



**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS DE BALSAS
COORDENAÇÃO DO CURSO DE ENGENHARIA CIVIL**

LARA STÉFANY DE OLIVEIRA CRUZ

**DETERMINATION OF LOAD-BEARING CAPACITY IN
DEEP FOUNDATIONS USING ARTIFICIAL NEURAL
NETWORKS**

**(Determinação da capacidade de carga em fundações profundas utilizando
redes neurais artificiais)**

**BALSAS - MA
2024**

Lara Stéfany de Oliveira Cruz

DETERMINATION OF LOAD-BEARING CAPACITY IN DEEP FOUNDATIONS USING
ARTIFICIAL NEURAL NETWORKS

(Determinação da capacidade de carga em fundações profundas utilizando redes neurais artificiais)

Trabalho de conclusão de curso na modalidade Artigo Científico, submetido à Coordenação de Engenharia Civil da Universidade Federal do Maranhão (UFMA), como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia Civil.

Orientador: Prof^o Dr. Cláudio Luis de Araújo Neto

Co-orientadora: Prof^a Me. Ranna de Sousa Barros

Lara Stéfany de Oliveira Cruz

DETERMINATION OF LOAD-BEARING CAPACITY IN DEEP FOUNDATIONS USING
ARTIFICIAL NEURAL NETWORKS

(Determinação da capacidade de carga em fundações profundas utilizando redes neurais artificiais)

Trabalho de conclusão de curso na modalidade Artigo Científico, submetido à Coordenação de Engenharia Civil da Universidade Federal do Maranhão (UFMA), como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia Civil.

Aprovado em: 01 de julho de 2024.

Prof^o Dr. Cláudio Luis de Araújo Neto – Orientador

Prof^a Me. Ranna de Sousa Barros – Co-orientadora

Prof^a Dr^a Carla Caroline Alves Carvalho – Examinadora interna

Prof^o Me. Moisés de Araújo Santos Jacinto – Examinador externo

Balsas - MA
2024

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Cruz, Lara Stéfany de Oliveira.

Determination Of Load-bearing Capacity In Deep Foundations Using Artificial Neural Networks / Lara Stéfany de Oliveira Cruz, Alcineide Dutra Pessoa de Sousa, Moisés de Araújo Santos Jacinto. - 2024.

15 f.

Coorientador(a) 1: Ranna de Sousa Barros.

Orientador(a): Cláudio Luis de Araújo Neto.

Curso de Engenharia Civil, Universidade Federal do Maranhão, Balsas, 2024.

1. Capacidade de Carga. 2. Fundações Profundas. 3. Redes Neurais Artificiais. 4. Multicamadas Perceptron. 5. . I. Araújo Neto, Cláudio Luis de. II. Barros, Ranna de Sousa. III. Jacinto, Moisés de Araújo Santos. IV. Sousa, Alcineide Dutra Pessoa de. V. Título.

DETERMINATION OF LOAD-BEARING CAPACITY IN DEEP FOUNDATIONS USING ARTIFICIAL NEURAL NETWORKS

Lara Stéfany de Oliveira Cruz ¹, Alcineide Dutra Pessoa de Sousa ², Moisés de Araújo Santos Jacinto ³, Cláudio Luis de Araujo Neto ⁴ and Leandro Gomes Domingos ⁵

¹Department of Civil Engineering, UFMA University, Balsas City, Brazil
lara.cruz@discente.ufma.br

²Department of Civil Engineering, CEUMA University, Imperatriz City, Brazil
alcineide.dutrapessoa@gmail.com

³Department of Civil Engineering, UFPA University, Belém City, Brazil
moisesaraujosantosjacinto@gmail.com

⁴Department of Environmental Engineering, UFMA University, Balsas City, Brazil
claudio.neto@ufma.br

⁵Department of Civil Engineering, UFMA University, Balsas City, Brazil
leandro.gd@ufma.br

ABSTRACT

Knowing the geotechnical characteristics of the construction site is of utmost importance for the engineer when designing a project, regardless it is large, medium, or small in scale. By using SPT-N values, the designer will be capable of determining the load-bearing capacity of the soil. Semi-empirical models have been proposed to calculate the load-bearing capacity in deep foundations. However, these models are developed based mathematical frameworks and approximations, where the calculation is not always accurate. Artificial Neural Networks (ANNs) are considered a mechanism capable of accurately calculating these values because they use more reliable variables. For this reason, the present study aims to propose the use of Multi-Layer Perceptron (MLP) artificial neural networks to determine the load-bearing capacity of deep foundations based on SPT-N values and depth. The database compiled from a series of 68 load tests carried out in the city of Balsas-MA, for which SPT-N values and their respective depths were available. To evaluate the obtained results, the roots of the mean squared errors (RMSE) and Pearson correlation coefficients were calculated. The results indicated that the proposed model can determine the load-bearing capacity with a small error rate (RMSE) and high correlation with the values calculated using the classical formulas from the literature

KEYWORDS: *Load-Bearing Capacity, Deep Foundations, Artificial Neural Networks & Multi-Layer Perceptron.*

I. INTRODUCTION

Soils, in general, exhibit non-linear characteristics, making their behaviour under loading variable. To find a correlation between loading and soil, foundations were created to support the load applied by the construction to the ground. To determine the type of foundation, it is necessary to know the load-bearing capacity of the soil where the construction will take place. In this context, semi-empirical and theoretical methods were developed to determine this factor in Civil Construction [1].

According to [2], theoretical formulas often fail to achieve satisfactory results in predicting the loadbearing capacity of pile foundations. Therefore, semi-empirical methods are used, as they are based on empirical correlations and in situ results, providing more accurate results. Consequently, numerous semi-empirical methods were developed based on load test results and tests like the Standard Penetration Test (SPT), which is quite common in Brazil [3].

As reported by [1], semi-empirical methods were initially developed to predict settlements in sands due to the difficulty of testing this material in the laboratory. Subsequently, they were applied to clays and, finally, to soils typically used in civil construction, such as silts, clayey sands, and sandy clays.

Thus, the use of semi-empirical methods is crucial for predicting the load-bearing capacity of a foundation, aiding in design and providing reliability to designers and builders, while optimizing execution costs [4]. It is worth noting that despite their extensive use, these methods exhibit high safety coefficient values, thus increasing foundation costs.

In contrast, the use of machine learning models, particularly Artificial Neural Networks (ANNs), has been accepted and shown to be effective in predicting load-bearing capacity values for deep foundations [5].

In this context, this article proposes the use of MLP-type artificial neural networks to determine the load-bearing capacity of deep foundations based on SPT-N values and depth found in the city of BalsasMA. The methodology of the article was based on a database search to initiate the work. After that, the type of ANN to be used was chosen, as well as the mathematical operations that were utilized to design the algorithm. It is believed that this approach can significantly contribute to optimizing the design and construction processes of civil structures, ensuring greater efficiency and safety in foundations.

II. LOAD-BEARING CAPACITY

Foundations, in general, are responsible for transmitting the forces generated by the construction and are usually classified as shallow and deep foundations. According to [6], deep foundations are characterized as elements capable of supporting the load of the terrain and transmitting this load to the soil through their base and lateral surface, referred to as end-bearing resistance and skin friction, respectively.

Also, according to the standard, this type of foundation must have its end or base supported at a depth greater than eight times its smallest dimension determined in the project and must exceed a minimum of 3 meters. Examples of deep foundations include piles, caissons, and drilled shaft.

The choice of a deep foundation should consider the technical and economic conditions of the construction, where the following terrain characteristics must be known: origin and characteristics of the subsoil, load-bearing capacity to be transmitted to this foundation, limitations of the foundations available on the market, and proximity to neighboring constructions [7]. However, to define the type of foundation, it is necessary to know the load-bearing capacity of the soil where the construction will be done, especially for deep pile foundations [1].

To determine these loads, it is extremely important to carry out a preliminary and complementary geotechnical investigation, based on NBR 6122, where the preliminary investigation can be done through the Standard Penetration Test (SPT), known nationally as the Percussion Drilling Test [8].

According to [9], the SPT is the most widely known geotechnical investigation tool worldwide because it can indicate the consistency of cohesive soils and the compaction of granular soils. Furthermore, the test can determine the groundwater level and the nature of the soil in each penetrated layer, determining the penetration resistance index, known as SPT-N.

According to [10], the SPT equipment consists of a rope, a 65kg hammer, a tripod, a guide, rods, and a standard sampler. The procedure with this equipment essentially involves driving the standard sampler into the soil, penetrating 15cm increments through the free fall of the 65kg hammer from a height of 75cm [11]. After drilling 45cm in all layers, the N_{SPT} value is determined as the sum of the number of blows required to reach the last 30cm that the standard sampler can penetrate [9].

