

# DESENVOLVIMENTO DE MODELOS NEURAIIS PARA AUXILIAR PROJETOS DE PAVIMENTOS NO ESTADO DO CEARÁ

DEVELOPMENT OF NEURAL MODELS TO ASSIST FLOORING PROJECTS IN THE STATE OF CEARÁ

FRANCISCO CARLOS HENRIQUE PIO DE OLIVEIRA  
*Univ. Fed. do Ceará, Fortaleza, Ceará, Brasil franciscocarlosipo@gmail.com*

CARLA BEATRIZ COSTA DE ARAÚJO  
*Univ. Fed. do Ceará, Fortaleza, Ceará, Brasil carlabeatriz@ufc.br*

SUELLY HELENA DE ARAÚJO BARROSO  
*Univ. Fed. do Ceará, Fortaleza, Ceará, Brasil suelly@det.ufc.br*

ANTONIO JÚNIOR ALVES RIBEIRO  
*Univ. Fed. do Ceará, Instituto Federal de Educação, Ciência e Tecnologia do Ceará junior.ribeiro@ifce.edu.br*

## RESUMO ABSTRACT

O conhecimento geológico desempenha um papel essencial no planejamento e na execução de obras de pavimentação. Através do avanço com uso das redes neurais artificiais foi possível obter resultados significativos nos estudos de caracterização geológica-geotécnica de pavimentos, oferecendo uma abordagem inovadora para compreender as propriedades geotécnicas do solo subjacente às estradas e vias. A modelagem neural, quando há disponibilidade de dados em quantidade e qualidade adequados possibilita a previsão de uma variedade de características geotécnicas dos solos, podendo ser uma opção de estimativa mais econômica e complementar em relação à obtenção tradicional de dados por meio apenas de ensaios de laboratório de Módulo de Resiliência necessários para projeto de pavimentos. O objetivo principal deste trabalho é desenvolver modelos neurais, por meio do uso de inteligência artificial para serem aplicados em projetos de pavimentação no Estado do Ceará. Para isso, foram levantados bancos de dados contendo informações geotécnicas de pavimentos do Estado do Ceará. Ao total os bancos de dados contém mais de um mil dados abrangendo informações de propriedades físicas do solo, Califórnia Bearing Ratio e classificação AASHTO. Todos estes dados são oriundos do projeto da Universidade Federal em parceria

Geological knowledge plays an essential role in the planning and execution of paving works. Through advancements in artificial neural networks, significant results have been achieved in geological-geotechnical characterization studies of pavements, offering an innovative approach to understanding the geotechnical properties of the soil underlying roads and highways. Neural modeling, when adequate quantity and quality of data are available, enables the prediction of various soil geotechnical characteristics, potentially serving as a more economical and complementary option compared to the traditional acquisition of data solely through laboratory tests of Resilience Modulus necessary for pavement design. The main objective of this work is to develop neural models using artificial intelligence to be applied in pavement projects in the State of Ceará. For this purpose, databases containing geotechnical information of pavements in the State of Ceará were collected. In total, the databases contain over a thousand records covering soil physical properties, California Bearing Ratio, and AASHTO classification information. All this data comes from projects at the Federal University in partnership with the National Department of Transportation Infrastructure. Through the use of Artificial Neural Networks, neural models were developed to predict Resilience Modulus values,

com o Departamento Nacional de Infraestrutura de Transportes. Através da utilização de Redes Neurais Artificiais foi possível desenvolver modelos neurais para previsão de valores de Módulo de Resiliência, a maior parte desses modelos atingiu valores de correlação acima de 0,7, sugerindo uma relação significativa entre as variáveis utilizadas para estimar valores de Módulo de Resiliência. O modelo mais representativo teve um valor de 0,86. Isso destaca a promissora facilidade e aplicabilidade dos modelos neurais na previsão do Módulo de Resiliência para o dimensionamento empírico e empírico-mecânico de pavimentos.

**Palavras-chave:** Redes Neurais Artificiais. Módulo de resiliência.

## 1. INTRODUÇÃO

O conhecimento geológico é essencial para a caracterização precisa dos materiais presentes em solos e rochas, desempenhando um papel estratégico no planejamento e desenvolvimento de projetos. Essa abordagem permite otimizar o uso dos recursos naturais, promovendo soluções sustentáveis e minimizando impactos ambientais negativos (Lima, 2022). Aprimorar ou modificar as condições naturais do solo para adaptação das necessidades de projetos de construções tem sido uma prática antiga, que muitas vezes resulta em redução de custos e outros benefícios tangíveis. Atualmente existem várias técnicas de melhoramento do solo abrangendo tratamentos rasos, médios e profundos do solo envolvendo drenagem, reforço, voltados a geotecnia, dependendo da construção e necessidades do projeto (Correia et al. 2016).

A geotecnia é essencial em projetos de transporte, pois a estabilidade do solo determina a segurança e durabilidade das obras. Uma caracterização adequada evita falhas estruturais e reduz impactos ambientais, prevenindo desastres relacionados a erros de análise geotécnica (Santos et al., 2020; Costa et al., 2020). Ao realizar levantamentos geológico-geotécnicos, é possível elaborar cartas geotécnicas que disponibilizam informações valiosas sobre a resistividade e a estabilidade do solo nas áreas projetadas para construção

with most of these models achieving correlation values above 0.7, suggesting a significant relationship between the variables used to estimate Resilience Modulus values. The most representative model had a value of 0.86. This highlights the promising ease and applicability of neural models in predicting Resilience Modulus for empirical and empirical-mechanistic pavement design.

**Keywords:** Artificial Neural Networks. Resilience Module.

(Silveira e Reis, 2021). Países em desenvolvimento, como Brasil e Índia, no qual a grande parte do escoamento da produção e transporte de pessoas é realizado através das rodovias, esse papel é ainda mais significativo (Alves e Santarem, 2015; India, 2018).

A maioria das rodovias brasileiras possui revestimento asfáltico apoiado sobre o subleito natural e camadas de solo compactado, como base e sub-base. A geotecnia desempenha um papel essencial nessas estruturas, pois as propriedades geométricas, físicas, mecânicas e químicas dos materiais utilizados influenciam diretamente seu desempenho (Correia et al. 2021). Assim, análises geológico-geotécnicas são essenciais em contextos de desenvolvimento de infraestruturas. Estas análises contribuem para uma compreensão mais clara das condições do solo e do subsolo, prevenindo problemas que poderiam surgir devido a condições geológicas desfavoráveis (Santos et al. 2020; Costa et al. 2020).

O Brasil adota predominantemente uma abordagem empírica para o dimensionamento de pavimentos flexíveis, com um método cuja origem remonta à década de 1960 (Ferreira, 2021). O CBR, que se fundamenta na relação entre a resistência do solo e a pressão aplicada, facilita decisões iniciais sobre a adequação dos materiais a serem utilizados e a configuração do pavimento (Silva et al. 2023). Sua fundamentação empírica, no entanto, limita a precisão do método, já que não abrange

a complexidade de condições variáveis de carregamento e características dos materiais modernos (Cardozo et al. 2023). Entre as deficiências desse ensaio ressalta-se que o CBR não representa o efeito real das cargas no pavimento, uma vez que não considera as tensões de confinamento e não leva em consideração a aplicação dinâmica das cargas, ocasionada pelos veículos em movimento (Nguyen et al. 2016). Além disso, esse método também não acompanha os avanços ocorridos na caracterização de materiais e apesar da relevância que desempenhou em seu início até os dias atuais, percebe-se que novos parâmetros e análises devem ser adotados incorporando características elásticas e resistivas sob diferentes condições ambientais (Mello et al. 2021).

A realização do dimensionamento de estruturas de pavimentos asfálticos é um processo complexo, que precisa do conhecimento de variáveis de difícil previsão e modelagem. Em decorrência da dificuldade ainda presente, foi desenvolvida diversos estudos voltados à elaboração de métodos mais modernos e analíticos de dimensionamento de pavimentos asfálticos, com objetivo de minimizar cada vez mais o alto teor de empirismo ainda existente nas metodologias utilizadas. Tais estudos deram origem aos métodos chamados mecanístico-empíricos (Pitangui, 2019).

