivo da pesquisa é apresentar os resultados das análises de seis modelos que utilizaram essa ferramenta, mostrando que quando bem modelado existe uma rapidez na obtenção das influências, com erros aceitáveis (5,5%), e que quando modelados de forma inadequada podem gerar valores com erros de até 90% em relação ao valor do ábaco. A facilidade do uso da técnica e a rapidez no processamento resulta na melhor compreensão quando se tem um número grande de pontos no interior do maciço de solo onde deseja-se prever os valores das influências, devido a capacidade de processamento em lote da RNA.

Palavras-Chave: Ábacos. Predições das Influências. Mecânica dos Solos. Inteligência Computacional. Rede Neural Artificial.

¹Doutor em Engenharia Civil pela Universidade do Estado do Rio de Janeiro.

²Especialista em Engenharia Estrutural pelo UGB/FERP.

USE OF ARTIFICIAL NEURAL NETWORK TO OBTAIN INFLUENCES FOR INCREASED VERTICAL STRESS IN THE GROUND DUE TO EXTERNAL LOADS

Abstract

This article shows an application of a tool aimed at facilitating the resolution of civil engineering problems, specifically obtaining the influence for stress increases in the soil due to external loads without the use of abacuses, a very important parameter in the evaluation of the stability of construction works. engineering. This tool was created due to the contrast between the processing of the human brain and computers and is called Artificial Neural Network (ANN). Analysis results of six models that used this tool will be shown, showing that when well modeled there is a speed in obtaining influences, with acceptable errors (5.5%), and that when not well modeled, they can generate values with errors of up to 90% in relation to the value of the abacus. The ease of use of the technique and the speed of processing are better understood when you have a large number of points inside the soil massif where you want to predict the values of the influences, due to the batch processing capability of the ANN.

Keywords: Abacus. Predictions of Influences. Soil Mechanics. Computational Intelligence. Artificial Neural Network.

Introdução

Para aplicação da Mecânica dos Sólidos Deformáveis aos solos, deve-se partir do conceito de tensões. Uma maneira adequada consiste na consideração de que os solos são constituídos de partículas e que as forças aplicadas a eles são transmitidas de partícula a partícula, além das que são suportadas pela água dos vazios. (Pinto, 2006)


As tensões nos solos são decorrentes das Tensões Iniciais e das Tensões devido a Sobrecargas Externas. As tensões iniciais são aquelas originadas pelo peso próprio do maciço. O cálculo deste estado de tensões pode ser bastante complexo em situações de grande heterogeneidade e topografia irregular (Bastos 2002). Além do peso próprio da massa de solo, as tensões no solo podem variar devido a carregamentos externos, dando origem às tensões induzidas. A determinação da

magnitude e distribuição dessas tensões no subsolo é muito importante na avaliação da estabilidade das obras de engenharia.

Experiências realizadas nos primeiros tempos da Mecânica dos Solos mostraram que ao se aplicar uma carga na superfície do terreno, numa área com bem definida, os acréscimos de tensões numa certa profundidade não se limitam à projeção da área carregada. Nas laterais da área carregada também ocorrem aumentos de tensão, que se somam às anteriores devidas ao peso próprio. Uma prática corrente para estimar o valor das tensões a uma certa profundidade consiste em considerar que as tensões se espraiam segundo áreas crescentes, mas sempre mantendo uniformidade distribuídas, entretanto esta prática não considera a superposição dos efeitos e para resolver tal problema, a Teoria da Elasticidade tem sido empregada para a estimativa das tensões no interior da massa de solo em virtude de carregamentos na superfície, e mesmo no interior do terreno. (Pinto, 2006)

Diversos pesquisadores, utilizando a teoria da elasticidade, promoveram soluções para a descoberta do acréscimo de tensões verticais devido a diversos tipos de carregamento aplicados na superfície do terreno, gerando ábacos que são o “Calcanhar de Aquiles” dos estudantes de engenharia civil, dentre estes os mais conhecidos são: Boussinesq (carga pontual), Love (Carga Circular), Newmark (Carga retangular), Steinbrenner (Carga retangular), Osterberg (Carga Trapezoidal) e Therzagui e Carothers (Carga Uniformemente Distribuída ao Longo de uma Faixa de Comprimento Infinito e Largura Constante), dentre outros. A Figura 1 mostra o exemplo do ábaco de Love para carregamentos circulares (a esquerda), o ábaco de Osterberg para carregamentos trapezoidais (no centro) e do ábaco de Steinbrenner para carregamentos retangulares (a direita).

