

ANÁLISE E PREDIÇÃO DO COMPORTAMENTO RESILIENTE DE SOLOS COM ADIÇÃO DE CIMENTO EMPREGANDO-SE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Stephanny Conceição Farias do Egito Costa

scfecosta@uesc.br

Universidade Estadual de Santa Cruz - UESC, Ilhéus, BA, Brasil.

Adriano Elisio de Figueiredo Lopes Lucena

lucenaafb@uol.com.br

Universidade Federal de Campina Grande - UFCG, Campina Grande, PB, Brasil.

William de Paiva

wpaiwa461@gmail.com

Universidade Estadual da Paraíba - UEPB, Campina Grande, PB, Brasil.

RESUMO

No Brasil, o desenvolvimento do método mecanístico-empírico de dimensionamento de pavimentos flexíveis, MeDiNa, requer parâmetros referentes às características mecânicas dos materiais e, entre eles, o comportamento resiliente. As deformações resilientes são obtidas em laboratório com o ensaio Triaxial de Carga Repetida, mas o equipamento necessário à sua execução ainda requer grande capital de investimento. Dada a evolução da modelagem computacional e a possibilidade de aquisição de resultados rápidos e confiáveis por meio de sistemas inteligentes, nesse trabalho se objetivou construir Redes Neurais Artificiais capazes de prever o Módulo de Resiliência de solos melhorados com cimento a partir de sua caracterização física. A qualidade dos modelos foi mensurada por índices estatísticos e análise das diferenças nos resultados do dimensionamento com uso dos valores preditos em relação aos obtidos em ensaios. Além disso, fez-se análises estatísticas para verificação da alteração das propriedades dos solos estudados após a adição do aglomerante. Os resultados indicam melhoria no comportamento resiliente dos materiais, mas não linearmente proporcional à adição de cimento. Em relação à predição do Módulo de Resiliência, obteve-se bons resultados para os índices analisados e, conseqüentemente, pouca ou nenhuma diferença entre as estruturas dimensionadas. As Redes Neurais Artificiais desenvolvidas nesse trabalho mostraram desempenho superior àquelas até então publicadas, no tangente à magnitude dos erros de predição.

Palavras-chave: Predição; Módulo de resiliência; Redes neurais artificiais.

INTRODUÇÃO

A abordagem mecanicista de dimensionamento de pavimentos teve suas primeiras contribuições na década de 1950, por Hveem, que publicou correlações entre cargas, deflexões e fissuras de pavimentos asfálticos. Nessa mesma década, o progresso computacional proveu ampliação das pesquisas, permitindo análises mais rebuscadas do estado de tensões e deformações atuantes no pavimento.

Hoje, a teoria mecanicista ocupa posição de destaque na literatura mundial (Han *et al.*, 2018; Khasawneh e Al-jamal, 2019; Ren *et al.*, 2019; Haider, Masud e Chatti, 2020; Qian *et al.*, 2020; Brizolla de Mello *et al.*, 2021; Chegenizadeh *et al.*, 2022) devido à possibilidade de análise do comportamento mecânico dos materiais que compõem as estruturas mais próximas da realidade. Dessa forma, evidencia-se a tendência global de adoção desse tipo de abordagem no dimensionamento de pavimentos, vistas as melhorias de desempenho que podem ser alcançadas devido a uma melhor compreensão e modelagem das estruturas.

Dada a dificuldade de desenvolvimento e/ou utilização de métodos genuinamente mecanísticos, surge o chamado Mecanístico-Empírico (M-E), que faz uso de observações de campo para calibrar as equações pertinentes às análises. Alguns países já adotam a abordagem M-E há algumas décadas, a exemplo dos Estados Unidos da América, África do Sul e Portugal. A tendência de mudança somada às limitações do método empírico (Chiarello *et al.*, 2019; Franco, 2007; Vendrusculo *et al.*, 2018) adotado até então no Brasil fez surgir em 2018 um novo método de dimensionamento de pavimentos – MeDiNa (Método de Dimensionamento Nacional) – baseado na rotina de Análise Elástica de Múltiplas Camadas (AEMC), que permite prever a performance do pavimento quanto à fadiga e à deformação permanente ao longo de sua vida útil, possibilitando o dimensionamento de estruturas mais duradouras e seguras aos usuários.

O MeDiNa aborda a análise de deformabilidade de estruturas de pavimento sob as condições de solicitação de tráfego. Nesse contexto, a utilização do Módulo de Resiliência (MR) se mostra mais adequada do que o método baseado no Califórnia Bearing Ratio (CBR), que não é capaz de traduzir os mecanismos de ruptura dos pavimentos flexíveis, pois estão associados ao estado de tensões desenvolvido pela repetição de cargas. A consideração do comportamento resiliente dos materiais permite estimar a surgência e intensidade de fissuras e trincas que causam a deterioração estrutural das rodovias. Além disso, o MeDiNa admite a utilização de materiais tratados quimicamente, ressaltando a variação do MR entre o início e fim da vida útil quanto à fadiga.

Nos materiais tratados quimicamente há adição de aglomerantes que modificam as propriedades do solo ou criam

uma matriz que envolva ou cimente os grãos. Tal processo pode se dar pela adição de cal (Andavan & Pagadala, 2019; Cheng *et al.*, 2018; James, 2020), cimento (Hataf, Ghadir e Ranjbar, 2018; Solihu, 2020; Ayininuola e Abidoeye, 2018), betume (Çalisici, 2018; Oluyemi-Ayibiowu, 2019; Dantas Neto, Pereira e Abreu, 2020) e rejeitos da indústria como, por exemplo, os provenientes do beneficiamento de rochas e minerais (Martins e Belchior, 2018), casca de arroz (Silva, Bello e Ferreira, 2020), entre outras possibilidades (Miraki *et al.*, 2022; Choobbasti, Samakoosh & Kutanaei, 2019; Hataf, Ghadir e Ranjbar, 2018).