O método mecanístico-empírico surge como uma alternativa mais robusta ao tradicional método baseado no CBR, pois considera de forma mais abrangente os efeitos das tensões e deformações nos pavimentos, permitindo uma previsão mais precisa do desempenho estrutural ao longo do tempo (Silva e Santos, 2021). Nesse contexto, o módulo de resiliência (MR) desempenha um papel fundamental, sendo um dos principais parâmetros utilizados para avaliar o comportamento dos solos sob carregamento do tráfego (Ribeiro et al. 2016). Além disso, a utilização do MR possibilita testar diferentes combinações de materiais em condições reais, permitindo ajustes mais eficientes na engenharia de pavimentos (Rocha et al. 2021). Assim, ao incorporar fatores como volumes de tráfego e características climáticas, o dimensionamento mecanístico-empírico amplia a precisão das análises e otimiza o desempenho das rodovias (Cardozo et al. 2023).

Apesar da utilização do Módulo de Resiliência apresentar diversos ganhos ao dimensionamento de pavimentos, em alguns casos, este método pode apresentar algumas desvantagens, entre as quais destacam-se: necessidade de maior conhecimento dos técnicos para a realização dos ensaios, normalmente com equipamentos que são onerosos com disponibilidade limitada (Sas et al. 2015; Mehrpazhouh et al. 2019). Ensaios que são mais usuais, como o índice California Bearing Ratio, possuem maior facilidade de serem realizados em maior quantidade de laboratórios, justamente por serem testes mais simples. Para a realização do ensaio do módulo de resiliência são necessárias câmaras destinadas ao ensaio triaxial de cargas repetidas que consistem em um aparato relativamente sofisticado, o que dificulta, ou até mesmo inviabiliza, o seu deslocamento e a sua utilização fora de locais adequados (Ribeiro, 2016).

No Brasil, a disponibilidade de equipamentos triaxiais de carga repetida é limitada, estando grande parte concentrada em instituições acadêmicas. Diante dessa restrição e da necessidade de estimativas do módulo de resiliência (MR) para o dimensionamento mecanístico-empírico de pavimentos, os modelos de Redes Neurais Artificiais (RNA) surgem como uma alternativa viável (Oliveira, 2024). As redes neurais artificiais (RNAs) têm se consolidado como uma ferramenta computacional essencial, inspiradas nos princípios do funcionamento do cérebro humano. Elas são projetadas para simular a forma como os neurônios biológicos processam informações, permitindo a aprendizagem a partir de exemplos, além de serem capazes de reconhecer padrões e generalizar informações baseadas em dados de entrada (Maciel et al. 2023). Essa aptidão faz com que as RNAs sejam aplicadas em uma variedade de domínios, como previsão de demanda, diagnósticos em saúde, análise financeira, entre outros setores (Caires e Simonelli, 2021). As RNAs são técnicas, amplamente utilizadas para solução de problemas não lineares e que se aplicam para diversas áreas do conhecimento, inclusive a engenharia rodoviária, com resultados satisfatórios (Celeste et al. 2019).

Diversos trabalhos recentes têm investido na aplicação de Redes Neurais Artificiais (RNA) para prever o módulo de resiliência em diferentes

contextos. De acordo com o estudo realizado por Oliveira (2024), a aplicação de redes neurais na previsão de propriedades geotécnicas demonstrou resultados promissores. Utilizando um extenso banco de dados geotécnicos com mais de oito mil registros, a modelagem neural possibilitou prever valores de CBR e módulo de resiliência (MR) com coeficientes de correlação superiores a 0,70, alcançando 0,98 para CBR e 0,86 para MR. Em estudo realizado por Cabral et al. (2022) a Deformação Permanente (DP) e o Módulo de Resiliência (MR) de solos utilizados em pavimentos foram analisados por métodos mecanístico-empíricos e empíricos. Ensaio triaxiais de carga repetida (RLT) foram aplicados, e a modelagem foi realizada pelos métodos MeDiNa e CAP 3D-D. O uso de RNA teve destaque, cujo desenvolvimento demonstrou grande capacidade na geração de parâmetros para modelos de predição da DP nos solos estudados. Na análise conduzida por Carmo e Marques (2021) promoveu a comparação de dados reais com as previsões de RNA, evidenciando a eficácia desse método em prever o módulo de resiliência em misturas experimentais, o que constitui um avanço significativo na área de dimensionamento de pavimentos. Em investigação realizada por Paz et al. (2020) foi utilizado as redes neurais para identificar defeitos em rodovias do Estado do Ceará e foi obtido uma acurácia de 80% em seus resultados.

Este trabalho pretende contribuir para o estudo do comportamento mecânico dos solos no Estado do Ceará, por meio de estimativas de Módulo de Resiliência. Para tal, utilizou-se como ferramenta principal as RNAs, que possibilitou realizar estimativas de MR a partir de resultados de ensaios básicos, de tal forma que se possa contribuir para facilitar a utilização de métodos de dimensionamento mecanístico-empírico de pavimentos, além de ser uma alternativa para reduzir custos e tempo de operação de ensaios mais complexos.

## 2. OBJETIVO

Criar modelos de redes neurais artificiais para previsão de propriedades geológico-geotécnicas para aplicações em projetos de pavimentos no Estado do Ceará.

## 3. METODOLOGIA

Esta pesquisa foi desenvolvida no estado do Ceará, situado no Nordeste do Brasil entre meridianos 37° 14' 54" e 41° 24' 45" de longitude a oeste de Greenwich e 2° 46' 20" e 7° 52' 15" de latitude Sul. Possui extensão territorial de 146.016 km<sup>2</sup> e divide-se, atualmente, em 184 municípios. A metodologia proposta para este estudo compreende o desenvolvimento de modelos neurais para previsão de propriedades geotécnicas (MR). Os modelos de redes neurais artificiais seguiram as seguintes etapas: os procedimentos iniciais envolveram a realização do levantamento e análise do banco de dados geotécnicos de pavimentos no Estado do Ceará, posteriormente foram criados os modelos de previsão de MR para o Estado do Ceará. A figura 1 mostra o fluxograma das etapas desta pesquisa.



**Figura 1:** Estruturação das fases da pesquisa

Fonte: Autores

Os dados utilizados para os modelos fazem parte do Projeto da Universidade Federal do Ceará com o DNIT, denominado Pesquisa, Treinamento e Acompanhamento Técnico de Pavimentos Asfálticos Nacionais, sendo especificamente desenvolvido no Subprojeto 2 - Plataforma integrada de estruturação e análise de dados com uso de Inteligência Artificial. Além dos dados provenientes de 47 projetos de rodovias federais (BRs) arquivados no acervo de projetos do DNIT/CE, a equipe do Subprojeto 2 realizou a aquisição de estudos geotécnicos adicionais de projetos rodoviários municipais e estaduais. Essa iniciativa visava enriquecer a base de dados disponível. Nesse contexto, foram obtidos dados de vários trechos de projetos em diversas rodovias, incluindo a CE-085, CE-040, CE-010, CE-155, CE-153, CE-187, CE-388, CE 292 e a Rodovia Aracati - Canoa Quebrada.

Inicialmente o banco de dados fornecido continha o total de 1342 dados de entrada-saída contendo as informações de percentuais de solo passantes nas peneiras (1", 3/8", #4, #10, #40, #200), classificação da American Association of State

Highway and Transportation Officials (AASHTO), Limite de Liquidez (LL), massa específica seca máxima ( $\gamma_{dmax}$ ), umidade ótima ( $o_t$ ), California Bearing Ratio (CBR), tensão confinante ( $\sigma_3$ ), tensão desvio ( $\sigma_d$ ) e Módulo Resiliência (MR). A escolha desses parâmetros para alimentação dos modelos neurais foi baseada na relevância para a previsão do MR. Esses parâmetros são fundamentais para entender o comportamento mecânico dos solos e sua capacidade de resistir a cargas. Todos esses dados foram usados para criação dos modelos. Foram retirados do banco de dados, aleatoriamente 268 exemplos, usados na fase de validação dos modelos, que corresponde a 20% do conjunto e 1073 exemplos utilizados para treinamento, que corresponde a 80% dos dados. Ao total foram criados 6 modelos diferentes, variando-se os dados de entradas e arquiteturas para cada modelo, sendo o Módulo de Resiliência comum a todos como dado de saída. A distribuição geográfica dos pontos de coleta desses dados é apresentada na Figura 2.