Figura 1. Ábacos de Love, Osterberg e Steinbrenner.




Fonte: Adaptado de Gerscovich, 2006.

A grande questão é: como obter as influências para os acréscimos de tensões decorrentes de carregamentos externos de forma alternativa aos ábacos e fórmulas da teoria da elasticidade, que são muito utilizados na engenharia geotécnica e de fundações?

As Redes Neurais Artificiais (RNA) serão utilizadas como resposta a este questionamento, tendo em vista que Silva (2016) informa que a similaridade destas com a estrutura do cérebro, pois exibem características semelhantes ao do comportamento biológico humano, tais como: Procura paralela e endereçamento pelo conteúdo; aprendizado; associação; generalização; abstração; robustez; e degradação gradual, e tais características serão exploradas no presente Projeto de Iniciação Científica. Uma Analogia entre o modelo biológico e o modelo artificial adotado pelas RNAs está demonstrado na Figura 2.

Figura 2. Analogia entre os Neurônios Biológico e Artificial.



Fonte: Silva, 2016.

As Redes Neurais Artificiais podem ser utilizadas, em geral, em qualquer área que possua problemas de solução não algorítmica. Na área da Medicina, podem ser utilizadas para diagnósticos em geral. Na área Comercial e Financeira são utilizadas para inúmeros tipos de avaliação e previsão de índices, taxas, etc. Na área da Engenharia podem ser utilizadas para resolução de problemas de computação paralela, aproximação de funções, controle, reconhecimento de padrões, etc. (Osório 2005)

Neste trabalho, o enfoque dado foi o estudo de técnicas de inteligência computacional, através de Redes Neurais Artificiais (RNAs), como método alternativo para resolução de problemas comuns da Engenharia Civil, como a obtenção da influência para o acréscimo de tensões decorrentes de diversos tipos de carregamentos externos aplicados na superfície ou no interior do terreno, que é um dos parâmetros mais utilizados pelos alunos na disciplina de Mecânica dos Solos e pelos engenheiros projetistas de fundações e de contenções.


Materiais e métodos

Para o alcance do objetivo foi elaborado o levantamento de dados junto aos Ábacos de Love, Osterberg e Steinbrenner, formando três bancos de dados para o treinamento, teste/validação das Redes Neurais Artificiais, um para cada tipo de ábaco. Nestes, os dados de entrada são a geometria dos carregamentos e a distância

do ponto onde se deseja obter a influência do carregamento em uma dada profundidade, onde a influência faz parte do conjunto de dados de saída ou alvo.

A Figura 3 apresenta os 56 pontos que foram utilizados no ábaco de Love para a predição das influências, onde cada ponto é um registro do primeiro Banco de Dados, que estão apresentados na Tabela 1. Para gerar o segundo e terceiro Bancos de dados foi adotado o mesmo procedimento, criando 80 registros para o segundo Banco de Dados (Osterberg) e 88 registros para o terceiro (Steinbrenner).

Figura 3. Marcação dos Pontos no Ábaco de Love



Fonte: Pesquisa do Autor

Tabela 1. Primeiro banco de dados extraído do ábaco da Figura 3.

X/R	Z/R	Influência	X/R	Z/R	Influência
1,00	1,20	0,30	0,00	0,50	0,90
2,40	2,80	0,05	0,00	0,72	0,80
1,00	0,70	0,40	0,00	0,90	0,70
0,00	1,10	0,60	0,00	1,34	0,50
1,30	0,70	0,20	0,00	1,58	0,40
1,80	1,80	0,10	0,00	1,98	0,30
1,20	0,20	0,15	0,00	2,52	0,20
1,60	0,70	0,10	0,00	2,96	0,15
1,00	0,30	0,50	0,00	3,72	0,10
1,80	0,80	0,05	2,14	4,00	0,05
1,00	0,40	0,50	0,40	0,98	0,60
0,80	0,20	0,90	1,00	2,00	0,20
0,80	2,20	0,20	0,40	1,60	0,36