Segundo Hanandeh, Ardah e Abu-Farsakh (2020), há diferença entre estabilização química e melhoramento dos solos. A pequena adição de produtos químicos objetivando a secagem do solo ao ponto em que se permita a execução satisfatória do processo de compactação, é denominada melhoramento. Já a adição de produtos ao ponto de prover ligações com os grãos de solo seria a estabilização. Apesar dessa diferença, ambos estão relacionados à capacidade de troca catiônica e efeitos pozolânicos. O solo estabilizado com cimento deve atender a requisitos de densidade, durabilidade e resistência, resultando em material duro e com rigidez à flexão, estando o teor de cimento normalmente entre 6% e 10% em peso seco. Já para solos melhorados, o teor utilizado está entre 2% e 4%, sendo capaz de modificar o solo quanto à plasticidade e sensibilidade à água e, segundo o Departamento Nacional de Infra-Estrutura de Transportes (2006), permitindo ainda considerar a flexibilidade da camada.

Apesar de todo o ganho técnico atrelado ao desenvolvimento e utilização do MeDiNa, tem-se, na prática, como fator limitante, a obtenção dos parâmetros necessários para alimentar a rotina de cálculo como, por exemplo, o MR e a Deformação Permanente (DP). As deformações resilientes, ou recuperáveis, podem ser obtidas em laboratório por meio do ensaio Triaxial de Carga Repetida (TCR), mas o equipamento necessário à sua execução requer grande capital de investimento, pois é demasiadamente dispendioso em relação aos ditos ensaios tradicionais. Além disso, necessita de treinamento especial para os operadores e técnicos, sendo inviável a sua execução em canteiro de obras.

Em alguns países, esse entrave vem sendo minimizado fazendo-se uso de modelagens preditivas (Zeghal e Khogali, 2005; Solanki, Zaman e Ebrahimi, 2009; Saha *et al.*, 2018; Khasawneh e Al-jamal, 2019; Farh, Awed e El-Badawy, 2020) a partir de Redes Neurais Artificiais (RNAs), uma das técnicas mais utilizadas da Inteligência Artificial, que são capazes de identificar padrões em grandes bancos de dados e realizar predições com alta taxa de confiabilidade.

No Brasil, Viana (2007), Ribeiro (2016) e Ferreira (2008) utilizaram RNAs para predição do MR em solos do interior

do estado de São Paulo, Região Metropolitana de Fortaleza e solos distribuídos no território nacional, respectivamente. Foi observado em todos os trabalhos o grande potencial de utilização desse método, mas alguns fatores como a regionalização dos dados nos trabalhos de Viana (2007) e Ferreira (2008), os altos valores de erro inviabilizam o uso de algumas redes desenvolvidas, dando espaço à busca de aperfeiçoamento e melhorias dos resultados obtidos até então.

As RNAs são constituídas por neurônios artificiais, em que cada unidade é chamada de *Perceptron* que, por sua vez, é composto pelos sinais de entrada (dados que alimentam o sistema), pesos sinápticos, bias, funções de ativação e saída. O processo de aprendizagem de uma RNA é o resultado de ajustes sequenciais dos pesos sinápticos até que o modelo responda da forma mais aproximada possível do que se deseja. As RNAs podem apresentar as mais variadas arquiteturas, ou seja, números de camadas e neurônios em cada uma delas. Entre as camadas de entrada e saída podem existir uma ou mais camadas intermediárias/ocultas. Ao modelá-las, busca-se encontrar o número de camadas intermediárias, quantidade de neurônios, algoritmos de aprendizagem e funções de transferência em cada uma delas de maneira que os resultados gerados sejam otimizados.

Para que a RNA consiga gerar o resultado esperado, é necessário que ela passe pelas fases de treinamento, validação e teste, apresentando-a aos padrões de dados. Rotineiramente, os padrões que constituem a base de dados são divididos aleatoriamente para as fases citadas, sendo a maior parte deles, em torno de 70%, pertencentes ao conjunto de treinamento.

O processo de aprendizagem pode ser do tipo não supervisionada, por reforço ou supervisionada. A aprendizagem supervisionada consiste em apresentar à rede um conjunto de treinamento com padrões de entrada e os respectivos resultados. Com o conjunto de validação, a rede poderá comparar os resultados gerados com o esperado e, se necessário, ajustar os pesos até que o valor de saída atenda aos critérios de erro definidos. A grande vantagem do aprendizado supervisionado está justamente na possibilidade de comparação entre o valor gerado e o esperado, permitindo verificar a precisão das saídas e estabelecer critérios de qualidade para o modelo, por meio, por exemplo, dos limites ditos aceitáveis aos erros medidos. Quando os erros chegam a valores considerados pequenos, pode-se admitir que o treinamento foi suficiente para prover os ajustes necessários.

Dado o cenário brasileiro e o desenvolvimento de tecnologias, objetivou-se criar modelos de predição dos valores de MR de solos brasileiros com pequenas adições de cimento a partir de dados da caracterização física dos solos, reduzindo limitações técnicas e econômicas pertinentes à execução do ensaio TCR. Esses modelos preditivos serão construídos utilizando RNAs, tendo sua qualidade mensurada por parâ-

metros estatísticos e aplicabilidade testada por meio do confronto do dimensionamento de estruturas de pavimentos, no MeDiNa, com as informações preditas e as de referência do comportamento resiliente dos materiais utilizados.

MÉTODO

Análise laboratorial e tratamento estatístico

Os dados utilizados nessa pesquisa são provenientes dos ensaios realizados em amostras retiradas de 29 jazidas de empréstimos utilizadas nas BR 158/GO e PE 270. Para cada amostra foram realizados os ensaios de granulometria, limites de Atterberg, compactação na energia modificada, CBR e TCR. Os ensaios TCR foram realizados no Laboratório de Engenharia de Pavimentos da Universidade Federal de Campina Grande (LEP-UFCG). Os demais, pelas empresas STS – Serviços Técnicos de Sondagem e PDCA Engenharia, seguindo as normas:

- DNER ME 041/94 – Solos – Preparação de amostras para ensaios de caracterização;
- DNER ME 080/94 – Solos – Análise granulométrica por peneiramento;
- DNER ME 082/94 – Solos – Determinação do limite de plasticidade;
- DNER ME 122/94 – Solos – Determinação do limite de liquidez;
- DNER ME 129/94 – Solos – Compactação utilizando amostras não trabalhadas;
- DNER ME 049/94 – Solos – Determinação do Índice de Suporte Califórnia utilizando amostras não trabalhadas;
- DNIT ME 134/2018 – Pavimentação – Solos – Determinação do módulo de resiliência.