Para a criação dos modelos de previsão das variáveis de Módulo de Resiliência foi empregado como ferramenta as Redes Neurais Artificiais, foi utilizado o software QNET 2000, em sua versão

demo. O QNET é um programa perceptron multicamadas que utiliza o algoritmo de retropropagação do erro para o treinamento da rede neural artificial. O programa admite até oito camadas intermediárias de neurônios e a escolha entre quatro funções distintas de ativação (sigmóide, gaussiana, secante hiperbólica e tangente hiperbólica (Dantas Neto, 2004). Em geral, não há regras para a escolha da função de ativação a ser empregada no modelo de redes neurais, a escolha da função mais adequada é feita por tentativas e erros, ou seja, a que apresentar resultado mais satisfatório, nesta pesquisa a função que melhor apresentou resultados foi a função sigmóide, a equação dessa função é apresentada a seguir:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

Onde

$\sigma(x)$ : Representa a saída da função sigmóide, um valor entre 0 e 1.

$x$ : Representa a entrada da função, que pode ser qualquer valor real.

$e^{-x}$ : É a base do logaritmo natural

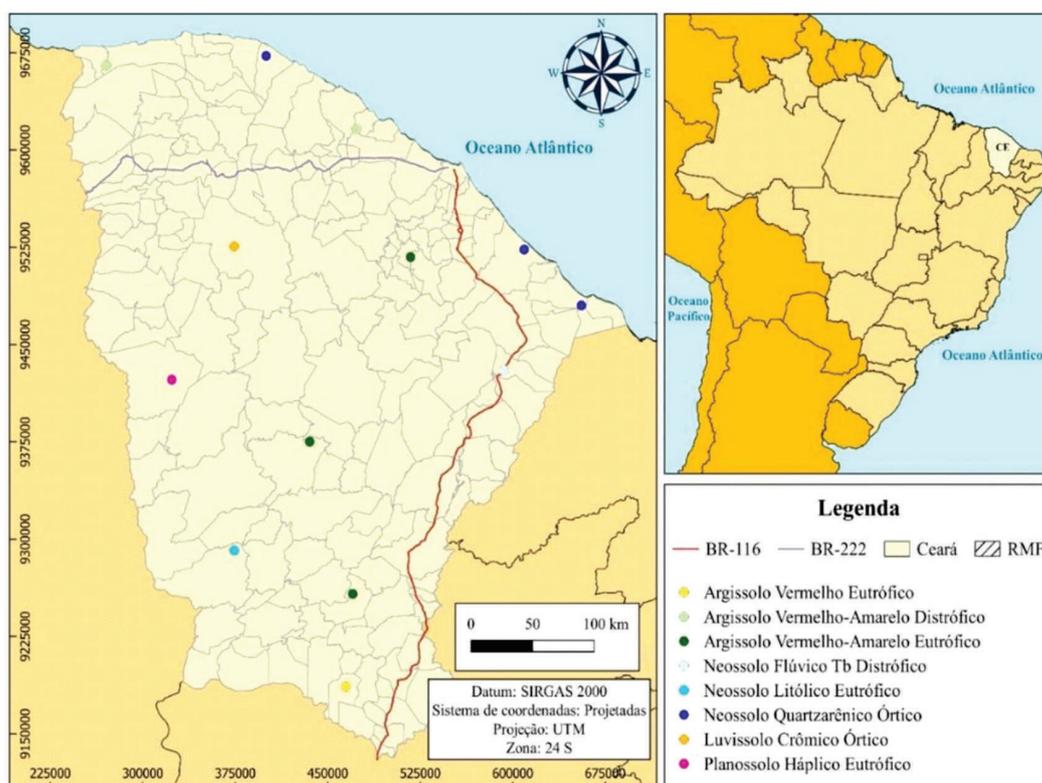


Figura 2: Localização do estado do Ceará e dos pontos de coleta do Módulo de Resiliência

Fonte: Elaborado pelos autores.

O QNET 2000 proporciona a modelagem por duas fases: treinamento e validação. Para realização do treinamento é necessário escolher dois parâmetros para ajustar os pesos sinápticos  $w_{kj}$ :  $\eta$  (taxa de aprendizagem) que afeta no processo de convergência do algoritmo de retropropagação dos erros; e o fator  $\alpha$  (momentum), que diminui a fragilidade do algoritmo durante essa convergência. Estes parâmetros manipulam o algoritmo de retropropagação na regulagem dos pesos sinápticos ( $w_{kj}$ ). O fator  $\alpha$  correlaciona-se com a estabilidade do algoritmo de retropropagação, geralmente adotado entre 0,8 e 0,9 (Dantas Neto, 2004). Neste trabalho adotou-se os valores de 0,8 para o fator  $\alpha$  e para a taxa de aprendizagem  $\eta$  variando entre 0,001 e 0,15. Dessa forma de adoção de  $\eta$  permite que o programa otimize os valores aprendizagem fazendo-se a fase de treinamento com maior rapidez e minimizando o risco de não convergência numérica Araújo (2015).

O programa QNET 2000 admite a mudança desses parâmetros a qualquer momento da fase de treinamento melhorando a eficiência, porém neste trabalho apenas o valor de  $\eta$  foi variado dentro de uma faixa determinada durante o treinamento e o fator  $\alpha$  foi mantido constante. Antes de iniciar a fase de treinamento foi feito o tratamento dos dados, para tal, realizou-se a normalização das variáveis. É necessária esta normalização, tendo em vista que, as diferentes funções de ativação que realizam o cálculo dos neurônios fornecem valores dentro de um intervalo. Essa etapa também pode ser realizada no próprio programa, mas

apresenta desvantagens pois omite informações dos dados de entrada impedindo a implementação do modelo em planilhas de cálculo (Dantas Neto, 2004).

Inicialmente os dados oriundos dos ensaios geotécnicos passaram por um pré-processamento para que se adequassem às restrições impostas pela modelagem neural no QNET 2000. Esse procedimento foi realizado da seguinte forma: numerização e normalização dos dados. A numerização compreendeu em se atribuir um valor decimal aos dados que possuem valores alfanuméricos (variáveis qualitativas) proveniente de ensaios geotécnicos de laboratório como: o Índice de Plasticidade (IP), o Limite de Liquidez (LL) e a Classificação da AASHTO, esta etapa foi realizada para todos os modelos, abaixo é apresentado uma tabela de exemplo desta etapa. A Tabela 1 apresenta um exemplo de numerização dos dados alfanuméricos.

Após numerização dos dados foi realizada a normalização, no qual consiste em transformar os valores decimais em valores limitantes de uma determinada função. Os valores dos dados de entrada e saída foram normalizados entre 0,15 e 0,85, considerando uma relação linear entre os valores de mínimos e máximos de cada uma das variáveis ligadas utilizando a Equação 1. A Tabela 2 mostra os valores máximos e mínimos das variáveis de Módulo de Resiliência. Na Tabela 3, é possível observar um exemplo de normalização dos dados com todos os resultados dos ensaios em valores decimais e em valores normalizados.

**Tabela 1:** Exemplo da numerização dos dados

Variável	Dados Alfanuméricos	Numerizado
LL	NP	0
IP	NP	0
Classificação AASTHO	A-1-A	1,1
	A-1-B	1,2
	A-2-4	2,4
	A-2-6	2,6
	A-3	3
	A-4	4
	A-6	6

Fonte: Elaborado pelos autores.

**Tabela 2:** Valores máximos e mínimos das variáveis envolvidas na modelagem com utilização das redes neurais artificiais para Módulo de Resiliência

DADOS DE ENTRADA	MÁXIMO	MÍNIMO
OT (%)	17	4,2
DEN (g/cm <sup>3</sup> )	2,19	1,65
CBR (%)	114	3,8
EXP (%)	5	0
LL (%)	46	0
IP (%)	16,7	0
25,4 (#1")	100	80
9,5 (#3/8")	100	40
4,76 (#10)	100	22
2 (#10)	100	18
0,42 (#40)	89	14
0,0074 (#200)	71	5
σ <sub>3</sub>	0,137	0,021
σ <sub>d</sub>	0,412	0,021
CLASIFICACÃO AASHTO	7,5	1,1
DADO DE SAÍDA MR	2038	50,069

Fonte: Elaborado pelos autores.