Through the SPT test report, it is possible to define the type of foundation to be used in the soil, as well as the diameter or cross-sectional area of the shaft. Using these variables, along with the length of the

pile in each borehole, it is possible to obtain the load-bearing capacity value that the terrain can support [12].

[13] states that the load-bearing capacity is the sum of the end-bearing and skin friction resistances of the studied soil, as shown in Figure 1.




Figure 1. Demonstration of the resistance components for the load-bearing capacity result, [2].

And it can be demonstrated using equation 1.

$$R = R_L + R_p \quad (1)$$

The lateral resistance (R_L) is the product of the perimeter and the sum of the forces obtained from the skin friction resistance along the entire length of the pile, equation 2. In turn, the end-bearing resistance (R_p) is the product of the unit end-bearing stress and the cross-sectional area of the pile base, equation 3.

$$R_L = U * \sum r_L * \Delta L \quad (2)$$

$$R_p = r_p * A_p \quad (3)$$

The use of these variables, especially the use of the SPT test as a source to define this load, has been present from studies in Egyptian soils to soils with fine and coarse granulation [13]. However, calculating this load-bearing capacity, especially in deep foundations, is declared a major problem for geotechnics. Despite the emergence of semi-empirical models such as those by Aoki and Velloso (1975), Décourt and Quaresma (1978), and Teixeira (1996), the precision of the results is generally inaccurate. This is due to the fact that these models work based on approximations of mathematical models and physical assumptions [14].

III. ARTIFICIAL NEURAL NETWORKS

Artificial Neural Networks (ANNs) can be classified as a subset of *machine learning*. Their name and structure are inspired by the human brain because they are capable of processing information in a nonlinear, parallel, and highly complex manner, as well as identifying and solving patterns [15].

There are different types of artificial neural networks, each designed for specific tasks. The most common types are Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and Multi-Layer Perceptron (MLP) networks. CNNs are used for image recognition and video processing due to their high capacity for capturing features in spatial dimensions. RNNs are effective in processing sequential data, such as time series, because of their ability to retain information over time. The MLP, on the other hand, is a general-purpose neural network [16].

In analogy to the human brain, ANNs can organize their neurons or nodes to perform tasks quickly, focusing on a specific task. Their components include activation functions, summation, and synaptic weights [8], as illustrated in Figure 2.




Figure 2. Diagram of an Artificial Neuron, [17].

The input data, represented by x_j , are the starting point of a neuron. They are connected to each synaptic weight in the hidden layers, w_{kj} , which are determined during the training of the ANN. The summation is responsible for the total sum of the products between the input data and the synaptic weights, u_k [8].

According to the author, the activation function, $g(\cdot)$, determines the output value of a neuron through mathematical functions such as linear, hyperbolic tangent, sigmoid, and threshold functions. The biases, b_k , are applied outside the summation and have the power to adjust the summation response values up or down, allowing the ANN to make corrections after the input data is inserted. Finally, the output, which can be more than one depending on the network model, is determined. Mathematically, the neuron's operation is described by equations 4 and 5.

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

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

The units are organized in layers interconnected by synaptic connections, where there are input and output layers as well as hidden layers, which are received by each neuron in the network. The most well-known and simplest artificial neural network technique with this structure is the Multi-Layer Perceptron (MLP) (Figure 3), which operates in two phases: learning and execution. Additionally, it is known for solving function approximation, optimization, and prediction problems [18].




Figure 3. Architecture of a Multi-Layer Perceptron (MLP), [18].

The input layer receives the data that the network will process, where each neuron in this layer corresponds to a feature imposed on the input data by the designer. The hidden layers perform the more complex part of the network, as each neuron in this layer is connected to both the input and output layers, and each of these connections has a weight that is adjusted during the machine's training phase. As the name suggests, the output layer contains the final results of the network, with the number of neurons in this layer corresponding to the number of responses the network is configured to predict [16].

According to [19], the algorithm for updating the synaptic weights of an MLP is *Backpropagation*. This algorithm involves two phases in its implementation: *forward* propagation and *backward* propagation. In *forward* propagation, the input signals remain unchanged as they propagate through all the layers to the network's output, without any change in their weights.

Backward propagation involves propagating the calculation error from the output back to the hidden and input layers through the network. During this propagation, the gradients of the loss function concerning each weight are calculated using the chain rule. The weights are then adjusted in the opposite direction of the gradient using gradient descent, thus reducing the network's error [19].

Once the network is trained, it can perform the tasks programmed in its interface. It is important to note that the neural network's performance will only be beneficial if the network architecture, the implemented algorithm, the dataset used in the training phase, and all its layers and neurons are wellspecified and interconnected, thereby producing a minimal sum of errors as the network's function desires [20].

Given this, an ANN can be used to minimize error impacts, particularly in the field of Geotechnics. In a study by [21], artificial neural networks were used to relate the settlement of isolated piles to their geometric properties and the results obtained from SPT tests on soil consistency. Using the QNET 2000 software, the correlation coefficient result was 0.94 in the validation phase.

[22] used ANNs to estimate the load-bearing capacity of continuous flight auger piles and precast concrete piles, comparing the results with those obtained using the semi-empirical methods of AokiVelo and Décourt-Quaresma. He concluded that the network was satisfactory with only four input parameters and a few neurons in the hidden layer.

IV. MATERIALS AND METHOD

4.1. Research method

To determine the load-bearing capacity of a deep foundation, semi-empirical methods based on approximations of mathematical models are used. However, these methods do not always yield accurate results. For this reason, the use of Artificial Neural Networks (ANNs) in geotechnics has been growing, as they provide more precise results that assist in the execution of a foundation.

Based on the discussions proposed by [23], the research conducted in this work can be classified by its methodology as explanatory, regarding its objective, and also quantitative and statistical regarding its approach. For data collection, procedures based on *ex-post facto* were used.

To obtain the results proposed in this work, two types of variables were defined. The first variable was classified as dependent, which is the one where modelling will occur to predict the values it will assume when there is no information about it. In this study, the dependent variable is the load-bearing capacity.

The second variable consists of the characteristics that the model user has available for project development, being independent. In this work, the data for this variable are obtained from SPT-N values and their respective depth.

4.2. Database

The data used as the second variable for the modelling process were obtained from SPT test reports conducted in the city of Balsas, in the state of Maranhão. According to IBGE (2022), the municipality is situated at an altitude of 243 meters and has the following geographic coordinates: latitude: $-7^{\circ} 31' 59''$ S and longitude: $46^{\circ} 2' 6''$ W. It has a population of 101,767 inhabitants and covers a territorial area of 13,141.637 km². Figure 4 shows the location of the municipality in relation to the State of Maranhão.



Figure 4. Location of the municipal.

The reports were provided by Company Y and the coordinates of the identified points are shown in Figure 5.




Figure 5. Points where SPT tests were conducted.

Therefore, upon analysing the 26 reports provided by Company Y, it was found that in certain tests, more than one hole was drilled per coordinate, totalling 68 holes. For each drilling depth, an SPT-N value was obtained, and these data were used for modeling the artificial neural network.

4.3. Model used

The model used in the network was implemented in three stages: construction of the algorithm and selection of the type of ANN, training and specifications of the artificial neural networks, and finally, the network testing was performed.

The type of ANN chosen depends on the problem proposed by the designer. In the study in question, the MLP (Multilayer Perceptron) was chosen to determine the load capacity values in deep foundations. The algorithm used in the network was *Backpropagation*, which involves calculating the error through *forward* and *backward* passes.

The variables used for the calculation of load capacity were: two inputs, SPT-N and depth, one hidden layer, varying between 2 to 10 neurons in the hidden layer, and one output corresponding to the load capacity value. Figure 6 shows the network topology and the training phase for determining the load capacity values.




Figure 6. Network topology.

Therefore, the value predicted by the network in each *loop* is then compared with the measured value. As a stopping criterion for the network, it was defined that if the error in one *loop* is greater than 10^{-7} compared to the error in another *loop*, the network continues updating its synaptic weights if this condition is not met.

4.4. Evaluation Metrics

The model evaluation metrics consist of analyses of statistical characteristics both in the testing phase and in the training phase. These are based on assessments through hypothesis testing, Pearson correlation, and Root Mean Square Error (RMSE).

4.4.1. Root mean squared error

After calculating the values using the artificial neural networks, it was then possible to calculate the Root Mean Square Error (RMSE) based on the results from the output layer and the actual values. RMSE is mathematically defined as shown in equation 6.