1,40	2,00	0,15
2,40	2,40	0,05
1,80	2,00	0,10
0,80	0,60	0,60
1,40	0,40	0,10
0,60	0,36	0,90
2,20	1,60	0,05
1,80	1,40	0,10
0,40	0,80	0,70
0,40	1,20	0,50
1,00	0,20	0,50
0,60	2,80	0,15
0,40	3,60	0,10
2,40	2,60	0,05
1,60	2,60	0,10

0,40	2,17	0,25
0,40	2,60	0,18
0,40	3,20	0,13
0,40	0,42	0,90
0,63	1,00	0,50
0,80	1,40	0,33
0,80	1,80	0,26
1,00	2,80	0,13
1,00	3,30	0,10
0,80	3,80	0,08
1,60	3,60	0,08
1,92	3,00	0,08
2,10	2,20	0,08
1,40	2,40	0,13
1,25	1,40	0,20

Fonte: Pesquisa do Autor

Após a consolidação dos três Bancos de Dados, foram realizadas seis modelagens de Redes Neurais Artificiais (RNAs), duas para cada tipo de ábaco supracitado, através do software comercial GMDH Shell 3.0, da empresa GMDH.

A principal diferença entre as duas modelagens de cada ábaco é que na primeira modelagem, para a fase de treinamento da Rede, que é onde a RNA aprende sobre a geometria do carregamento externo, o ponto do maciço de solo onde se deseja obter a influência do acréscimo de tensões, além da influência do carregamento nesse ponto, foram utilizados 85% dos dados do Banco de Dados e os 15% de dados remanescentes foram utilizados para o Teste/Validação da RNA. Na segunda modelagem, alterou-se os percentuais, tanto para a fase de treinamento da RNA quanto para a fase de Teste/Validação, para 95% e 5% dos dados, respectivamente, aumentando com isso a quantidade de dados que farão parte do treinamento, que em teoria melhora a qualidade da RNA.

Cabe ressaltar que a fase de Teste/Validação do modelo, consiste em utilizar os dados que não foram utilizados no treinamento, e através da análise dos erros gerados, entre os valores de influências obtidos no ábaco e os valores de influência obtidos na RNA, valida-se o Modelo de RNA, indicando se este está apto ou não para ser utilizado como forma alternativa ao ábaco considerado.

A análise de erro se dá da seguinte forma, quanto menor o Erro Percentual Absoluto Médio (MAPE), mais preciso é o modelo RNA, ou seja, caso o MAPE seja

igual a 12%, isso quer dizer que o Modelo faz previsões que erram por 12% do valor real.


Resultados e análises

Neste capítulo estão apresentados os dados e as análises das seis modelagens, extraídos do software GMDH SHELL 3.0.

Dados obtidos com as modelagens


A Figura 4 apresentada a seguir ilustra a forma gráfica de apresentação dos dados das Modelagens feitas pelo software supracitado (Modelagem RNA1 – Ábaco de Love). A Figura 5 ilustra um modelo de resultado do software para mostrar a acurácia da RNA (Modelagem RNA1 – Ábaco de Love).

Figura 4. Gráfico do Treinamento e Teste/Validação – Modelo RNA1.



Fonte: Pesquisa do Autor

Figura 5. Acurácia do Modelo RNA1.



Fonte: Pesquisa do Autor

A Tabela 2, apresentada a seguir, resume os dados obtidos nas seis modelagens, demonstrando os valores MAPE para as fases de treinamento e teste/validação de cada uma delas.

Tabela 2. Resumo dos Dados Extraídos das Modelagens.

Modelo	Ábaco	Registros	% Treinam.	% Validação	MAPE % Treinam.	MAPE % Validação
RNA1	Love	56	85	15	9,4	19,9
RNA2	Love	56	95	5	6,6	22,3
RNA3	Osterberg	80	85	15	29,0	6,3
RNA4	Osterberg	80	95	5	26,9	5,5
RNA5	Steinbrenner	88	85	15	99,6	140,5
RNA6	Steinbrenner	88	95	5	153,8	88,9

Fonte: Pesquisa do Autor

Análise dos dados

Da análise dos resultados da Tabela 2 verifica-se que para o Ábaco de Love, o Modelo RNA1 apresentou a melhor performance, onde as previsões de influência feitos por ele, erram o valor real em média 20%. Já para o ábaco de Osterberg o Modelo RNA4 apresentou a melhor performance, com uma média de 5,5% de erro em relação ao valor Real. Para o Ábaco de Steinbrenner, a melhor performance foi obtida

com o Modelo RNA6, onde a média percentual de erro em relação ao valor real é de aproximadamente 89%.