**Tabela 3:** Exemplo de normalização dos dados de MR

Variável	Valor Decimal	Valor Normalizado
OT (%)	14,92	0,74
DEN (g/cm <sup>3</sup> )	1,93	0,51
CBR (%)	14	0,21
EXP (%)	5	0,85
LL (%)	35	0,68
IP (%)	5,7	0,39
25,4	100	0,85
9,5	96	0,79
4,76	94	0,78
2	92	0,67
0,42	70	0,52
0,074	40	0,85
Classificação AASHTO	4	0,85
σ <sub>3</sub>	0,137	0,46
σ <sub>d</sub>	0,412	0,26
MR	385	0,85

Fonte: Elaborado pelos autores.

$$\frac{X' - 0,15}{0,85 - 0,15} = \frac{X - X_{MIN}}{X_{MAX} - X_{MIN}} \tag{1}$$

Onde:

X' = Variável resultante da normalização;

X = Variável a ser normalizada;

X<sub>MIN</sub> = Valor mínimo da variável a ser normalizada;

X<sub>MAX</sub> = Valor máximo da variável a ser normalizada.

Foi realizado o teste com várias arquiteturas distintas, alterando o número de camadas, ou de neurônios em função dos resultados obtidos na fase de treinamento e validação. O critério para interromper ou pausar a modelagem baseou-se na observação do comportamento dos valores de correlação durante as fases de treinamento e validação. Se, em qualquer ponto do processo de modelagem, os valores de correlação caírem abaixo do limite de 0,70, a respectiva modelagem é descartada. Posteriormente, um novo modelo com maior número de iterações é construído, até atingir um valor de correlação igual ou superior a 0,70. A seleção do modelo mais eficiente foi baseada nos valores do coeficiente de determinação ( $R^2$ ) e na redução do número de parâmetros de entrada. As estimativas do módulo de resiliência foram obtidas considerando  $\sigma_3 = 0,051$  MPa e  $\sigma_d = 0,103$  MPa.

### 3. RESULTADOS E DISCUSSÕES

Para as previsões do MR, inicialmente, foram desenvolvidos seis modelos distintos, alternando as variáveis de entrada e o número de neurônios na camada intermediária de cada modelo. Os resultados dos diferentes modelos dessas estimativas foram organizados de forma a possibilitar sua interpretação e análise. Para alguns modelos (M2, M5 e M6) foram testadas várias arquiteturas até atingir valores de coeficiente de correlação na validação acima de 0,7. Ao longo das fases de treinamento e validação, o programa QNET2000 concede várias informações, entre elas estão os valores das correlações entre os valores calculados e os medidos, que serão denominadas de  $R_t$  para o treinamento e  $R_v$  para a validação. Além disso, o programa também fornece informações relevantes acerca da influência relativa de cada variável de entrada nos modelos desenvolvidos,

expressa em termos de percentual de contribuição. Essa funcionalidade permite identificar quais propriedades exercem maior impacto na predição do MR, auxiliando na interpretação e aplicação prática dos modelos.

De posse dessas informações correspondentes aos modelos M2, M5 e M6 desenvolveu-se gráficos que abrangem como se deu a evolução dos valores de correlação para o treinamento e validação com o número de iterações. Na Tabela 4 são indicados os valores de correlação para as etapas de treinamento e validação dos modelos neurais desenvolvidos, além das arquiteturas de rede.

**Tabela 4:** Valores das correlações de acordo com cada modelo de MR

Modelo	Arquitetura	Correlação Treinamento	Correlação Validação
M1	A:15-17-15-10-9-1	0,98	0,92
M2	A:11-15-7-5-1	0,88	0,73
M3	A:10-14-5-3-1	0,97	0,86
M4	A:7-15-5-5-1	0,98	0,88
M5	A:7-15-11-9-5-1	0,98	0,86
M6	A:13-15-14-13-11-8-1	0,93	0,73

Fonte: Elaborado pelos autores.

O modelo M1 para estimação individual do MR apresentou as seguintes camadas de entradas: OT, DEN, CBR, EXP, LL, IP, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class. O Gráfico 1 mostra a comparação entre os valores de correlação obtidos para esse modelo. A variável de maior influência para o modelo M1 pertence às faixas granulométricas e percentual que passa na peneira de 0,042mm com 13,63% seguido do percentual que passa na peneira 0,074mm com 12,44% e umidade ótima com 11,33%. Para este modelo a variável de menor impacto foi a classificação AASHTO. Os percentuais de contribuição das variáveis estão apresentados no Gráfico 2.

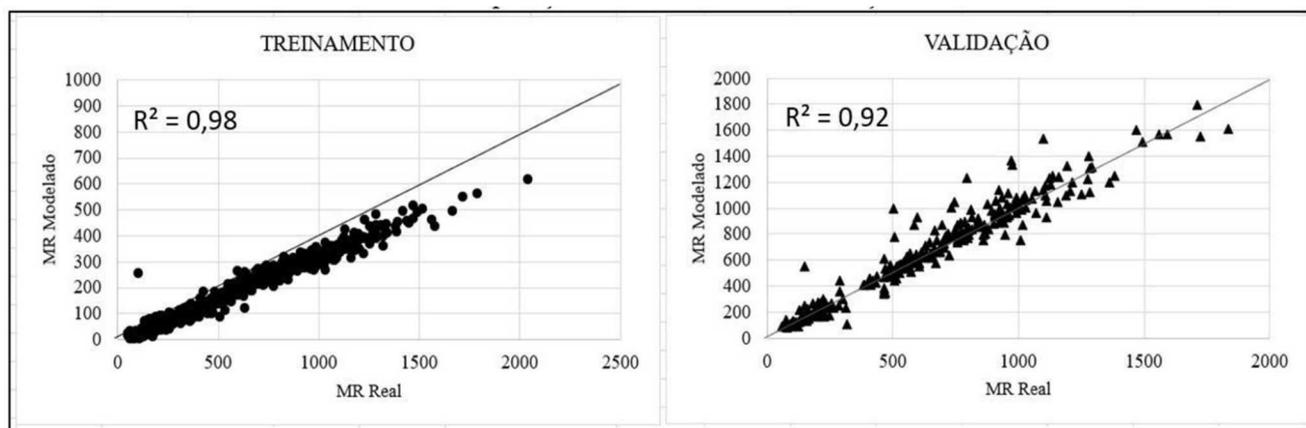


Gráfico 1: Comparação do treinamento e validação do modelo M1

Fonte: Elaborado pelos autores.

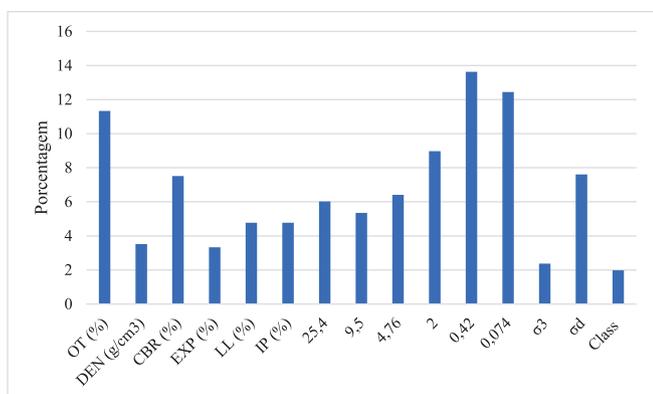


Gráfico 2: Percentual de contribuição das variáveis de entrada do modelo M1

Fonte: Elaborado pelos autores.

O modelo M2 para estimativa individual do MR utilizou como dados de entrada as seguintes

variáveis: DEN, CBR, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074), σ3, σd e Class. O Gráfico 3 mostra os valores de correlação e o comparativo entre os valores reais e os modelados nas fases de treinamento e validação. Comparando o número de iterações nas fases de treinamento e validação, o maior valor de correlação para a validação foi obtido com dez mil iterações (Gráfico 4). Quanto ao percentual de contribuição a variável de maior influência para o modelo M2 foi a densidade com 25,64% seguido da classificação AASHTO com 14,18% e a tensão confinante com 10,37%. Para este modelo a variável de menor impacto foi o percentual que passa na peneira de 2mm. Os percentuais de contribuição das variáveis estão apresentados no Gráfico 5.