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (y_i - p_i)^2} \quad (6)$$

Where:

- y_i is the predicted value for the i-th observation;
- p_i is the observed value for the i-th observation;
- n is the total number of observations.

RMSE is one of the essential metrics for evaluating prediction models using ANN, providing a quantitative measure of the accuracy of their predictions. Compared to other metrics, such as Mean Absolute Error (MAE), RMSE can identify and penalize larger errors [25].

4.4.2. Pearson correlation

The Pearson correlation was used to check for the occurrence of linearity between the actual and predicted values. It is responsible for quantifying the strength and direction of the linear relationship between two continuous variables. The formula for calculating the Pearson correlation coefficient (equation 7) is given by:

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (7)$$

Where:

- n is the number of data pairs;
- x and y are the variables being compared;
- $\sum xy$ is the sum of the products of the data pairs;
- $\sum x$ and $\sum y$ are the sums of the individual variables;
- $\sum x^2$ and $\sum y^2$ are the sums of the squares of the individual variables.

According to [26], the correlation ranges between -1 and 1, where the sign indicates its direction and the value indicates its magnitude. If the value is closer to 1, the linear association between the variables is characterized as strong; if it is closer to zero, the association is almost negligible.

V. RESULTS AND DISCUSSION

A computational model based on ANN, designed to calculate load capacity from SPT-N and depth data, was proposed in this article. Data from 68 boreholes were used for each simulation, with each borehole having different depths, totalling 709 load capacity values. Of this total, 68 values (approximately 10%) were randomly reserved for testing, and the remainder was used to train the model.

The network topology used consists of an input layer, an intermediate layer, and an output layer. Simulations were conducted for different numbers of neurons in the intermediate layer and different learning rate values. The training and testing results are presented below in graphs and the previously defined evaluation metrics.

The network topology used is composed of three layers: an input layer, an output layer, and a hidden layer. In the first simulation, 6 neurons were used in the hidden layer with a learning rate of $\mu=0.01$. The results of this simulation are presented in Table 1 and in the graph of Figure 7.

Table 1: Simulation with 6 Neurons.

Metric	Value
RMSE	1,94 kN
Correlation	0,93

In Figure 7, it is possible to see how closely the values estimated by the model match the desired values.




Figure 7: Network testing phase with 6 neurons.

For the second simulation, the number of neurons in the hidden layer was modified, setting it to 8 neurons. Table 2 presents the error and correlation values obtained with this topology.

Table 2: Simulation with 8 Neurons.

Metric	Value
RMSE	2,00 kN
Correlation	0,93

It is noticeable that increasing the number of neurons in the hidden layer resulted in a slight increase in the error value; however, the correlation remained the same. In Figure 8, a comparison between the values obtained by the model and the actual values can be observed.

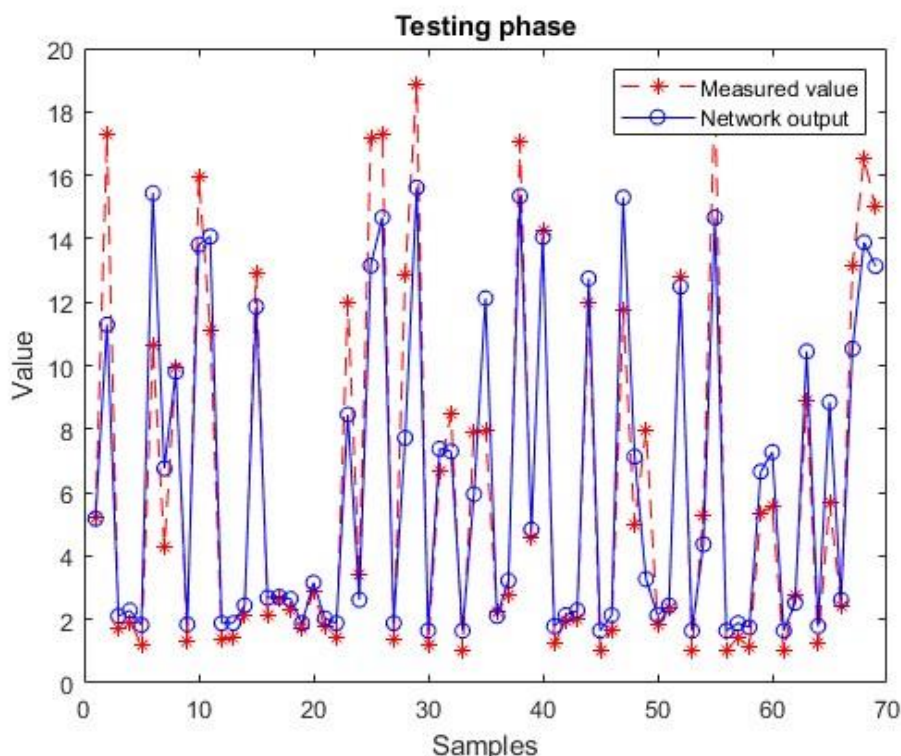


Figure 8: Network Testing Phase with 8 Neurons.

In order to have a broader view of the simulations, Tables 3 to 7 present the simulation values for different learning rates and numbers of neurons in the hidden layer. Initially, 2 neurons were fixed in the hidden layer and the learning rate values were varied. Table 3 shows the results of these simulations.

Table 3: Results of the Network with 2 Neurons.

Number of neurons in the hidden layer	Learning rate	RMSE	Correlation
2	0,1	1,94211931	0,941788378
	0,2	2,09703424	0,904014988
	0,3	2,06777628	0,914820487
	0,4	2,4620696	0,906868907
	0,5	2,2755417	0,92114097
	0,6	2,29602668	0,92062478
	0,7	2,41789689	0,921329994
	0,8	1,91014049	0,955081479
	0,9	1,81110241	0,954929634
	1	3,33067794	0,913955275

It is noticeable that the best result when the number of neurons was fixed at 2 occurred when the learning rate used was 0.9. Another simulation was conducted by fixing 4 neurons in the hidden layer and varying the learning rate values. The results of this simulation are presented in Table 4.

Table 4: Results of the Network with 4 Neurons.

Number of neurons in the hidden layer	Learning rate	RMSE	Correlation
4	0,1	2,12920883	0,927012651
	0,2	1,54966102	0,950414351
	0,3	1,99730469	0,943785856
	0,4	1,80576442	0,939042062
	0,5	2,38794901	0,921268879
	0,6	1,88554196	0,933481299
	0,7	3,1582591	0,944415238
	0,8	3,44813794	0,933539309
	0,9	2,60068657	0,915437275
	1	2,40306136	0,899634558

For 4 neurons in the hidden layer, the best result was obtained with a learning rate of 0.2. Following the same methodology of fixing the number of neurons in the hidden layer and varying the learning rate, Table 5 presents the results for 6 neurons in the hidden layer.

Table 5: Results of the Network with 6 Neurons.

Number of neurons in the hidden layer	Learning rate	RMSE	Correlation
6	0,1	1,70121848	0,953344514
	0,2	2,46477456	0,920706435
	0,3	2,06445471	0,9384334
	0,4	2,28858395	0,924912493
	0,5	2,74862754	0,876012368
	0,6	2,03397933	0,913573554
	0,7	2,90541789	0,915521827
	0,8	2,73197701	0,931875275
	0,9	2,25870292	0,930770002
	1	3,99954007	0,90787199

For 6 neurons in the hidden layer, the best result was obtained with a learning rate of 0.1. In the penultimate simulation, eight neurons were fixed in the hidden layer. Table 6 presents the results for this simulation.

Table 6: Results of the Network with 8 Neurons.

Number of neurons in the hidden layer	Learning rate	RMSE	Correlation
8	0,1	2,65040869	0,904444848
	0,2	2,2351627	0,911829876
	0,3	2,08928934	0,93844497
	0,4	2,17904337	0,924965393
	0,5	2,67351468	0,88643435
	0,6	2,33760268	0,912957167
	0,7	3,75295424	0,894947321
	0,8	2,14574767	0,931255397
	0,9	3,57288427	0,925948839
	1	4,18216093	0,868132723

With 8 neurons in the hidden layer, the best result was achieved with a learning rate of 0.3. Finally, a simulation was conducted with 10 neurons in the hidden layer. The results for this group of simulations are presented in Table 7.

Table 7: Results of the Network with 10 Neurons.