Para os ensaios de compactação CBR e TCR foram moldados 3 corpos de prova (CPs) de cada jazida, sendo um de solo natural e dois com adição de cimento do tipo CP II 32 F – RS em peso seco, nas porcentagens de 2% e 3%, totalizando 87 amostras para cada ensaio. Essas amostras passaram pelo processo de compactação logo após o umedecimento. Os CPs submetidos ao ensaio TCR foram armazenados em câmara úmida por 7 dias. Dados os baixos teores de cimento adicionados, essas amostras podem ser chamadas de “solos melhorados com cimento”, justificando serem ensaiadas seguindo a mesma norma utilizada para os solos naturais (DNIT

ME 134/2018), que permite a prática de ensaios para “(...) solos e materiais melhorados por pequenas quantidades de adições de produtos químicos ou fibras naturais (...), desde que não estabilizados quimicamente”.

Após execução do plano experimental foi construído um banco compilando-se os resultados provenientes nos ensaios, somados à classificação TRB, em planilha eletrônica com 22 colunas e 1566 linhas, em que cada linha representa um padrão de entrada para RNA. Como os dados coletados para desenvolvimento das RNAs são de diferentes tipos, necessitaram ser pré-processados a fim de torná-los, na totalidade, do tipo numérico. Os Limites de Consistência e Classificação TRB são originalmente apresentados do tipo alfanuméricos. Dessa forma, foram assumidas como “zero” as informações referentes aos Limites, quando Não Líquido (NL) e/ou Não Plástico (NP). A classificação TRB perdeu o caractere “A” que inicia todas as nomenclaturas, e teve os “a” e “b” substituídos por “1” e “2”, e o “-” por “,”.

Após as adaptações mencionadas, o banco de dados foi submetido a tratamento estatístico para identificação de *outliers*. Foram considerados *outliers* os pontos localizados acima e abaixo dos Limites Superior (LS) e Inferior (LI), respectivamente, do intervalo interquartil (IQR). Esses valores foram analisados um a um para a sua exata correção/exclusão, almejando minimizar ruídos e geração de erros nas modelagens sem comprometer a qualidade e o tamanho do banco de dados. Houve a diminuição de 3,45% do número de padrões de entrada, sendo assim, o banco passou de 1566 para 1512 linhas (padrões). Após esse tratamento, foi realizada a normalização dos dados, visto que são de diferentes ordens de grandeza, e a sua utilização na forma original poderia enviesar os resultados.

Análises do comportamento resiliente

As análises das alterações no comportamento resiliente dos solos após adição dos teores de cimento, quanto à sua melhoria após adição do aglomerante, foi realizada por meio de análises estatísticas para cada amostra estudada. A constatação, ou não, da alteração estatisticamente significativa do MR deu-se por meio da realização de testes de hipóteses. Esses mesmos testes também foram utilizados para verificar se a adição do aglomerante alterou a umidade ótima das misturas e se houve ganho nos valores de CBR.

O primeiro teste realizado foi a Análise de Variância (ANOVA), que tem como pressupostos a independência das observações, distribuição normal dos grupos de amostras, homogeneidade das variâncias e ausência de *outliers*. Para a correta aplicação desse tipo de teste, esses pressupostos devem ser verificados e atendidos. A normalidade da distribuição foi examinada por meio do teste de Shapiro-Wilk e

a homogeneidade das variâncias por meio do Teste de Levene. A interpretação dos resultados ocorreu analisando-se o p-valor em comparação ao nível de significância adotado (α), que nessa pesquisa foi de 0,05.

Após a execução dos testes mencionados, foi verificado se todos os pressupostos da ANOVA foram atendidos. Em caso afirmativo, procedeu-se com a Análise de Variância para constatar alteração, ou não, estatisticamente significativa do valor de MR médio. No caso das amostras em que os pressupostos não foram atendidos, foi realizado o teste não paramétrico correspondente à ANOVA de um fator, no caso, o teste de Kruskal-Wallis. As condições para o seu uso se referem à comparação de, no mínimo, três amostras diferentes e independentes com seis observações, e que possam ser ranqueadas. O teste de Kruskal-Wallis é rotineiramente utilizado quando não se pode realizar a ANOVA para a verificação de igualdade de parâmetros entre grupos. Por não requerer normalidade nas distribuições é chamado de teste não paramétrico. Quando esse teste indica diferença entre pelo menos um grupo de amostras, procede-se com o teste de Dunn para identificar qual é o grupo em questão.

Com a realização dos testes para os três grupos (natural, +2% e +3%) foi possível verificar se a adição de aglomerante trouxe, ou não, alterações ao comportamento resiliente do material comparado ao seu estado natural.

Modelagem das RNAs

Nessa etapa do trabalho foram construídas RNAs para predição do MR a partir dos resultados dos ensaios de caracterização geotécnica, utilizando-se o *software* MATLAB. O treinamento foi do tipo supervisionado, em que o conjunto de resultados esperados é fornecido junto aos dados de entrada. As RNAs foram compostas por três camadas (entrada, oculta e saída). A camada de entrada foi constituída por 16 variáveis (porcentagem de cimento, porcentagem passante nas peneiras 50,8 mm (2”); 25,4 mm (1”), 9,5 mm (3/8”); 4,8 mm (nº 4); 2 mm (nº 10); 0,42 mm (nº 40) e 0,074 mm (nº 200), LL, LP, classificação TRB, umidade ótima, MEASM, CBR, expansão, tensões confinante e desvio), a intermediária possuía número variável de neurônios, múltiplos de 4 entre 4 e 48 e, por fim, a camada de saída com apenas um neurônio, sendo o MR.