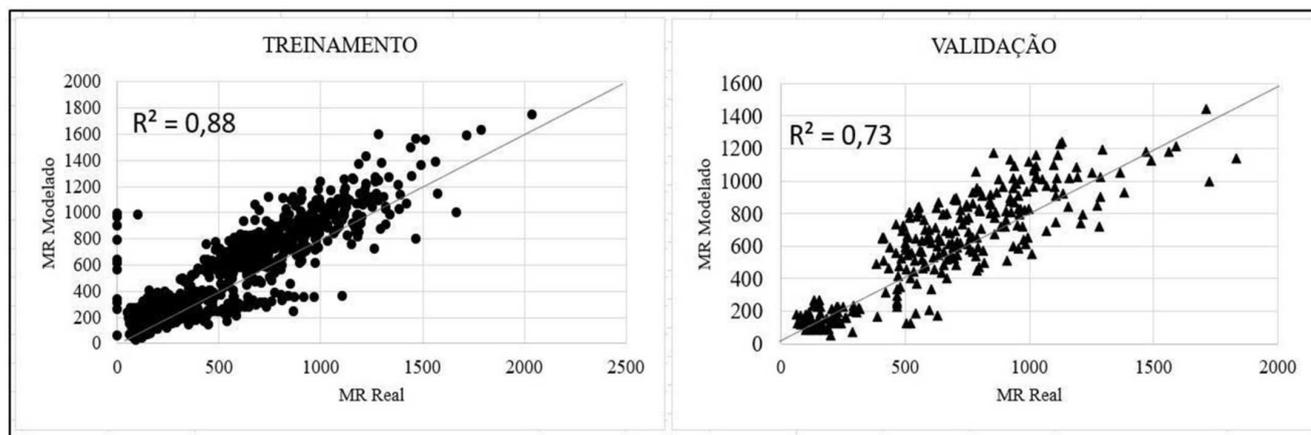
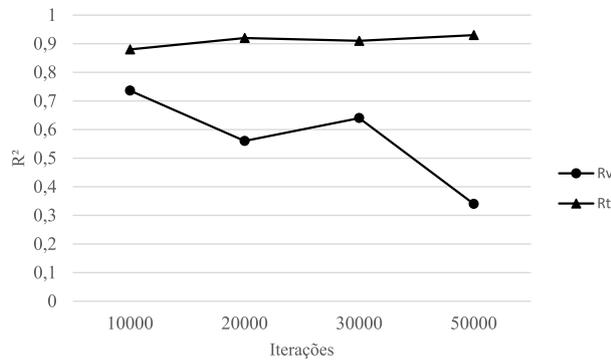


Gráfico 3: Comparação do treinamento e validação do modelo M2

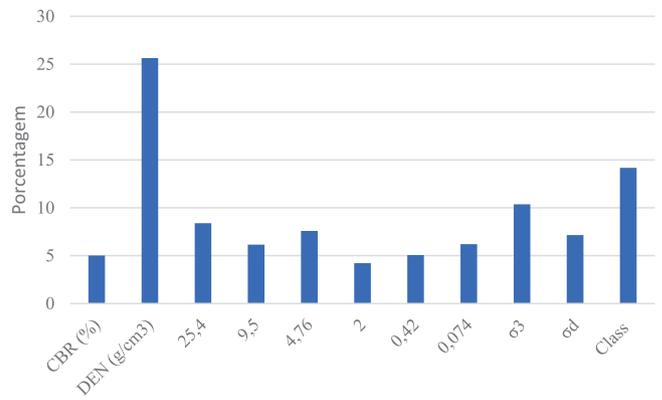
Fonte: Elaborado pelos autores.



**Gráfico 4:** Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura

Fonte: Elaborado pelos autores.

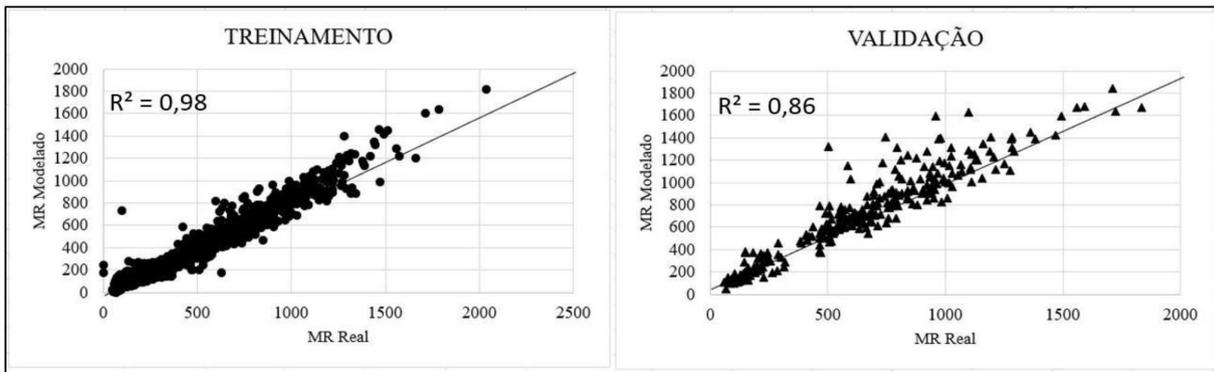
O modelo M3 utilizou dez variáveis de entrada: OT, DEN, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma 3$  e  $\sigma d$ . As variáveis de maior influência para o modelo M3 foram os percentuais que passam na peneira de 9,5mm com 16,39% seguido do percentual que passa na peneira 0,074mm com



**Gráfico 5:** Percentual de contribuição das variáveis de entrada do modelo M2

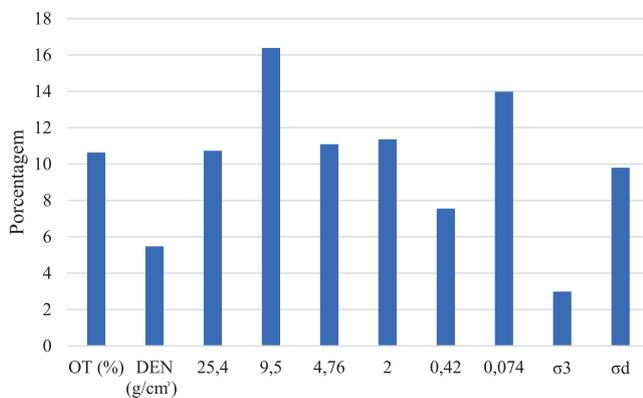
Fonte: Elaborado pelos autores.

13,98% e o percentual da peneira de 2mm com 11,36%. Para este modelo a variável de menor impacto foi a tensão de confinamento ( $\sigma 3$ ). A seguir, são apresentados os valores de correlação obtidos para esse modelo (Gráfico 6) e os percentuais de contribuição das variáveis de entrada (Gráfico 7).



**Gráfico 6:** Comparação do treinamento e validação do modelo M3

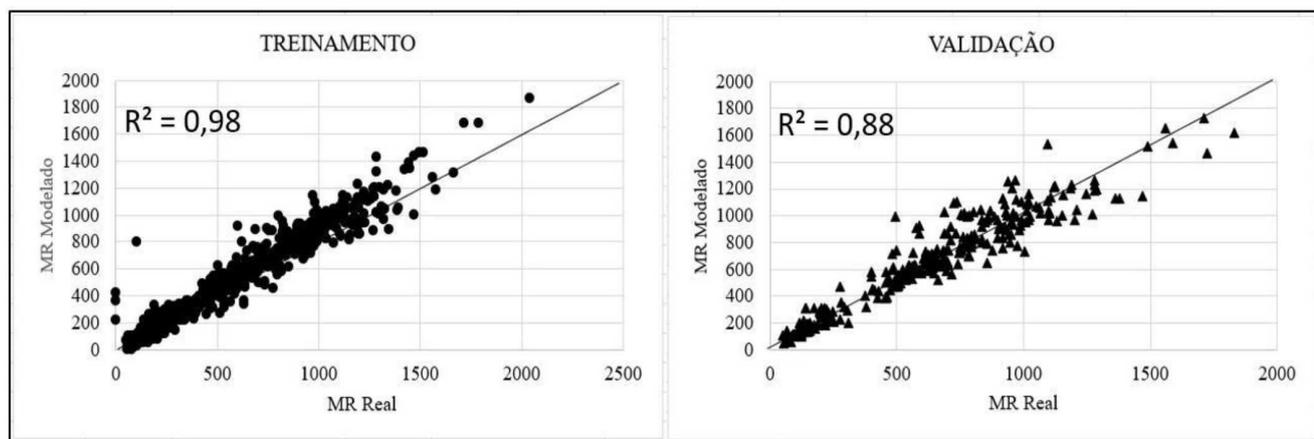
Fonte: Elaborado pelos autores.