Number of neurons in the hidden layer	Learning rate	RMSE	Correlation
10	0,1	2,47489422	0,91510898
	0,2	4,31178155	0,947399929
	0,3	1,98704772	0,90597883
	0,4	2,30947364	0,898714947
	0,5	1,89046129	0,942592974
	0,6	2,10081816	0,959191648
	0,7	2,65189015	0,91694354
	0,8	5,59881005	0,89008605
	0,9	5,15250675	0,900390976
	1	3,35600769	0,875248464

With 10 neurons in the hidden layer, the best result was obtained with the learning rate set at 0.5. Overall, among all the simulations presented, the best result was achieved when four neurons were fixed in the hidden layer and the learning rate was set to 0.2 (RMSE = 1.54 and correlation = 0.95), as shown in Table 8.

Table 8: Simulation Results.

Number of neurons in the hidden layer	Learning rate	RMSE	Correlation
2	0,9	1,81110241	0,954929634
4	0,2	1,54966102	0,950414351
6	0,1	1,70121848	0,953344514
8	0,3	2,08928934	0,93844497
10	0,5	1,89046129	0,942592974

VI. CONCLUSIONS

Deep foundations generally depend on good design and precise calculations regarding the load they will support. However, using semi-empirical methods to calculate their load capacity requires numerous variables. On the other hand, for calculating this capacity using ANNs, only two variables are necessary.

To determine the load capacity values for different SPT tests conducted in the city of Balsas-MA, artificial neural networks of the MLP type were used in this work. To present the results, statistical evaluation metrics such as RMSE and Pearson correlation were utilized.

In this context, the neural model underwent various tests with the number of neurons in the hidden layer ranging from 2 to 10. The best result was obtained when four neurons were fixed in the hidden layer and a learning rate of 0.2 was used (RMSE = 1.54 and Pearson correlation = 0.95).

This result demonstrates that using ANNs can aid in determining load capacity values in deep foundations. However, if the database were larger, the study could achieve more effective results, thus improving the model to boost its use in civil construction for this type of calculation.

Furthermore, the study encourages new investigations into the SPT reports provided. Through them, it is possible to use artificial neural network models to calculate the distance between the points under study and also to compare the results obtained by the network with load capacity results calculated using the semi-empirical methods present in the literature.

REFERENCES


- [1]. Velloso, D. A.; Lopes, F. R. (2010). *Fundações: Fundações profundas*. 2. ed. São Paulo: Oficina de Textos.
- [2]. Cintra, J. C. A.; Aoki, N. (2010). *Fundações por estacas: projeto geotécnico*. São Paulo: Oficina de Textos, 96 p.
- [3]. Santos, M. F. da S., et al. (2017). Análise dos perfis de sondagem SPT em Caxias/MA. In: Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC'2017. n° I, Belém – PA.
- [4]. Monteiro, T. M; Araújo, C. B. C. de; AGUIAR, M. F. P de. (2017). Análise de métodos semiempíricos nacionais e internacionais para determinação da capacidade de carga axial em estacas tipo raiz. *Revista Tecnologia*, v. 38, n. 2, p. 1-16, dez.
- [5]. Amancio, L. B. (2013). *Previsão de Recalques em Fundações Profundas Utilizando Redes Neurais Artificiais do Tipo Perceptron*. Tese apresentada ao programa de pós-graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Mestre em Engenharia Civil. Área de Concentração: Geotecnia.
- [6]. Associação Brasileira de Normas Técnicas (ABNT). (2022). NBR 6122: Projeto e execução de fundações. Rio de Janeiro, 2022.
- [7]. Pereira, J. A; Rodrigues, B. V. (2023). Análise dos fatores condicionantes na escolha de tipos de fundações em solos moles. *Revista Multidebates*, v. 7, n. 4, p. 89-97, dez.
- [8]. Delazzeri, M. L. C. (2018). *Estimativa da Capacidade de Carga de Fundações Profundas Utilizando Rede Neural Artificial*. Tese apresentada ao programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Estadual de Feira de Santana como requisito parcial à obtenção do título de Mestre em Ciências em Engenharia Civil e Ambiental.
- [9]. Cristoferi, R. A; Bergmann, A. C; Lorenzi, V. (2018). Comparativo entre Ensaio de Sondagem à Percussão Manual e Mecânico: um estudo de caso na região oeste do Paraná. 19 f. Artigo - Universidade Paranaense: Campus de Toledo, PR.
- [10]. Associação Brasileira de Normas Técnicas (ABNT). (2020). NBR 6484: Solo - Sondagem de simples reconhecimento com SPT - Método de Ensaio. Rio de Janeiro.
- [11]. Silva, G. C. F; Azevedo, R. B; Cunha, F. R. L. (2021). Avaliação da Sondagem SPT via estudo de caso. 15 f. Artigo - Pontifícia Universidade Católica de Goiás, Curso de Engenharia Civil, GO.
- [12]. Cintra, J. C. A.; Aoki, N.; Tsuha, C. H. C.; Giacheti, H. L. (2013). *Fundações: ensaios estáticos e dinâmicos*. [S.L]: Editora Oficina de Textos, 144p.
- [13]. Vural, I.; Kabaca, H.; Poyraz, S. (2023). Uma nova proposta de abordagem para estimativa da capacidade de suporte final da estaca com base em dados de teste de carregamento de estaca. *Apl. Ciência*, 13, 7993. DOI: <https://doi.org/10.3390/app13137993>
- [14]. Fellenius, B. H. (2020). *Noções básicas de projeto de fundações*. British Columbia.
- [15]. Moreira, I. I. P.; et al. (2021). Redes neurais artificiais para previsão de capacidade de carga em estacas do tipo hélice contínua. *Brazilian Journal of Development*, Curitiba, v. 7, n. 12, p. 112577-112597, dez.
- [16]. Goodfellow, I.; Bengio, Y.; Courville, A. (2016). *Deep learning*. Cambridge: MIT Press.
- [17]. Silva, In; Spatti, D. E; Flauzino, R. (2016). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático (2ª edição)*. São Paulo, Brasil: Artliber.
- [18]. Haykin, S. (2008). *Redes Neurais: Princípios e Prática (3ª edição)*. Porto Alegre, Brasil: Bookman.
- [19]. Jesus, B. V. de. (2019). *Experimentos de previsão da carga de ruptura em estacas carregadas axialmente à compressão utilizando Redes Neurais Artificiais (RNA)*. 178 f. Dissertação (Mestrado em

Engenharia Civil) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

- [20]. Assis, H. S. de. (2023). Previsão do comportamento de estacas hélice contínua a partir de inteligência artificial. 2023. 46 folhas. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Instituto Politécnico, Universidade Federal do Rio de Janeiro, Macaé.
- [21]. Silveira, M. V. (2014). Modelo neuronal para previsão de recalques em estacas hélice contínua, metálica e escavada. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia e Hidráulica Ambiental, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Fortaleza.
- [22]. Ferreira, R. A. (2010). Previsão da capacidade de carga de fundações profundas através de redes neurais artificiais. 85 f. Monografia (Bacharel em Engenharia Civil), Universidade Estadual de Feira de Santana, Feira de Santana.
- [23]. Minayo, M. C. de S. (2014). O desafio do conhecimento, pesquisa qualitativa em saúde. 14. ed. ed. São Paulo: Hucitec. 407. p.
- [24]. Instituto Brasileiro de Geografia e Estatística (IBGE). (2022). Cidades e Estados: IBGE. <https://www.ibge.gov.br/cidades-e-estados/ma/balsas.html>
- [25]. Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. 2022. European Geosciences Union. doi: <https://doi.org/10.5194/gmd-15-5481-2022>
- [26]. Figueiredo Filho, D. B.; et al. (2014). Desvendando os Mistérios do Coeficiente de Correlação de Pearson: O Retorno. Leviathan – Cadernos de Pesquisa Política, n. 8, pp. 66-95.

Authors

Lara Stéfany de Oliveira Cruz is a Building Technician from the Federal Institute of Maranhão (IFMA), in 2021 she completed her Interdisciplinary Bachelor's Degree in Science and Technology from the Federal University of Maranhão (UFMA) and is currently completing her Bachelor's degree in Civil Engineering from the Federal University of Maranhão (UFMA).



Alcineide Dutra Pessoa de Sousa has received a bachelor's degree in civil engineering from the Federal University of Maranhão, São Luis, in 2019 and a master's degree in 2020 and a Doctorate in 2023, both from the Federal University of Pará. She is currently a teacher on the course of Civil Engineering at CEUMA University. Her research interest is in the areas of signal processing and Artificial Intelligence applied to Engineering problems.