Optou-se por redes do tipo *Feed-forward Backpropagation* por serem capazes de resolver problemas não linearmente separáveis, e foram utilizados três diferentes tipos de função de treinamento, sendo eles: *Bayesian regularization* (TRAINBR), *Levenberg-Marquardt* (TRAINLM) e *Gradient Descent* (TRAINGD). Em relação às funções de transferência, foram testadas as combinações possíveis entre a Linear, Logística Sigmoidal e Tangente Hiperbólica. A performance das redes foi verificada por meio dos valores do Coeficiente de

Determinação (R^2) e Erro Quadrático Médio (MSE), elegendo-se, a partir desses parâmetros e do tempo de treinamento, a rede com melhores resultados para predição do MR.

Dimensionamento de pavimentos

Após a escolha da melhor RNA para predição do MR de solos com adição de cimento, seus resultados foram comparados aos valores de MR previstos, calculando-se o erro absoluto de cada padrão. Das 87 amostras de solos, foram escolhidas as três que apresentaram o maior valor de Erro Médio Absoluto (MAE) dos 18 pares de tensões correspondentes a um ensaio TCR.

As três amostras mencionadas foram utilizadas para dimensionamento de pavimento flexível utilizando o MeDiNa. Para efeito de comparação, para cada estrutura dimensionada e analisada com os valores preditos, foi dimensionada uma para os valores obtidos nos ensaios TCR.

As estruturas fictícias dimensionadas seguiram o padrão inicial do MeDiNa para as camadas 1, 3 e subleito. A camada 1 é composta por Concreto Asfáltico (CA) do tipo RJ CAP 30/45 #12,5mm Sepetiba com 8,8 cm de espessura inicial; camada 3 de solo argiloso LG' (1) com 20 cm, e o subleito de solo silteoso NS'. Nessas camadas não houve alteração de qualquer característica física ou mecânica dos materiais. A base do pavimento com 20 cm de espessura, numerada como camada 2, teve espessura inicial fixada em 20 cm; coeficiente de Poisson, 0,35; Abrasão Los Angeles, 41%; modelo de deformação permanente com coeficientes de regressão $\Psi_1 = 0,1608$, $\Psi_2 = -0,097$, $\Psi_3 = 0,525$ e $\Psi_4 = 0,0752$. As características físicas e os coeficientes de regressão do modelo resiliente não linear foram alterados conforme o material adotado.

Quanto aos dados de tráfego, também se utilizou o *default* do MeDiNa, sendo o tipo de via para sistema arterial primário, Volume Médio Diário no 1º ano de 1370, veículo padrão de eixo simples de roda dupla, período de projeto de 10 anos e N Total de $5,00 \times 10^6$.

Os resultados das estruturas modeladas com os valores de MR preditos pela RNA e os determinados em laboratório foram comparados quanto à espessura final das camadas, Afundamento de Trilha de Roda (ATR) e Área Trincada no fim do período de projeto.

RESULTADOS E DISCUSSÕES

Ensaio laboratoriais

Os resultados da granulometria e limites de consistência

das amostras permitiram classificar os materiais de acordo com o TRB, observando que todas as amostras são granulares e de comportamento excelente a bom como subleito, sendo: 17,24% do tipo A-1-a, 20,69% A-1-b, 55,17% A-2-4 e apenas 6,9% A-2-6. Em relação ao índice de grupo, todas apresentaram $IG=0$. A porcentagem passante na peneira #50,8 obteve em todas as amostras o valor de 100%, caracterizando-a como uma constante no contexto dessa pesquisa. Essa constatação resultou na exclusão dessa variável de todas as outras verificações estatísticas e de seu uso como dado de entrada das RNAs a serem construídas.

Foram realizados os ensaios de compactação e CBR para todas as amostras (natural, +2% e +3%), visto que os teores de cimento adicionados poderiam provocar mudanças no teor de umidade ótimo, devido, por exemplo, à hidratação necessária para ativação do aglomerante e/ou aumento do valor de CBR devido ao possível aumento da rigidez do CP.

Para verificação de significância da alteração do teor de umidade nas três condições de ensaio foram realizados testes estatísticos de comparação de média. Inicialmente, tentou-se proceder com a Análise de Variância (ANOVA), mas ao realizar o teste de Shapiro-Wilk para verificar a normalidade da distribuição ao nível de significância de 5%, verificou-se que as amostras com adição de 2% e 3% de cimento não possuem distribuição Normal, ferindo um dos pressupostos necessários para realização da ANOVA e direcionando a análise de dados para métodos não paramétricos.

O resultado do teste de Kruskal-Wallis indica, com 95% de certeza, que os dados testados não possuem diferenças significativas. Após os testes, percebeu-se que a adição de cimento em porcentagens de 2% e 3% não alteraram significativamente o teor de umidade ótima das amostras, como era esperado previamente. É possível que os teores utilizados sejam ínfimos ao ponto de não provocar esse tipo de alteração ou que não tenha havido tempo suficiente para completa hidratação do aglomerante, já que a compactação ocorreu imediatamente após a hidratação.

O procedimento estatístico para análise da variação de CBR foi o mesmo utilizado para os resultados do ensaio de compactação. Quanto à normalidade, o teste de Shapiro-Wilk comprova a sua existência para os três grupos de amostragem. O teste de Levene foi utilizado para verificar a homogeneidade da variância entre as amostras, e o resultado mostrou que as variâncias não são homogêneas para $\alpha = 0,05$. Devido ao não atendimento dos pressupostos da ANOVA, realizou-se o teste de Kruskal-Wallis, que indica, com 95% de certeza, que há diferença em pelo menos um grupo de amostras. Para verificar quais grupos são diferentes entre si, realizou-se o teste de Dunn e pôde-se verificar por meio do p-valor $< 0,05$ (condição para rejeitar a hipótese nula) que todos os grupos são diferentes entre si.