**Gráfico 7:** Percentual de contribuição das variáveis de entrada do modelo M3

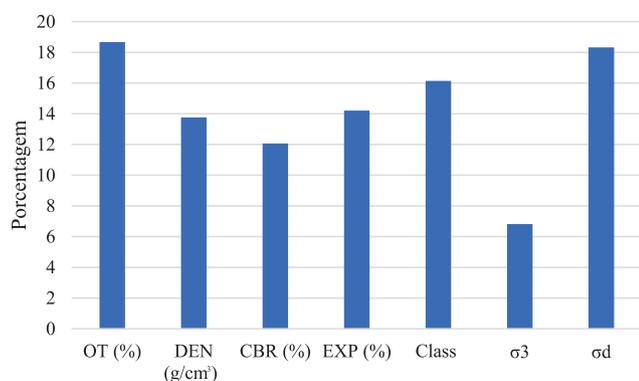
Fonte: Elaborado pelos autores.

O modelo M4 utilizou 7 variáveis de entrada: OT, DEN, (P9,5), (P2), (P0,074),  $\sigma 3$  e  $\sigma d$ . A variável de maior influência para o modelo M4 foi a umidade ótima com 18,67% seguido da tensão de desvio ( $\sigma d$ ) com 18,32% e percentual passante na peneira de 0,074mm com 16,14%. Para este modelo a variável de menor impacto foi a tensão confinante ( $\sigma 3$ ). Os valores de correlação obtidos para esse modelo são apresentados no Gráfico 8 e os percentuais de contribuição das variáveis de entrada no Gráfico 9.



**Gráfico 8:** Comparação do treinamento e validação do modelo M4

**Fonte:** Elaborado pelos autores.

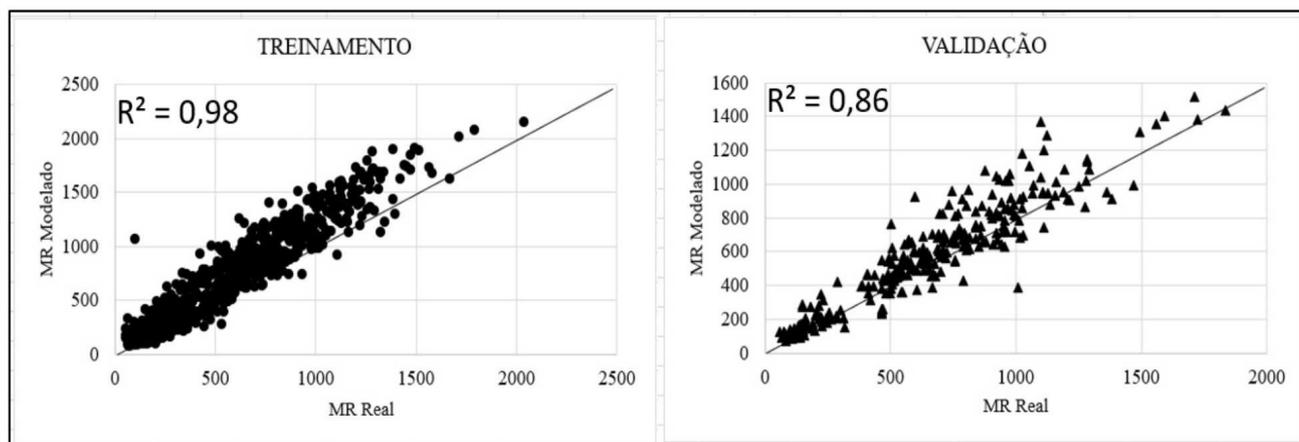


**Gráfico 9:** Percentual de contribuição das variáveis de entrada do modelo M4

**Fonte:** Elaborado pelos autores.

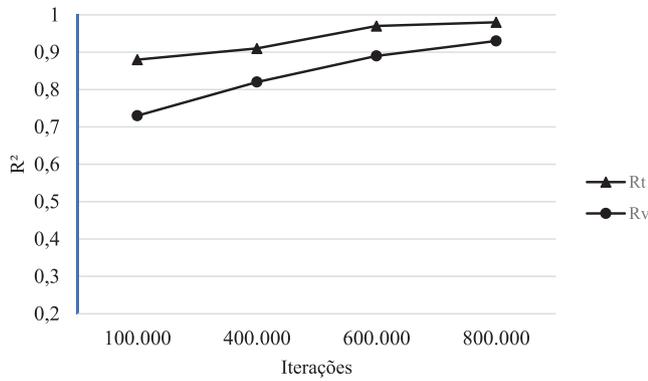
O modelo M5 para estimativa utilizou as seguintes variáveis de entrada: OT, DEN, CBR, EXP,

$\sigma_3$ ,  $\sigma_d$  e Class. O maior valor de correlação na fase de validação foi alcançado com 800.000 iterações. Observou-se que, conforme o número de iterações aumentava, os coeficientes de correlação também se elevavam em ambas as fases, indicando melhor desempenho do modelo. Em relação à contribuição das variáveis, a mais influente foi a tensão de desvio ( $\sigma_d$ ), com 22,3%, seguida da classificação AASHTO (21,68%) e do CBR (18,19%). A variável de menor impacto foi a tensão de confinamento ( $\sigma_3$ ). Na sequência, estão apresentados os resultados referentes aos valores de correlação, ao comportamento do número de iterações nas fases de treinamento e validação, bem como os percentuais de contribuição das variáveis (Gráficos 10, 11 e 12).



**Gráfico 10:** Comparação do treinamento e validação do modelo M5

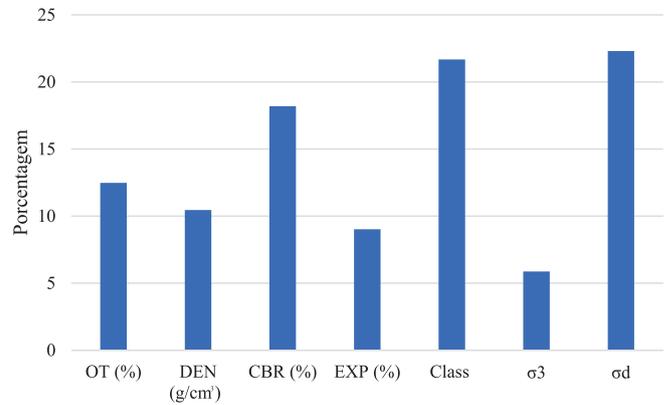
**Fonte:** Elaborado pelos autores.



**Gráfico 11:** Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura

Fonte: Elaborado pelos autores.

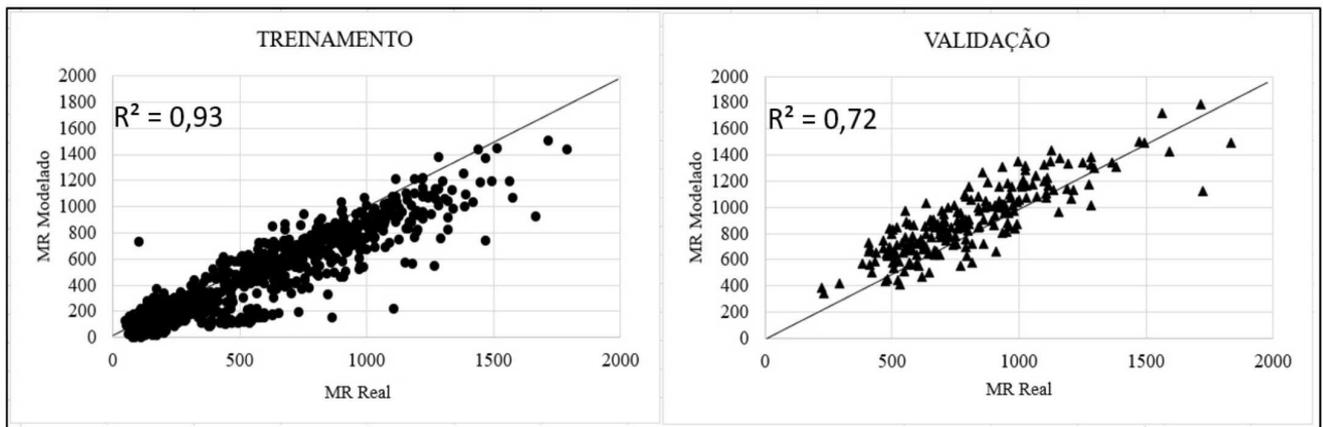
O modelo M6 utilizou 15 variáveis de entrada: OT, DEN, CBR, EXP, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class para a estimativa do Módulo de Resiliência. O Gráfico 13 mostra os valores de correlação obtidos para esse modelo. Comparando o número de iterações nas fases de treinamento e validação, foi possível perceber que o maior valor de correlação para a validação foi obtido com quatrocentos mil iterações. Na fase de validação, após aumentar o número de iterações superiores a quatrocentos mil, os va-