Moisés de Araujo Santos Jacinto is a researcher in the area of Civil Engineering and Production Engineering, Graduated in Civil Engineering, Master in Civil Engineering (UFPA) Postgraduate in Production Engineering, Postgraduate Lato Sensu in progress MBA in Business Management and Doctorate in progress in Civil Engineering (Civil Construction and Structures).



Claudio Luis de Araujo Neto has a PhD in Civil and Environmental Engineering, a master's degree in Civil and Environmental Engineering, a specialist in Education and Environmental Management and Auditing, a degree in Sanitary and Environmental Engineering and a degree in Agricultural Sciences. Professor of the Environmental Engineering Course and the Postgraduate Program in Environmental Science and Technology at the Federal University of Maranhão (UFMA). Coordinator of the Sanitation and Environmental Geotechnics Research Group and the Environmental Geotechnics Laboratory (CCBL/UFMA). Member of the Environmental Geotechnics Group (GGA) at



the Federal University of Campina Grande (UFCG), where he coordinates the geotechnical testing subgroup. He has experience in the area of Sanitary Engineering, with an emphasis on Environmental Geotechnics, Urban Solid Waste and Landfill.

Leandro Gomes Domingos has a degree in degree in Environmental Management Technology (2008) from the Federal Institute of Education, Science and Technology of Rio Grande do Norte (IFRN), a degree in Civil Engineering (2016) and a Master's in Sanitary Engineering (2011) from the Federal University of Rio Grande do Norte (UFRN). Currently, he is an Assistant Professor (Level 2) and Coordinator of the Bachelor's Degree Program in Civil Engineering at the Center for Sciences of Balsas, at the Federal University of Maranhão (UFMA).



TEXTO EM PORTUGUÊS

Determinação da capacidade de carga em fundações profundas utilizando redes neurais artificiais

RESUMO

Conhecer as características geotécnicas do local que será feita a construção é de suma importância ao engenheiro na hora de elaborar seu projeto, seja ele de grande, médio ou pequeno porte. Por meio de valores de N_{SPT} , o projetista será capaz de calcular a capacidade de carga que o solo suporta. Modelos semiempíricos foram propostos para calcular a capacidade de carga em fundações profundas, porém, foram criados por meio de modelos matemáticos e aproximações, onde esse cálculo nem sempre é preciso. As Redes Neurais Artificiais (RNA), são consideradas um mecanismo capaz de calcular com precisão esses valores, pois utiliza variáveis mais confiáveis. Por esse motivo, o presente estudo tem como objetivo propor a utilização de redes neurais artificiais do tipo MLP para determinar a capacidade de carga de fundações profundas, a partir dos valores de N_{SPT} e profundidade. O banco de dados consistiu de 68 testes de carga, realizados na cidade de Balsas-MA, para os quais estavam disponíveis valores de N_{SPT} e suas respectivas profundidades. Para avaliar os resultados obtidos, foram calculadas as raízes dos erros quadráticos médios e os coeficientes de correlação de Pearson. Os resultados indicaram que o modelo proposto é capaz de determinar a capacidade de carga com pequena taxa de erro (RMSE) e alta correlação com os valores calculados através das fórmulas clássicas da literatura.

Palavras-chave: Capacidade de carga. Fundações Profundas. Redes Neurais Artificiais.

1 INTRODUÇÃO

Solos, em geral, apresentam características de não linearidade, portanto são variáveis em relação ao seu comportamento sob a ação de um carregamento. Na busca de uma afinidade entre o carregamento-solo, as fundações foram criadas, com o intuito de suportar a carga que a construção aplica no terreno.

Para definir o tipo de fundação é necessário saber a capacidade de carga que o solo, onde será feito a construção, suportará. Nesse contexto, foram criados os métodos semiempíricos e teóricos para determinar esse fator na Construção Civil (Velloso; Lopes, 2011).

Segundo Cintra e Aoki (2010) as formulas teóricas por vezes não conseguirão obter resultados satisfatórios em relação a previsão da capacidade de carga em fundações do tipo estacas, por esse motivo, são utilizados os métodos semiempíricos, pois foram criados com embasamento em correlações empíricas e também nos resultados obtidos *in situ*, conseguindo assim um resultado mais preciso. Diante disso, os inúmeros métodos semiempíricos foram desenvolvidos com base nos resultados de prova de cargas e de ensaios, como o *Standard Penetration Test* (SPT), bastante comum no território nacional (Santos, *et al.*, 2017).

De acordo com Velloso e Lopes (2011), os métodos semiempíricos, inicialmente foram desenvolvidos com o intuito de prever recalques em areias, pois havia dificuldade em realizar ensaios desse material em laboratório, logo após passaram a ser aplicados em argilas e por fim nos solos característicos usados na construção civil, como os siltes, areias argilosas, argilas arenosas.

Dessa forma, a utilização dos métodos semiempíricos é de suma importância para prever a capacidade de carga de uma fundação, auxiliando no dimensionamento e passando uma confiabilidade ao projetista e ao executor, além de otimizar os custos na execução (Monteiro, *et al.*, 2017). Vale ressaltar que apesar de serem muito utilizados, esses métodos apresentam valores elevados de coeficientes de segurança, elevando assim o custo da fundação.

Em contrapartida, o uso de modelos baseados em aprendizado de máquina, principalmente Redes Neurais Artificiais (RNAs), vem sendo aceito e se mostrando eficazes no que se diz respeito a previsão de valores de capacidade de carga em fundações profundas (Amancio, 2013).

Nesse contexto, este artigo propõe a utilização de redes neurais artificiais do tipo MLP para determinar a capacidade de carga de fundações profundas, a partir dos valores de N_{SPT} e profundidade, encontrados na cidade de Balsas-MA. A metodologia do artigo foi baseada em uma busca de base de dados para iniciar o trabalho, após isso foi escolhido o tipo de RNA a ser utilizada e as operações matemáticas que foram utilizadas para projetar o algoritmo. Acredita-se que essa abordagem possa contribuir significativamente para a otimização dos processos de projeto e construção de estruturas civis, garantindo maior eficiência e segurança nas fundações.

2 CAPACIDADE DE CARGA

Fundações, de um modo geral são responsáveis por transmitir os esforços gerados pela construção, são geralmente classificadas em fundações rasas e profundas. De acordo com a NBR 6122 (ABNT, 2022), fundações profundas são caracterizadas como elementos que são capazes de suportar a carga do terreno e de transmitir essa mesma carga ao solo pela sua base e sua superfície lateral, chamadas de resistência de ponta e de resistência lateral, respectivamente.

Ainda de acordo com a norma, este tipo de fundação tem que possuir uma ponta ou a sua base sendo apoiada na profundidade, onde essa deve ser superior a oito vezes a sua menor dimensão determinada em projeto e também ultrapassar o mínimo de 3 metros, são exemplos de fundações profundas as estacas, tubulões e caixões.

Para a escolha de uma fundação profunda deve-se levar em consideração as condições técnicas e econômicas da referida construção, onde devem ser conhecidas as seguintes características do terreno: origem e característica do subsolo, capacidade de carga que serão transmitidas a essa fundação, limitação das fundações existentes no mercado e também a proximidade das construções limítrofes (Pereira; Rodrigues, 2023). Porém, para definir o tipo de fundação é necessário saber a capacidade de carga que o solo onde será feita a construção suportará, principalmente a fundação profunda do tipo estaca (Velloso; Lopes, 2011).

Para determinação dessas cargas é de extrema importância a execução de uma investigação geotécnica preliminar e também a complementar, que estão baseadas na NBR 6122, onde a preliminar pode acontecer por meio do *Standard Penetration Test* (SPT), ou como é conhecido nacionalmente, o Ensaio de Sondagem à Percussão (Delazzeri, 2018).

Para Cristoferi, Bergamann e Lorenzi (2018), o SPT é a ferramenta de investigação geotécnica mais conhecida no mundo todo, pois ele é capaz de indicar a consistência de solos coesivos e também a compacidade dos solos granulares. Ainda de acordo com os autores, o ensaio


consegue determinar o nível do lençol freático, assim como saber a natureza do solo em cada camada penetrada e por meio desse estímulo determina o índice de resistência a penetração, o chamado N_{SPT} .

Segundo a NBR 6484 (ABNT, 2020), a aparelhagem do ensaio é composta por corda, martelo de 65kg, tripé, guia, hastes e amostrador padrão. O procedimento com essa aparelhagem consiste, basicamente, na cravação do amostrador padrão no solo, perfurando de 15cm em 15cm, por meio da queda livre do martelo de 65kg, caindo sob uma altura de 75cm (Silva; Azevedo; Cunha, 2021). Após a perfuração completar 45cm em todas as camadas, é determinado o valor do N_{SPT} , que será o resultado da soma do número de golpes que ocorreram até chegar nos últimos 30 cm que o amostrador padrão conseguiu alcançar na penetração do trado (Cristoferi, *et al.*, 2018).