Analisando os Três modelos com a melhor performance (RNA 1, RNA 4 e RNA6) é possível notar que com a modelagem RNA4 pode-se obter valores de influência muito próximos do valor real, estando este aprovado para a obtenção de influências de carregamentos trapezoidais sem a utilização do ábaco em questão.

Para o Modelo RNA1, a acurácia foi reduzida quando comparado ao RNA4, e os valores de influência obtidas com ele podem ter variações consideráveis dependendo das variáveis de entrada, mas, ainda sim este modelo pode ser utilizado com cautela para a obtenção da influência de carregamentos circulares. Cabe frisar que a quantidade de registros do Banco de dados foi bem inferior a do Banco de Dados do Modelo RNA4, o que pode ter influenciado na performance do mesmo.

Já para o Modelo RNA6, o valor obtido de Erro Percentual Absoluto Médio (MAPE 89%) invalida a sua utilização para obtenção da influência de carregamentos retangulares, mesmo possuindo a quantidade de registros do Banco de Dados um pouco maior que a da Modelagem RNA4.

Cabe ressaltar que o formato dos três ábacos utilizados são diferentes e a forma geométrica das curvas destes ábacos podem demandar um maior número de pontos para a fase de treinamento da Rede Neural Artificial, para melhorar o aprendizado e a performance dos modelos.

Considerações finais

Os resultados obtidos neste trabalho mostram que as Redes Neurais Artificiais conseguem resultados satisfatórios para serem aplicadas na engenharia civil, desde que estas sejam bem modeladas.

Para a Modelagem do ábaco de Osterberg (carregamentos trapezoidais) esta técnica se mostrou bastante eficaz, confiável e ágil, pois após a execução do treinamento da RNA, seu uso torna-se vantajoso quando comparado ao uso dos

ábacos, devido à agilidade na obtenção dos resultados e a confiabilidade dos mesmos devido aos baixos erros obtidos pela RNA4 (5,5%).

Também foi verificado que os resultados obtidos para as Modelagens das Redes Neurais do ábaco de Love (RNA 1 e RNA2) não foram assertivos podendo haver variações médias de 22% entre o valor da RNA e o do ábaco, e, face ao exposto no item 3.2 do presente artigo não é recomendado o uso das Modelagens RNAs do ábaco de Steinbrenner (RNA 5 e RNA6), pois os erros médios podem chegar a 89%.

Para contornar os problemas supracitados, deve-se aumentar a quantidade de registros dos Bancos de Dados cuja performance não foram adequadas, de modo a aumentar o número de pontos no treinamento das RNAs, reduzindo com isso o erro gerado nestas.

Durante as modelagens pôde-se perceber que uma vantagem da utilização da Rede Neural Artificial quando comparada aos métodos tradicionais acontece principalmente quando se tem diversos pontos do solo onde se deseja conhecer as influências devido aos carregamentos externos, para o cálculo dos acréscimos de tensão vertical, pois para tal é utilizado o processamento em lote, que executa a RNA com todos os pontos que se deseja obter os dados em um único passo, tornando rápida a obtenção dessas influências, sem o uso de ábacos.

Referências

BASTOS, Cezar Augusto Burke. (2002). **Tensões nos Solos**. DMC/FURG, Rio Grande do Sul. Disponível em: <<http://civmec.dmc.furg.br/~disp04084/>>.

GERSCOVICH, D.M.S., **Apostila do Curso de Fundamentos Geotécnicos**. Universidade do Estado do Rio de Janeiro - UERJ. Rio de Janeiro. 2006.

OSÓRIO, F.S., **Redes Neurais Artificiais: Histórico, Modelos e Aprendizado**. Universidade do Vale do Rio dos Sinos. Rio Grande do Sul. RS. 2006.

PINTO, C.S., **Curso Básico de Mecânica dos Solos em 16 Aulas**. 3ª Edição. Oficina de Textos. São Paulo. 2006.

SILVA, M.A.S, **Aplicação de um Modelo de Inteligência Computacional Híbrido (Neuro-Fuzzy) na Previsão do Potencial de Ruptura De Taludes**. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Civil – PGECIV. Universidade do Estado do Rio de Janeiro – UERJ. RJ. 2016.