De acordo com os testes efetuados, a adição de cimento nas amostras influenciou o valor de CBR, muito provavelmente devido ao aumento da rigidez dos CPs devido ao endurecimento do aglomerante e seus efeitos sobre a matriz de solo. As amostras com 2% de aglomerante apresentaram aumento médio de 39% do valor de CBR. O menor ganho percentual de CBR ocorreu para as amostras da jazida 9, sendo da ordem de 10%. Ainda sobre esse mesmo teor de cimento, as jazidas 11, 13, 18, 21, 22 e 29 apresentaram aumento do CBR de mais de 50%. Para adição de 3% de cimento, o aumento médio do valor de CBR foi de 70%, sendo que as amostras das jazidas 11, 16, 17, 18, 21 e 22 chegaram a mais de 100% de aumento no valor de CBR quando comparado às amostras naturais.

Os resultados da expansão não foram analisados dessa forma, visto que 70% das amostras não expandiram.

Comportamento resiliente

Para cada uma das 87 amostras foram realizados os ensaios TCR, segundo a norma DNIT 134/2018-ME. As amostras com adição de 2% e 3% de cimento passaram pelo processo de cura úmida durante sete dias antes de serem submetidas ao ensaio.

A Tabela 1 apresenta as médias dos dezoito valores de MR obtidos para cada amostra e os resultados dos testes estatísticos realizados a fim de verificar a influência da adição de cimento no comportamento resiliente das amostras. Foram realizados os testes Shapiro-Wilk, Levene, ANOVA, Kruskal-Wallis e Dunn. O teste de Shapiro-Wilk verifica a normalidade de cada grupo de amostras, por isso apresenta um p-valor para cada condição de moldagem (natural, +2% e +3%). Os testes de Levene, ANOVA e Kruskal-Wallis geram único p-valor, pois analisam a significância estatística da homogeneidade das variâncias, similaridade das médias e populações, respectivamente. O teste de Dunn verifica se há diferenças entre os grupos das amostras, por isso existe um p-valor para cada combinação (Natural e + 2%; Natural e +3%; +2% e +3%). Quando as condições para realização da ANOVA não foram atendidas, procedeu-se o teste de Kruskal-Wallis.

Os resultados dos testes estatísticos indicam que as amostras 11, 16 e 22 não apresentaram diferença estatística, com 95% de certeza, entre os resultados de Módulo de Resiliência para as três condições de ensaio, pois apresentaram o p-valor para o teste ANOVA ou Kruskal-Wallis maior do que 0,05. Para as demais amostras, sabendo que todas as análises foram realizadas ao nível de significância de 5%, pôde-se verificar as diferenças entre os módulos de resiliência das amostras, comparando-as uma a uma para cada condição do corpo de prova. As diferenças estatísticas são constata-

das por meio da análise do valor obtido no teste de Dunn. Quando esse valor é maior do que o nível de significância adotado, interpreta-se que os grupos tendem a apresentar valores iguais da variável em questão. Quando menor, os grupos apresentam valores diferentes. Dessa maneira, tem-se as seguintes comparações:

- Solo natural e solo + 2% de cimento: O incremento de 2% de cimento ao solo natural melhorou, significativamente, os valores de MR de praticamente todas as amostras. Apenas a amostra da jazida 15 não apresentou ganhos ao teor de 2%;
- Solo natural e solo +3% de cimento: A amostra com 3% de cimento da jazida 3 não apresentou mudança no comportamento resiliente quando comparado à amostra de solo natural. As demais jazidas apresentaram ganhos significativos;
- Solo + 2% e solo +3% de cimento: Em apenas 17% das amostras (jazidas 7, 14, 15, 18 e 26) houve diferença significativa do MR entre os teores de 2% e 3%; os resultados das demais amostras indicam que não há diferença entre a adição de 2% ou 3% de aglomerante, ou seja, a adição de 3% de cimento aumentaria o custo do serviço sem incrementar os benefícios mecânicos no que tange ao comportamento resiliente.

Sumarizando as análises da alteração do comportamento resiliente dos materiais em estudo quando melhorados com cimento aos teores de 2% e 3%, verificou-se que a adição do aglomerante teve efeitos benéficos, mas que, na maioria das vezes, não houve diferença nos ganhos no comportamento resiliente quando adicionado 2% ou 3%, sendo então mais econômico adicionar os 2% de aglomerante.

Modelagem das RNAs

A Tabela 2 exemplifica como foram criadas as combinações de treinamento das redes ao tempo que contém a rede de melhor performance, como será descrito adiante. Ao total foram treinadas 648 redes, 216 para cada tipo de algoritmo de treinamento considerado (*Bayesian Regularization*, *Levenberg-Marquardt* e *Gradient Descent*). Os algoritmos de aprendizagem considerados foram *Gradient Descent* (LE-ARNGD) e *Gradient Descent with Momentum* (LEARNMGDM). Todas as redes foram criadas com três camadas, portanto, faz-se necessário o uso de duas funções de transferência, sendo a primeira entre a camada de entrada e a oculta e a segunda entre a camada oculta e a de saída. Nesse trabalho, fez-se todas as combinações possíveis entre as funções do tipo Linear, Logística Sigmoidal e Tangente Hiperbólica para cada um dos algoritmos de treinamento e aprendizagem.