Por meio do relatório do ensaio SPT, é possível definir o tipo de fundação a ser utilizada no solo, além do diâmetro ou seção transversal do fuste, onde com essas variáveis, juntamente com o comprimento da estaca em cada furo de sondagem, é possível obter o valor da capacidade de carga que o terreno suportará (Cintra *et al.*, 2013).

A NBR 6122 (ABNT, 2022) afirma que a capacidade de carga é o somatório das resistências de ponta e resistências laterais do solo em estudo, conforme apresentado na Figura 1.

Figura 1: Demonstrativo das parcelas de resistência para o resultado da capacidade de carga.



Fonte: Cintra e Aoki, 2010.

E pode ser demonstrado a partir da Eq. 1

$$R = R_L + R_P \quad (\text{Eq. 1})$$

Sendo a resistência lateral (R_L), a multiplicação entre o perímetro e o somatório das forças obtidas por resistência de atrito lateral em todo o comprimento da estaca (Eq. 2), por sua vez, a resistência de ponta (R_P), é o produto da unidade de tensão de ponta, pela área da seção transversal da base da estaca (Eq. 3).

$$R_L = U * \sum r_L * \Delta_L \quad (\text{Eq. 2})$$

$$R_P = r_P * A_P \quad (\text{Eq. 3})$$

O uso dessas variáveis, principalmente o uso do ensaio SPT como fonte para definir essa carga está presente desde o estudo em solos egípcios até em solos que possuem granulação fina e grossa (Vural, *et al.*, 2023), porém, o cálculo dessa capacidade de carga, principalmente em fundações profundas é declarado como um grande problema para a geotecnia, pois, mesmo com o surgimento de modelos semiempíricos como os de Aoki e Velloso (1975), Décourt e Quaresma (1978) e Teixeira (1996), a precisão dos resultados é geralmente, imprecisa, pelo devido fato desses modelos funcionarem com base em aproximações de modelos matemáticos e suposições físicas (Fellenius, 2020).


3 REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNA), podem ser classificadas como um subconjunto de *machine learning*, onde seu nome e estrutura foram criados com base no cérebro humano, pois são capazes de processar informações de uma forma não-linear, paralela e de extrema complexidade, assim como identificar padrões e resolvê-los (Moreira *et al.*, 2021).

Existem diferentes tipos de redes neurais artificiais, sendo cada uma designada para uma tarefa específica, as mais comuns são as Redes Neurais Convolucionais (CNNs) e as Redes Neurais Recorrentes (RNNs) e a Rede Neural Multicamadas (Multilayer Perceptron, MLP), a primeira é utilizada para reconhecimento de imagens e processamento de vídeos, pois possui uma alta capacidade de captura de características nas dimensões espaciais, já a segunda é eficaz no processamento de dados sequencias, com series temporais, por conta da sua capacidade de assegurar dados ao passar do tempo, a MLP (Goodfellow, 2016).

Assim como o cérebro humano, a RNA é capaz de organizar seus neurônios ou nodos com o intuito de realizar procedimentos de forma rápida, com o interesse focado em uma tarefa particular, suas partes são denominadas de funções de ativação, soma e pesos sinápticos (Delazzari, 2018), como pode ser visto na Figura 2.

Figura 2: Esquema de um neurônio artificial.



Fonte: Silva, Spatti e Flauzino, 2016.

O dados de entrada, representados por x_j , são o ponta pé inicial de um neurônio, eles são ligados a cada peso sináptico contidos nas camadas ocultas, w_{kj} , que são determinados durante o treinamento da RNA já a soma é responsável pelo somatório dos produtos entre os dados de entrada e os pesos sinápticos, u_k (Delazzari, 2018).

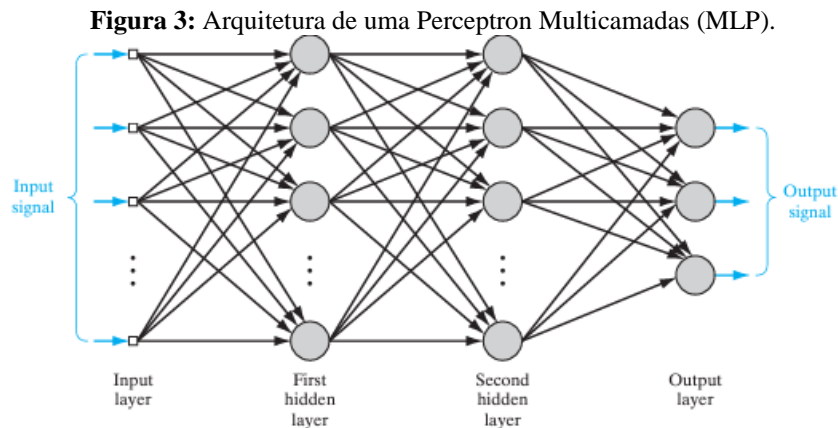
Ainda de acordo com o autor, a função de ativação, $g(\cdot)$, determina o valor de saída de um neurônio, por meio de funções matemáticas, como a linear, tangente hiperbólica, sigmoideal e

também a função limiar, as bias ou vies, b_k , são aplicados fora da somatória, com o poder de alterar os valores de resposta da soma para mais ou para menos, fazendo com que a RNA realize correções após a inserção dos dados de entrada e, por fim, a saída, que dependendo do modelo da rede, pode ser mais de uma, matematicamente, o funcionamento do neurônio se dá pelas Eq. 4 e 5.

$$\mathbf{u}_k = \sum_1^m \mathbf{w}_{kj} * \mathbf{x}_j \quad (\text{Eq. 4})$$

$$\mathbf{y}_k = \mathbf{g}(\mathbf{u}_k + \mathbf{b}_k) \quad (\text{Eq. 5})$$

As unidades estão organizadas em forma de camadas que são interligadas por meio de conexões sinápticas, onde há a entrada e a saída e também as camadas ocultas que são recebidas por cada neurônio presente na rede, a mais conhecida e simples técnica de redes neurais artificiais que possui esse esquema é a MLP (Figura 3), com duas fases de operação: aprendizagem e execução. Além disso é conhecida por resolver problemas de aproximação de funções, otimização e previsão (Haykin, 2008).



Fonte: Haykin, 2008.

A camada de entrada é aquela que recebe os referidos dados que a rede irá processar, onde cada neurônio presente nesta camada é correspondente a uma característica que foi imposta nos dados de entrada, pelo projetista, já as camadas ocultas são aquelas que realizam a parte mais complexa da rede, pois cada neurônio desta camada está ligado a camada de entrada e a camada de saída e cada uma dessas conexões possui um peso que são ajustados durante a fase de treinamento da máquina. Como o próprio nome já diz, na camada de saída é possível encontrar os resultados finais da rede, onde a quantidade de neurônios dessa camada corresponde ao número de respostas que a rede foi configurada para prever (Goodfellow, 2016).

De acordo com Jesus (2019), o algoritmo de atualização dos pesos sinápticos de uma MLP é o *Backpropagation*. Esse algoritmo tem em sua implementação a consideração de duas fases, a fase de propagação a diante (forward) e a propagação reversa (backward). Na propagação adiante, os sinais de entrada permanecerão inalterados na sua execução, propagando-se por todas as camadas até a saída da rede, sem mudança em seus pesos.

A reversa consiste em propagar o erro de cálculo da saída de volta para as camadas ocultas e de entrada por meio da rede, onde durante essa propagação, os gradientes da função de perda em relação a cada peso são calculados usando a regra da cadeia, então os pesos são ajustados na

direção oposta ao gradiente, usando o gradiente descendente, assim reduzindo o erro da rede (Jesus, 2019).

Uma vez que ocorre o treinamento da rede, ela se torna apta a cumprir com as tarefas que são programadas na sua interface, é importante ressaltar que o desempenho da rede neural só será proveitoso se a arquitetura de rede, o algoritmo implantado, o conjunto de dados na fase do treinamento e todas as suas camadas e neurônios forem bem especificados e interligados entre si, produzindo assim uma mínima soma dos erros, assim como a função imposta pela rede deseja (Assis, 2023).