**Gráfico 12:** Percentual de contribuição das variáveis de entrada do modelo M5

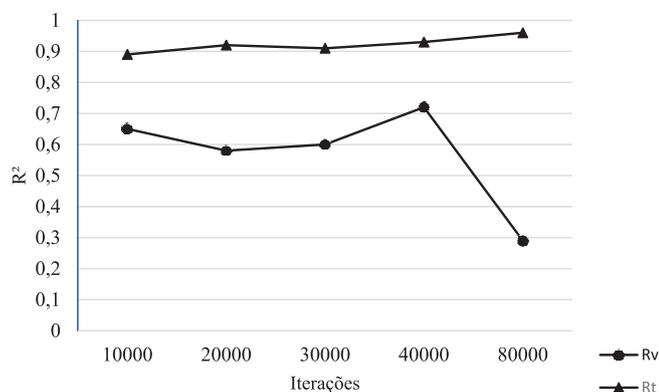
Fonte: Elaborado pelos autores.

lores de correlação foram mais baixos, conforme mostra o Gráfico 14. Para os percentuais de contribuição as variáveis de maior influência para o modelo M6 foram os percentuais que passam na peneira de 4,76mm com 22,16% seguido do percentual que passa na peneira 25,4mm com 11,21% e o percentual da peneira de 0,074mm com 9,08%. Para este modelo a variável de menor impacto foi a expansão com 3,34%. O Gráfico 15 apresenta os valores de contribuição das variáveis.



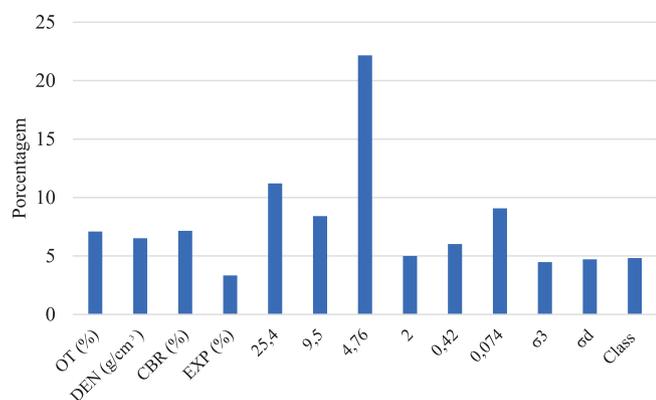
**Gráfico 13:** Comparação do treinamento e validação do modelo M6

Fonte: Elaborado pelos autores.



**Gráfico 14:** Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura

Fonte: Elaborado pelos autores.



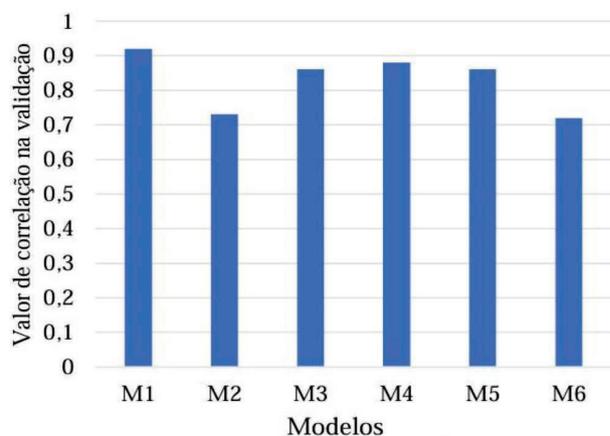
**Gráfico 15:** Percentual de contribuição das variáveis de entrada do modelo M6

Fonte: Elaborado pelos autores.

Após toda a etapa de modelagem, obtenção dos valores correlação e variáveis de contribuição de cada modelo, foi elaborado um histograma que demonstra a comparação entre os valores da modelagem na validação. Dentre todos os dados analisados, destacou-se o M1 que foi o valor de correlação mais elevado. Também é importante ressaltar que os modelos M3, M4 e M5 demonstraram valores de correlação mais estáveis. Esses três modelos foram caracterizados pela menor quantidade de variáveis de entrada e todos acima de 0,70 na validação. O gráfico 16 apresenta esses resultados de forma mais clara.

Os dois modelos neurais que tiveram os maiores valores de correlação na validação foram M1 e M4, com 0,92 e 0,88 respectivamente. Vale ressaltar que, o modelo M4 destacou-se pois teve

a menor quantidade de dados de entrada, o que representa um modelo que requer menos ensaios e maior facilidade para sua determinação. O modelo M1 apresentou o maior valor de correlação, porém foi o modelo com o maior número de dados de entrada, cada uma dessas entradas corresponde a um ensaio laboratorial, o que pode tornar o processo mais oneroso e demorado, devido à necessidade de múltiplos ensaios para a definição das camadas.



**Gráfico 16:** Histograma dos valores de correlação para cada modelo de MR

Fonte: Elaborado pelos autores.

Observou-se que os modelos M1 e M4 apresentaram conjuntos de variáveis com diferentes níveis de influência sobre os resultados. Apesar de a maioria das variáveis de maior contribuição serem distintas entre os modelos, destaca-se que a umidade ótima esteve presente em ambos, evidenciando sua importância no comportamento resiliente dos solos compactados. No entanto, sua significância relativa foi superior no modelo M4, sugerindo que, neste caso, as condições de compactação podem ter assumido um papel mais determinante na previsão do MR, resultados semelhantes foram encontrados por Viana et al. (2010), no qual a umidade ótima teve uma influência percentual de 15,74% na rede neural considerada ideal. Essa diferença de comportamento entre os modelos reforça a importância da análise individualizada das variáveis de entrada, considerando que sua influência pode variar conforme a arquitetura da rede e os dados utilizados no treinamento.

## 4. CONCLUSÕES

Este estudo demonstrou a eficácia das redes neurais artificiais na previsão de características geotécnicas para o dimensionamento mecanístico-empírico de pavimentos. Foram desenvolvidos seis modelos, explorando diferentes variáveis de entrada para identificar padrões relevantes, o que permitiu simplificar as abordagens e identificar novas correlações entre os dados, contribuindo para a compreensão dos padrões que influenciam o comportamento dos materiais.

Dentre os modelos analisados, o M1 apresentou o maior coeficiente de correlação na validação já na primeira tentativa de configuração. No entanto, devido à sua complexidade, não foi considerado o mais representativo. Em contrapartida, o modelo M4, apesar de uma correlação na validação um pouco menor (0,88), destacou-se pela eficiência e viabilidade, utilizando um conjunto reduzido de variáveis, como umidade ótima (OT), densidade (DEN), faixas granulométricas de polegadas, (P9,5), (2mm), (0,074mm),  $\sigma_3$  e  $\sigma_d$ , o que possibilitou uma abordagem mais econômica e prática, demandando um menor número de ensaios laboratoriais. Assim, o modelo M4 foi considerado o mais adequado para aplicação nesta pesquisa.

Os resultados obtidos confirmam que é possível desenvolver modelos preditivos para o módulo de resiliência em uma região específica, tornando-se uma alternativa viável para otimizar projetos de pavimentação e reduzir custos associados à obtenção desses dados exclusivamente por meio de ensaios laboratoriais. Além disso, os coeficientes de correlação obtidos nos modelos deste estudo variaram de 0,73 a 0,92, apresentando níveis de precisão compatíveis com os encontrados por Ribeiro (2016), que obteve correlações de até 0,985. Esses achados reforçam o potencial das redes neurais artificiais como ferramenta auxiliar na engenharia de pavimentos, contribuindo para uma caracterização geotécnica mais eficiente e acessível.