Tabela 1. MR médio e p-valor das análises estatísticas dos resultados do ensaio TCR

| | MR (MPa) | | |
|-----------|----------|------|------|
| | Nat. | 2% | 3% |
| Jazida 1 | 494 | 1074 | 1324 |
| Jazida 2 | 759 | 952 | 1017 |
| Jazida 3 | 810 | 1075 | 936 |
| Jazida 4 | 736 | 1248 | 1280 |
| Jazida 5 | 428 | 1118 | 1386 |
| Jazida 6 | 453 | 1019 | 857 |
| Jazida 7 | 462 | 794 | 1132 |
| Jazida 8 | 529 | 1293 | 1257 |
| Jazida 9 | 709 | 1209 | 1392 |
| Jazida 10 | 429 | 1048 | 1778 |
| Jazida 11 | 788 | 1054 | 1035 |
| Jazida 12 | 628 | 818 | 916 |
| Jazida 13 | 476 | 829 | 760 |
| Jazida 14 | 637 | 730 | 1212 |
| Jazida 15 | 559 | 696 | 1113 |
| Jazida 16 | 726 | 781 | 932 |
| Jazida 17 | 546 | 811 | 883 |
| Jazida 18 | 550 | 773 | 1093 |
| Jazida 19 | 361 | 1028 | 1073 |
| Jazida 20 | 562 | 883 | 1285 |
| Jazida 21 | 517 | 775 | 726 |
| Jazida 22 | 544 | 643 | 644 |
| Jazida 23 | 401 | 705 | 791 |
| Jazida 24 | 413 | 841 | 947 |
| Jazida 25 | 344 | 989 | 1346 |
| Jazida 26 | 312 | 845 | 1320 |
| Jazida 27 | 463 | 1377 | 1658 |
| Jazida 28 | 433 | 1616 | 1787 |
| Jazida 29 | 420 | 1563 | 1497 |

Fonte: Os próprios autores

Para cada configuração de rede foram testadas as arquiteturas com 4, 8, 12, 16, 20, 24, 28, 32, 36, 40, 44 e 48 neurônios na camada oculta, podendo alcançar até 10.000 épocas de treinamento. A performance das redes pode ser mensurada por meio do tempo de processamento, MSE e R^2 .

Após modelagem de todas as RNAs, buscou-se eleger aquela com melhor resultado, baseado nos maiores valores de R^2 e menor valor de MSE. Dos 100% de padrões de entrada das redes com algoritmo de treinamento *Gradient Descent*, 70% foram destinados ao treinamento, 15% para validação e 15% para testes, de forma randômica. Essas redes apresentaram os resultados menos satisfatórios, pois o maior valor de R^2 alcançado foi de 0,8217 para rede com algoritmos e funções transferência LEARNGDM, Tangente Sigmoidal e Linear, respectivamente. Em relação aos erros, o menor MSE gerado foi da ordem de 10^{-3} . Outra característica observada para esse conjunto de treinamento é o pequeno

tempo de processamento e o alcance de 10.000 épocas em praticamente todas as redes.

O conjunto de dados das redes com o algoritmo de treinamento *Levenberg-Marquardt* foram divididos semelhantemente aos do *Gradient Descent* e apresentaram melhores resultados, pois observou-se maiores valores de R^2 (0,9840) e menores valores de MSE ($3,32 \times 10^{-4}$). Em relação ao critério de parada, nenhuma das redes chegou a alcançar 100 épocas de treinamento, pois esse algoritmo é programado a parar se for alcançado o número de seis falhas consecutivas na fase de validação. Esse foi o principal motivo de parada de treinamento dessas redes, que ocorreu na maioria das vezes em frações de segundos.

Por fim, tem-se os resultados das redes construídas com o *Bayesian Regularization*. Esse algoritmo tem por característica desvincular pesos sinápticos não relevantes ao processo de treinamento, além disso, possui critério de validação próprio, não sendo necessária a divisão dos dados de entradas em três fases. Nesse caso, utilizou-se 70% dos dados para treinamento e 30% para teste. Elegeu-se como a melhor rede a de número 101, por apresentar maior valor de R e, conseqüentemente, R^2 (0,9903) – considerado de excelente ajuste – e um dos menores MSE ($2,77 \times 10^{-4}$), com algoritmos de aprendizagem LEARNGD, e as duas funções de transferência do tipo Tangente Sigmoidal. Seu tempo de treinamento foi de 03:44 minutos para 1069 épocas, com arquitetura 16:36:1. Foi constatado que, do número total de pesos (649) que compunham a rede, foram efetivamente utilizados 500.

Presume-se que o bom desempenho do algoritmo de treinamento *Bayesian Regularization* se deu à sua característica de adaptação e generalização para pequenos bancos de dados, pois o banco de dados era composto de apenas 1512 padrões, número não considerado alto para esse tipo de modelagem. Após treinamento da rede, foram extraídos os valores de saída preditos e transformados para a ordem de grandeza original, uma vez que todas as entradas e saídas da rede ocorreram com dados normalizados. Essa etapa fez-se necessária para que se pudesse determinar os coeficientes de regressão do Modelo Composto do Módulo de Resiliência.

Dimensionamento de pavimentos

Após transformação dos dados de saída de MR, antes normalizados, para unidade em MPa, calculou-se o MAE entre os valores ditos reais, obtidos em ensaios laboratoriais e os preditos na modelagem. Objetivou-se identificar as amostras que representassem as condições mais desfavoráveis em termos da predição do MR, para que se pudesse avaliá-las quanto à sua sensibilidade e possíveis conseqüências no dimensionamento de pavimentos e análise de tensões.

Tabela 2. Parte das configurações das RNAs

| | | | | Nº Rede | Arquit. | Épocas | Tempo | MSE | R | R ² |
|--|--------------------------------------|--|--|---------|---------|--------|----------|----------|---------|----------------|
| Treinamento <i>Bayesian Regularization</i> | Aprendizagem <i>Gradient Descent</i> | Função de Transferência (1) Tangente Sigmoidal | Função de Transferência (2) Tangente Sigmoidal | 93 | 16:4:1 | 94 | 00:00:00 | 3,86E-03 | 0,95554 | 0,913057 |
| | | | | 94 | 16:8:1 | 302 | 00:00:03 | 1,40E-03 | 0,98314 | 0,966564 |
| | | | | 95 | 16:12:1 | 237 | 00:00:04 | 9,44E-04 | 0,98834 | 0,976816 |
| | | | | 96 | 16:16:1 | 273 | 00:00:07 | 6,14E-04 | 0,99194 | 0,983945 |
| | | | | 97 | 16:20:1 | 333 | 00:00:12 | 5,23E-04 | 0,99302 | 0,986089 |
| | | | | 98 | 16:24:1 | 968 | 00:00:56 | 4,82E-04 | 0,99355 | 0,987142 |
| | | | | 99 | 16:28:1 | 974 | 00:02:18 | 4,22E-04 | 0,99419 | 0,988414 |
| | | | | 100 | 16:32:1 | 702 | 00:01:33 | 3,98E-04 | 0,99406 | 0,988155 |
| | | | | 101 | 16:36:1 | 1069 | 00:03:44 | 2,77E-04 | 0,99515 | 0,990324 |
| | | | | 102 | 16:40:1 | 2166 | 00:08:32 | 3,32E-04 | 0,99424 | 0,988513 |
| | | | | 103 | 16:44:1 | 977 | 00:05:22 | 3,15E-04 | 0,99333 | 0,986704 |
| | | | | 104 | 16:48:1 | 2539 | 00:14:05 | 2,83E-04 | 0,99508 | 0,990184 |