Diante do exposto, uma RNA pode ser utilizada para minimizar impactos de erros, principalmente na área de estudo da Geotecnia. Em um estudo feito por Silveira (2014), as redes neurais artificiais foram utilizadas para relacionar o recalque de estacas isoladas e suas propriedades geométricas e também com os resultados obtidos por meio de ensaios SPT sobre a consistência do solo, com o uso do software QNET 2000, o resultado do coeficiente de correlação foi de 0,94 na fase de validação.

Ferreira (2010), utilizou RNA para estimar a capacidade de carga em estacas do tipo hélice contínua e pré-moldadas de concreto, e comparou com resultados obtidos por meio de métodos semiempíricos de Aoki-Veloso e Décourt-Quaresma, concluindo que com apenas quatro parâmetros de entrada e poucos neurônios na camada oculta a rede foi satisfatória.

4 MÉTODO

4.1 Método de pesquisa

Para determinar a capacidade de carga de uma fundação profunda, são utilizados métodos semiempíricos baseados em aproximação de modelos matemáticos, porém, nem sempre se obtém resultados precisos, por esse motivo o uso de RNA dentro da geotecnia vem crescendo cada vez mais, pois ela consegue resultados mais precisos que auxiliam no momento de executar uma fundação.

Com base nas discussões propostas por Minayo (2014), a pesquisa realizada neste trabalho pode ser classificada por sua metodologia como sendo explicativa, quanto ao seu objetivo, e também quantitativa e estatística quanto a sua abordagem, para coleta de dados foi utilizado procedimentos baseados em *ex-post facto*.

Para obter os resultados propostos neste trabalho, foram definidos dois tipos de variáveis, onde a primeira variável foi classificada como dependente, que é aquela onde ocorrerá a modelação para prever os valores que ela irá assumir quando não tiver informações acerca dela. Nesse estudo a variável dependente é a capacidade de carga.

A segunda variável consiste nas características que o usuário do modelo tem como disponível para elaboração do projeto, sendo ela independente, no caso desse trabalho, os dados para essa variável são obtidos dos valores de N_{SPT} e de suas respectivas profundidades.

4.2 Base de dados

Os dados utilizados como segunda variável para o processo de modelagem foram obtidos através de relatórios de ensaios SPT realizados na cidade de Balsas, no estado do Maranhão. De acordo com o IBGE (2022) o município está situado a 243 metros de altitude e tem as seguintes coordenadas geográficas: latitude: $-7^{\circ} 31' 59''$ S e longitude $46^{\circ} 2' 6''$ W e tem uma

população de 101.767 habitantes, e compreende uma área territorial de 13.141,637 km². A Figura 4 mostra a localização do município com relação ao Estado do Maranhão.

Figura 4: Localização do município.



Fonte: Google Maps®, 2024.

Os relatórios foram fornecidos pela empresa Y e tem como coordenadas os seguintes pontos identificados na Figura 5.

Figura 5: Pontos onde foram realizados os ensaios SPT.



Fonte: Google Earth®, 2024.

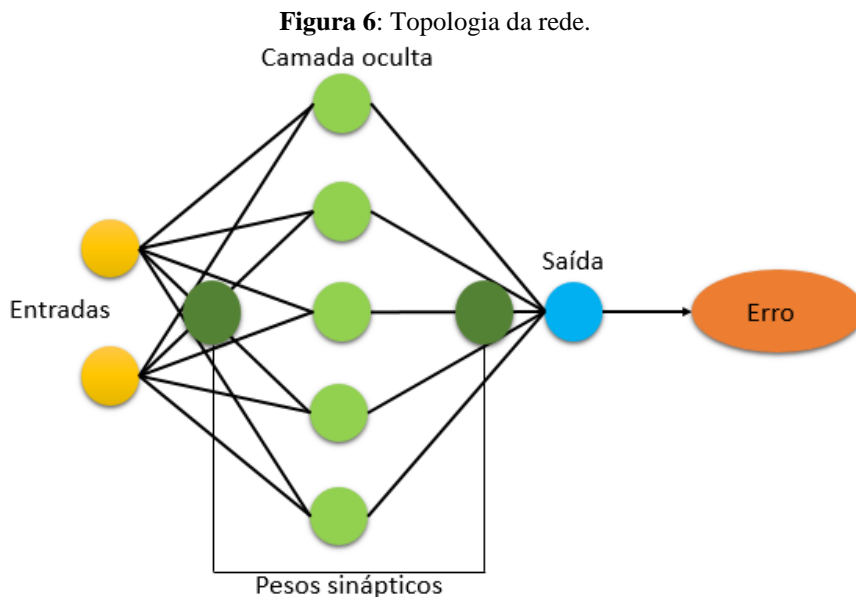
Portanto, ao analisar os 26 relatórios fornecidos pela empresa Y, constatou-se que em determinados ensaios ocorreram a perfuração de mais de um furo por coordenada, totalizando assim 68 furos, onde em cada profundidade de perfuração foi obtido um valor de N_{SPT} , utilizando assim esses dados para a modelagem da rede neural artificial.

4.3 Modelo utilizado

O modelo utilizado na rede foi realizado em três etapas: construção do algoritmo e escolha do tipo de RNA, treinamento e especificações das redes neurais artificiais e por fim, foi realizado o teste da rede.

O tipo de RNA escolhido depende do problema proposto pelo projetista, no caso do estudo em questão, a MLP foi escolhida para determinar os valores de capacidade de carga em fundações profundas. O algoritmo utilizado na rede foi o *Backpropagation*, que consiste em calcular o erro por meio de *forward* e *backward*.

As variáveis utilizadas para o cálculo da capacidade de carga foram: duas entradas, N_{SPT} e profundidade, uma camada oculta, variando entre 2 a 10 neurônios na camada oculta e uma saída correspondente ao valor da capacidade de carga. A Figura 6 mostra a topologia da rede e a fase de treinamento para a determinação dos valores de capacidade de carga.



Fonte: Autores, 2024.

Portanto, o valor previsto pela rede no decorrer de cada *loop* é então comparado com o valor medido. Como critério de parada da rede foi definido que se o erro de um *loop* for maior 10^{-7} que o erro de outro *loop*, se for diferente disso, a rede continua atualizando seus pesos sinápticos.

4.4 Métricas de avaliação

As métricas de avaliação do modelo consistem em análises das características estatísticas tanto na fase de teste quanto na fase de treinamento, elas são baseadas em avaliações através de testes de hipótese, correlação de Pearson e Raiz do Erro Quadrático Médio.

4.4.1 Raiz do erro quadrático médio

Após o cálculo dos valores pelas redes neurais artificiais, foi possível então, calcular a Raiz do Erro Quadrático Médio (RMSE), com base nos resultados da camada de saída e os valores reais. RMSE é matematicamente conhecido como está exposto na Eq. 6.

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (y_i - p_i)^2} \quad (\text{Eq. 6})$$

Onde:

- y_i é o valor previsto para a i -ésima observação;
- p_i é o valor observado para a i -ésima observação;
- n é o número de total de observações.

O RMSE é uma das métricas essenciais para a avaliação de modelos de previsão por RNA, fornecendo uma medida quantitativa da precisão de suas previsões. Em comparação com outras métricas, como o Erro absoluto médio (MAE), o RMSE é capaz de identificar e penalizar erros maiores (Hodson, 2022).

4.4.2 Correlação de Pearson

A correlação de Pearson foi utilizada para verificar se havia a ocorrência de linearidade entre os valores reais e os previstos. Ela é responsável por quantificar a força e a direção linear entre duas variáveis contínuas, a formula para calcular o coeficiente de correlação de Pearson (Eq. 7), é dado por:

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \quad (\text{Eq. 6})$$

- n é o número de pares de dados;
- x e y são as variáveis sendo comparadas;
- $\sum xy$ é a soma dos produtos dos pares de dados;
- $\sum x$ e $\sum y$ são as somas das variáveis individuais;
- $\sum x^2$ e $\sum y^2$ são as somas dos quadrados das variáveis individuais.

De acordo com Figueiredo Filho *et al.* (2014), a correlação varia entre -1 e 1, onde o sinal indica a sua direção e o valor a sua magnitude. Se o valor for mais perto de 1, a associação linear entre as variáveis é caracterizada como forte, se for mais próximo de zero, a associação é quase nula.

7 RESULTADOS E DISCUSSÕES

Um modelo computacional baseado em RNA, cuja finalidade é calcular a capacidade de carga a partir de dados de N_{SPT} e profundidade, foi proposto nesse artigo. Para cada simulação foram utilizados dados dos 68 furos. Cada furo com diferentes profundidades, compondo um total de 709 valores de capacidade de carga. Desse total 68 valores (aproximadamente 10%) foi, aleatoriamente, reservado para teste e o restante utilizado no treino do modelo.