## REFERÊNCIAS

- A. Mehrpazhouh, S. N. Moghadas Tafreshi y M. Mir-zababaei, Impact of repeated loading on mechanical response of a reinforced sand. *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 11, n.º 4, pp. 804-814, 2019. doi: 10.1016/j.jrmge.2018.12.013
- Alves, K. D. R.; Santarem, L. M. S. 2015. Um panorama da manutenção rodoviária no Brasil e as experiências internacionais XXIX Congresso Nacional de Pesquisa em Transporte da ANPET. Outro Preto.
- Araújo, C. B. C. 2015. Aplicação das redes neurais artificiais do tipo perceptron na estimativa de recalques em estacas. 2015. 203 f. Dissertação (Mestrado em Engenharia Civil: Geotecnia)-Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza.
- Cabral, W. S.; Barroso, S. H. D. A.; Silva, S. D. A. T. 2022. Consideração da deformação permanente de solos ocorridos na região Nordeste na análise mecanística-empírica de pavimentos. *Matéria (Rio de Janeiro)*, v. 26, n. 4, p. e13096. Disponível em: <http://doi.org/10.1590/s1517-707620210004.1396>. Acesso em: 2 abr. 2025.
- Caires, K. V. L; Simonelli, G. 2021. Forecasting the Brazilian demand for biodiesel using artificial neural networks. *Research, Society and Development*, [S. l.], v. 10, n. 5, p. e17410513381. DOI: 10.33448/rsd-v10i5.13381. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/13381>. Acesso em: 3 apr. 2025.
- Cardozo, L. G. E; Resende, D. C. C; Silva, N. A. B. 2023. Empirical and empirical-mechanistic dimensioning: Impact cracked area and on the project period of flexible pavements. *Research, Society and Development*, [S. l.], v. 12, n. 7, p. e11612742543. DOI: 10.33448/rsd-v12i7.42543. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/42543>. Acesso em: 1 abr. 2025.

- Correia, A.G.; Winter, M.; Puppala, A. 2016. A review of sustainable approaches in transport infrastructure geotechnics. *Transp. Geotech.* 7, 21-28.
- Correia, António Gomes et al. 2021. A geotecnia nos pavimentos e vias-férreas e perspectivas para a era digital. *Geotecnia*, n. 152, p. 113-141, 2021.
- Costa, M. C. A. d., Costa, B. C. A. d., Marques, J. A. F., e Marques, R. P. 2020. Elaboração de mapas geotécnicos a partir de relatórios de sondagem spt: georreferenciamento da região administrativa 01 do município maceió/al. Congresso Brasileiro De Mecânica Dos Solos E Engenharia Geotécnica. <https://doi.org/10.4322/cobramseg.2022.0548>.
- Dantas N, S. A. 2004. Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificadas com Borracha Granulada de Pneus Usados. Tese de Doutorado, publicação G.TD - 024/04, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 265p.
- Do Carmo, C. A. T.; Marques, G. L. de O. 2021. Avaliação comparativa de propriedades mecânicas de misturas asfálticas simples e compostas / Comparative evaluation of the mechanical properties of simple and composite asphalt mixtures. *Brazilian Journal of Development*, [S. l.], v. 7, n. 8, p. 84306-84329. DOI: 10.34117/bjdv7n8-579. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BRJD/article/view/35033>. Acesso em: 1 apr. 2025.
- Ferreira, A. D. 2021. Comparação entre método empírico e mecânico-empírico para dimensionamento de pavimentos flexíveis. In: 7º Congresso Técnico Científico da Engenharia e da Agronomia, Evento Virtual, 2021.
- FHWA Federal Highway Administration. 2014. Speed Concepts: Informational Guide. US DOT. [https://safety.fhwa.dot.gov/speedmgt/ref\\_mats/fhwasa10001](https://safety.fhwa.dot.gov/speedmgt/ref_mats/fhwasa10001).
- Honarmand-ebrahimi, Ali. Regression and neural network modeling of resilient modulus based on routine soil properties and stress states. The University of Oklahoma, 2006.
- India, G. 2018. Basic Road Statistics of India. 2015-16. Ministry of Road Transport and Highways: New Delhi.
- Lima, K. D. M. Estudo de caso: análise qualitativa e quantitativa de material granular para a pavimentação na região de Goiânia. 2021. 87 f. TCC (Graduação) - Curso de Bacharelado em Engenharia Civil, Departamento de Áreas Acadêmicas III, Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Campus Goiânia, Goiânia, 2022.
- Maciel, R. S.; Costa, T. de O.; Colen, F.; Maia, N. A.; Pereira, S.; Baraúna, E. E. Pereira; Baldin, T.; De Souza, L. H. Previsão da temperatura interna de um forno de carvão de alvenaria utilizando rede neural artificial do tipo LSTM. *CONTRIBUCIONES A LAS CIENCIAS SOCIALES*, [S. l.], v. 16, n. 8, p. 8472-8485, 2023. DOI: 10.55905/revconv.16n.8-016. Disponível em: <https://ojs.revistacontribuciones.com/ojs/index.php/clcs/article/view/1047>. Acesso em: 3 abr. 2025.
- Mello, L. B.; Chiarello, G. P.; Pascoal, P. T.; Baroni, M.; Specht, L. P. Solo-brita em bases de pavimentos flexíveis: avaliação quanto à fadiga utilizando o MEDINA. *Anuário do Instituto de Geociências*, v. 44, 2021. Disponível em: [https://doi.org/10.11137/1982-3908\\_2021\\_44\\_35192](https://doi.org/10.11137/1982-3908_2021_44_35192). Acesso em: 2 abr. 2025.
- Motta, L. M. G. (1991) Método de Dimensionamento de Pavimentos Flexíveis: Critério de Confiabilidade e Ensaio de Cargas Repetidas. Tese de Doutorado.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil
- Nguyen, B. T.; Mohajerani, A. 2016. Resilient modulus of fine-grained soil and a simple testing and calculation method for determining an average resilient modulus value for pavement design. *Transportation Geotechnics*, v.7, p.59-70.
- Oliveira, F. C. H. P. Desenvolvimento de modelos neurais e mapas geológico-geotécnicos para pavimentação no estado do Ceará. 2024. 156 f. Dissertação (Mestrado em Geologia) - Universidade Federal do Ceará, Fortaleza.

- Pitangui, L. C. 2019. Análise comparativa do método do DNER com o método mecanístico-empírico MeDiNa. Monografia (especialização) – Curso de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 93 p.
- Ribeiro, A. J. A. 2016. Um modelo de previsão do módulo de resiliência dos solos no estado do Ceará para fins de pavimentação. Tese (Doutorado em Engenharia de Transportes). Universidade Federal do Ceará, Fortaleza.
- Rocha, M. L.; Marques, G. L. O.; Oliveira, T. M. 2021. Avaliação dos resíduos de construção e demolição no dimensionamento de camada reforço de pavimentos flexíveis. *Revista Ibero-Americana de Ciências Ambientais*, v. 12, n. 2, p. 377-393. Disponível em: <https://doi.org/10.6008/cbpc2179-6858.2021.002.0033>. Acesso em: 2 abr. 2025.
- Santos, T.A., Pinheiro, R.J.B., Specht, L.P., et al. 2020. Análise do desempenho de subleitos rodoviários à luz de conceitos da Mecânica dos Pavimentos, *Revista Matéria*, v.25, n.3.
- Santos, A. E. M., Silva, D. d. F. S. d., Mendonça, G. A., Santos, T. V., Amaral, R. R., e Silva, L. A. M. 2020. Índice de queda de blocos e caracterização geológica-geotécnica em taludes rodoviários: um estudo de caso na br-262. *Research, Society and Development*, 9(12), e12891210968. <https://doi.org/10.33448/rsd-v9i12.10968>.
- Sas, W., Gluchowski, A., Gabrys, K., Szymanski. A. 2015. Application of cyclic CBR test for the estimation of re-silient modulus in the pavement construction. en *Proceedings of the XVI ECSM-GE Geotechnical Engineering for Infrastructure and Development*, pp. 3747-3752. doi: 10.1680/ecsmge.60678.
- Silva, L. V.; Omido, T. V.; Barboza, C. S. 2023. Omido, A. R. Dimensionamento de pavimentos flexíveis: análise comparativa de custos entre diferentes métodos. *REVISTA DELOS*, [S. l.], v. 16, n. 46, p. 2474-2498. DOI: 10.55905/rdelosv16.n46-030. Disponível em: <https://ojs.revistadelos.com/ojs/index.php/delos/article/view/1023>. Acesso em: 1 abr. 2025.
- Soares, J. B.; A. Mateos e L.M.G. Motta. 2009. Aspectos gerais de métodos de dimensionamento de pavimentos asfálticos de vários países e a relação com um novo método brasileiro. *Revista Pavimentação (ABPv)*, Outubro, p. 20-35
- Tarawneh, D.; Nazzal, M.D. Optimization of resilient modulus prediction from FWD results using artificial neural network. *Period. Polytech. Civ. Eng.* 2014, 58, 143-154.
- Viana, H. M. F., Parreira, A. B., e Fabbri, G. T. P. 2010. Análise das Relações entre o Módulo de Resiliência e as Propriedades dos Solos Grossos à Luz das Redes Neurais Artificiais. *Anais*.