Fonte: Os próprios autores

Observou-se que quanto maiores os valores de MR, maior o MAE. No geral, as amostras com adição de 3% de cimento alcançaram maiores valores de MR, comparadas àquelas com adição de 2% e as naturais, devido à ordem de grandeza dos valores. Dessa forma, as jazidas 9, 20 e 25 contêm as amostras com maior MAE, na ordem de 100 MPa, sendo todas de solo com adição de 3% de cimento (amostras 27, 60 e 75), como pode ser visto na Tabela 3.

Optou-se por dimensionar seis estruturas de pavimento flexível com três camadas cada, sendo as camadas 1 e 3 o *default* do próprio MeDiNa, assim como os dados de tráfego, e a camada de base, chamada de camada 2, composta das amostras supracitadas. Em relação à adoção do modelo de comportamento resiliente não-linear, três estruturas foram dimensionadas a partir dos resultados dos ensaios, e as demais com os resultados obtidos nas predições com a RNA escolhida. As características físicas da camada 2 também foram definidas a partir de ensaios laboratoriais das amostras. O coeficiente de Poisson e o modelo de Deformação Permanente foram adotados tais quais a Brita Graduada – Gnaisse C1, da base de dados do MeDiNa.

Os coeficientes de regressão k_1 , k_2 e k_3 do Modelo Composto e R^2 para os valores de MR ensaiados e preditos de cada uma das amostras, assim como a área trincada para o fim de período, Afundamento de Trilha de Roda (ATR) total e espessura final de cada camada estão apresentados na Tabela 4. Em relação aos coeficientes de regressão, percebe-se que todos os valores de k_1 , k_2 são positivos, o que indica

o aumento do MR em função da tensão confinante, e que os valores de k_3 foram negativos para as amostras 60 e 75, acarretando menor influência da tensão desvio em seu comportamento. O k_1 alcançou maiores valores para a situação de modelagem com uso dos valores preditos, sendo a amostra 27 a mais afetada, com diferença de aproximadamente 16% em relação ao valor modelado com os dados de ensaio. Comportamento inverso ocorreu para o k_2 , em que os valores preditos resultaram em menores valores desse coeficiente. Para o k_3 , à exceção da amostra 27, os demais valores se apresentaram bem próximos.

Para o dimensionamento dos pavimentos, alterando-se apenas os parâmetros do modelo resiliente da camada de base e fixando os modelos de fadiga e deformação permanente de todos os materiais, percebeu-se que houve redução de 3,3% e 0,2 mm, da área trincada no fim do período de projeto e ATR, respectivamente, para a amostra 27 e 2,7% e 0,1 mm para as amostras 60 e 75 para utilização dos dados preditos em relação aos ditos reais. As reduções apresentadas não acarretaram mudanças das espessuras das camadas da estrutura para as amostras 27 e 75. Apenas a amostra 60 apresentou redução de 1 cm na espessura do concreto asfáltico.

CONCLUSÕES

Os resultados obtidos mostraram que a adição de baixos teores de cimento a solos naturais podem trazer ganhos

Tabela 3. Amostras de maior Erro Médio Absoluto

| Tensão Confi- nante (MPa) | Tensão Desvio (MPa) | Amostra 27 | | Amostra 60 | | Amostra 75 | |
|------------------------------|------------------------|------------------|---------------------|------------------|---------------------|------------------|---------------------|
| | | MR real (MPa) | MR predito (MPa) | MR real (MPa) | MR predito (MPa) | MR real (MPa) | MR predito (MPa) |
| 0.020 | 0.020 | 746 | 848 | 589 | 660 | 967 | 1028 |
| 0.020 | 0.040 | 838 | 793 | 516 | 629 | 859 | 894 |
| 0.020 | 0.060 | 614 | 768 | 668 | 639 | 707 | 827 |
| 0.035 | 0.035 | 1042 | 1111 | 855 | 866 | 984 | 1226 |
| 0.035 | 0.070 | 954 | 1036 | 784 | 874 | 978 | 1065 |
| 0.035 | 0.105 | 976 | 1030 | 940 | 976 | 1018 | 1032 |
| 0.050 | 0.050 | 1242 | 1372 | 1077 | 1225 | 1665 | 1649 |
| 0.050 | 0.100 | 1189 | 1302 | 1080 | 1224 | 1246 | 1429 |
| 0.050 | 0.150 | 1231 | 1348 | 1140 | 1315 | 1197 | 1324 |
| 0.070 | 0.070 | 1487 | 1589 | 1540 | 1655 | 1718 | 1858 |
| 0.070 | 0.140 | 1387 | 1545 | 1434 | 1517 | 1359 | 1565 |
| 0.070 | 0.210 | 1508 | 1640 | 1349 | 1488 | 1280 | 1390 |
| 0.105 | 0.105 | 1765 | 1978 | 1838 | 2050 | 1846 | 2007 |
| 0.105 | 0.210 | 1902 | 2025 | 1694 | 1903 | 1638 | 1759 |
| 0.105 | 0.315 | 1868 | 2090 | 1727 | 1870 | 1513 | 1656 |
| 0.140 | 0.140 | 2084 | 2262 | 2117 | 2260 | 1918 | 2156 |
| 0.140 | 0.280 | 2118 | 2278 | 2005 | 2185 | 1792 | 1951 |
| 0.140 | 0.420 | 2075 | 2270 | 1773 | 1953 | 1549 | 1705 |
| MAE | | 131 | | 129 | | 123 | |