A topologia da rede utilizada consta de uma camada de entrada, uma camada intermediária e uma camada de saída. Simulações foram realizadas para diferentes quantidades de neurônios da camada intermediária e diferentes valores para a taxa de aprendizado. Os resultados de treinamento e teste estão apresentados a seguir em gráficos e nas métricas de avaliação definidas anteriormente.


A topologia da rede utilizada tem a composição de três camadas, sendo: uma de entrada, uma de saída e uma camada oculta. Na primeira simulação foram utilizados 6 neurônios na camada oculta e uma taxa de aprendizado $\mu = 0,01$. Os resultados dessa simulação estão apresentados na Tabela 1 e no gráfico da Figura 7.

Tabela 1: Simulação com 6 neurônios.

Métrica	Valor
RMSE	1,94 kN
Correlação	0,93

Na Figura 7 é possível visualizar o quanto os valores estimados pelo modelo se aproximam dos valores desejados.

Figura 7: Fase de teste da rede 6 neurônios.



Fonte: Autores, 2024.


Para a segunda simulação, foi modificado o número de neurônios da camada oculta, fixando em 8 neurônios. Na Tabela 2 estão apresentados os valores de erro e correlação obtidos com essa topologia.

Tabela 2: Simulação com 6 neurônios.

Métrica	Valor
RMSE	2,00 kN
Correlação	0,93

Percebe-se que aumentando o número de neurônios da camada oculta o valor do erro obteve um leve aumento, no entanto a correlação permaneceu o mesmo valor. Na Figura 8 é possível observar uma comparação entre os valores obtidos pelo modelo e os reais.

Figura 8: Fase de teste da rede com 8 neurônios.



Fonte: Autores, 2024.

A fim de se ter uma visualização mais ampla das simulações, estão apresentados nas Tabelas 3 a 8 os valores de simulação para as diferentes taxas de aprendizado e número de neurônios da camada oculta. Inicialmente, fixou-se 2 neurônios na camada oculta e variou-se os valores para taxa de aprendizagem. Na Tabela 3 são apresentados os resultados dessas simulações.

Tabela 3: Resultados da rede com 2 neurônios.

Número de neurônios na camada oculta	Taxa de Aprendizagem	RMSE	Correlação
2	0,1	1,94211931	0,941788378
	0,2	2,09703424	0,904014988
	0,3	2,06777628	0,914820487
	0,4	2,4620696	0,906868907
	0,5	2,2755417	0,92114097
	0,6	2,29602668	0,92062478
	0,7	2,41789689	0,921329994
	0,8	1,91014049	0,955081479
	0,9	1,81110241	0,954929634
	1	3,33067794	0,913955275

Percebe-se que o melhor resultado quando o número de neurônios foi fixado em 2 é quando a taxa de aprendizagem utilizada foi de 0,9. Outra simulação foi realizada fixando-se 4 neurônios na camada oculta e variando-se os valores para taxa de aprendizagem. Na Tabela 4 os resultados dessa simulação estão apresentados.

Tabela 4: Resultados da rede com 4 neurônios.

Número de neurônios na camada oculta	Taxa de Aprendizagem	RMSE	Correlação
4	0,1	2,12920883	0,927012651
	0,2	1,54966102	0,950414351
	0,3	1,99730469	0,943785856
	0,4	1,80576442	0,939042062
	0,5	2,38794901	0,921268879
	0,6	1,88554196	0,933481299
	0,7	3,1582591	0,944415238
	0,8	3,44813794	0,933539309
	0,9	2,60068657	0,915437275
	1	2,40306136	0,899634558

Para 4 neurônios na camada oculta obteve-se como melhor resultado o uso de uma taxa de aprendizagem igual a 0,2. Seguindo a mesma metodologia de fixar a quantidade de neurônios na camada oculta e variar a taxa de aprendizagem, na Tabela 5 estão apresentados os resultados para 6 neurônios na camada oculta.

Tabela 5: Resultados da rede com 6 neurônios.

Número de neurônios na camada oculta	Taxa de Aprendizagem	RMSE	Correlação
6	0,1	1,70121848	0,953344514
	0,2	2,46477456	0,920706435
	0,3	2,06445471	0,9384334
	0,4	2,28858395	0,924912493
	0,5	2,74862754	0,876012368
	0,6	2,03397933	0,913573554
	0,7	2,90541789	0,915521827
	0,8	2,73197701	0,931875275
	0,9	2,25870292	0,930770002
	1	3,99954007	0,90787199

Para 6 neurônios na camada oculta o melhor resultado foi obtido quando a taxa de aprendizagem foi de 0,1. Na penúltima simulação fixou-se oito neurônios na camada oculta. Na Tabela 6 estão apresentados para essa simulação.

Tabela 6: Resultados da rede com 8 neurônios.

Número de neurônios na camada oculta	Taxa de Aprendizagem	RMSE	Correlação
8	0,1	2,65040869	0,904444848
	0,2	2,2351627	0,911829876
	0,3	2,08928934	0,93844497
	0,4	2,17904337	0,924965393
	0,5	2,67351468	0,88643435
	0,6	2,33760268	0,912957167
	0,7	3,75295424	0,894947321

0,8	2,14574767	0,931255397
0,9	3,57288427	0,925948839
1	4,18216093	0,868132723

Com 8 neurônios na camada oculta o melhor resultado foi alcançado com uma taxa de aprendizagem de 0,3. Por fim, foi feita uma simulação para 10 neurônios na camada intermediária. Os resultados para esse grupo de simulação estão apresentados na Tabela 7.

Tabela 7: Resultados da rede com 10 neurônios.

Número de neurônios na camada oculta	Taxa de Aprendizagem	RMSE	Correlação
10	0,1	2,47489422	0,91510898
	0,2	4,31178155	0,947399929
	0,3	1,98704772	0,90597883
	0,4	2,30947364	0,898714947
	0,5	1,89046129	0,942592974
	0,6	2,10081816	0,959191648
	0,7	2,65189015	0,91694354
	0,8	5,59881005	0,89008605
	0,9	5,15250675	0,900390976
	1	3,35600769	0,875248464

Com 10 neurônios na camada intermediária o melhor resultado obtido foi com a taxa de aprendizagem fixada em 0,5. De modo geral, dentre todas as simulações apresentadas, o melhor resultado foi obtido quando foi fixado quatro neurônios na camada oculta e 0,2 como taxa de aprendizagem (RMSE = 1,54 e correlação igual 0,95), como exposto na Tabela 8.

Tabela 8: Resultado das simulações.

Número de neurônios na camada oculta	Taxa de Aprendizagem	RMSE	Correlação
2	0,9	1,81110241	0,954929634
4	0,2	1,54966102	0,950414351
6	0,1	1,70121848	0,953344514
8	0,3	2,08928934	0,93844497
10	0,5	1,89046129	0,942592974

8 CONCLUSÕES

As fundações profundas, em geral, dependem de um bom projeto e cálculos precisos quanto ao esforço que irá suportar, todavia, ao utilizar métodos semiempíricos para calcular sua capacidade de carga são necessárias inúmeras variáveis, por outro lado, para o cálculo dessa capacidade por meio de RNA, se faz necessário o uso de apenas duas variáveis.

A fim de determinar os valores dessas capacidades de cargas para diferentes ensaios SPT feitos na cidade de Balsas-MA, foram utilizados nesse trabalho redes neurais artificiais, do tipo MLP, que para apresentar os resultados foram utilizadas métricas estatísticas de avaliação, como RMSE e correlação de Pearson.

Nesse contexto, o modelo neural passou por diversos teste com a quantidade de neurônio na camada oculta variando de 2 a 10, e o o melhor resultado foi obtido quando foi fixado quatro neurônios na camada oculta e 0,2 como taxa de aprendizagem $RMSE = 1,54$ e correlação de Pearson igual a 0,95.

Esse resultado demonstra que a utilização de RNA pode ajudar na determinação dos valores de capacidades de carga em fundações profundas, porém se o banco de dados fosse maior, o estudo poderia chegar em resultados mais eficazes, melhorando assim o modelo afim de alavancar o seu uso dentro da construção civil para esse tipo de cálculo.

Além disso, o estudo colabora para que ocorram novas investigações quanto aos relatórios SPT fornecidos, por meio deles é possível utilizar modelos de redes neurais artificiais para calcular a distância entre os pontos em estudo e também comparar os resultados obtidos por meio da rede com resultados de capacidade de carga calculados através dos métodos semiempíricos presentes na literatura.