Fonte: Os próprios autores

Tabela 4. Coeficientes de regressão e resultados do dimensionamento de pavimentos

| $MR = k_1 \sigma_3^{k_2} \sigma_d^{k_3}$ | Amostra 27 | | Amostra 60 | | Amostra 75 | |
|--|------------|---------|------------|---------|------------|---------|
| | Ensaiado | Predito | Ensaiado | Predito | Ensaiado | Predito |
| k1 | 6311,95 | 7350,75 | 7027,03 | 7434,74 | 4334,27 | 4691,48 |
| k2 | 0,5512 | 0,5174 | 0,6854 | 0,6643 | 0,5853 | 0,5771 |
| k3 | 0,0033 | 0,0686 | -0,0782 | -0,0712 | -0,2052 | -0,2026 |
| R ² | 0,9854 | 0,9743 | 0,9678 | 0,9722 | 0,9227 | 0,9625 |
| Área trincada (%) | 23,9 | 20,6 | 29,1 | 26,4 | 26,3 | 23,6 |
| ATR total (mm) | 5,2 | 5 | 5,3 | 5,2 | 5,3 | 5,2 |
| Esp. camada 1 (cm) | 5 | 5 | 6 | 5 | 5 | 5 |
| Esp. camada 2 (cm) | 20 | 20 | 20 | 20 | 20 | 20 |
| Esp. camada 3 (cm) | 20 | 20 | 20 | 20 | 20 | 20 |

Fonte: Os próprios autores

quanto à melhoria do comportamento resiliente, mas que se deve observar que não há relação direta entre o aumento do teor e os valores de MR. No caso dessa pesquisa, a adição de 3% do cimento CP II 32 F – RS aos solos estudados não ultrapassou os ganhos para o comportamento resiliente comparados àqueles com adição de 2%.

Em relação à predição dos valores de MR utilizando RNAs, observou-se bons resultados nas modelagens desenvolvidas, em que foram alcançados altos valores de R² (acima de 0,99) concomitante a baixos valores de MSE (da ordem de 10⁻⁴). Apesar da qualidade desses índices estatísticos, houve diferenças nas estimativas de área trincada e ATR no dimen-

sionamento dos pavimentos. As estruturas dimensionadas com os valores preditos subdimensionaram esses parâmetros, mas, apesar disso, apenas uma das amostras apresentou diferença de 1 cm na espessura das camadas de concreto asfáltico.

Os resultados alcançados indicam o grande potencial de utilização de RNAs para predição do comportamento resiliente de solos. Dadas as inúmeras possibilidades de arquitetura, utilização de funções de transferência e algoritmos de aprendizagem, além da possibilidade de verificação da qualidade das redes por outros indicadores de qualidade estatística, somada ao incremento do banco de dados, pode-

-se chegar a resultados cada vez mais próximos dos reais e com consequente similaridade no dimensionamento final dos pavimentos.

REFERÊNCIAS

- Al-Marshoudi, A.S. (2018) "Water Institutional Arrangements of Falaj Al Khatamain in the Sultanate of Oman", *Journal of Earth Science and Engineering*, vol. 8, no. 2, DOI: 10.17265/2159-581x/2018.02.001
- Andavan, S. & Pagadala, V.K. (2019) "A study on soil stabilization by addition of fly ash and lime", *Materials Today: Proceedings*, vol. 22, pp. 1125–112, DOI: 10.1016/j.matpr.2019.11.323
- Chegenizadeh, A. et al. (2022) "Mechanical Properties of Cold Mix Asphalt (CMA) Mixed with Recycled Asphalt Pavement", *Infrastructures*, vol. 7, no. 45, DOI: 10.3390/infrastructures7040045.
- Cheng, Y. et al. (2018), "Engineering and mineralogical properties of stabilized expansive soil compositing lime and natural pozzolans", *Construction and Building Materials*, vol. 187, pp. 1031–1038, DOI: 10.1016/j.conbuildmat.2018.08.061.
- Chiarello, G.P. et al. (2019), "Avaliação estrutural e financeira de pavimento flexível dimensionado pelo Método do DNER (1981) e MEDINA (2019): estudo de caso da duplicação da BR 287 - trecho Santa Cruz do Sul à Tabai/RS", artigo apresentado no 33º Congresso de Pesquisa e Ensino em Transporte da ANPET, Bauneário Comboriú, SC, 10-14 novembro, pp. 1234–1245.
- Choobbasti, A.J., Samakoosh, M.A. & Kutanaei, S.S. (2019), "Mechanical properties soil stabilized with nano calcium carbonate and reinforced with carpet waste fibers", *Construction and Building Materials*, vol. 211, pp. 1094–1104. DOI: 10.1016/j.conbuildmat.2019.03.306.
- Dantas Neto, S.A., Pereira, C.G.F. & Abreu, A.A. (2020), "Stabilization of sandy soil with high content of asphalt emulsion", *Revista Escola de Minas*, vol. 73, no. 2, pp. 163–169. DOI: 10.1590/0370-44672019730118.
- Departamento Nacional de Estradas de Rodagem - DNER (1994), *DNER ME 082/94: Solos - Determinação do limite de plasticidade*, DNER, Rio de Janeiro, pp. 1-3.
- Departamento Nacional de Estradas de Rodagem - DNER (1994), *DNER ME 122/94: Solos - determinação do limite de liquidez - método de referência*, DNER, Rio de Janeiro, pp. 1-7.
- Departamento Nacional de Estradas de Rodagem - DNER (1994), *DNER ME 129/94: Solos - Compactação utilizando amostras não trabalhadas*, DNER, Rio de Janeiro, pp 1-7.
- Departamento Nacional de Estradas de Rodagem - DNER (1994), *DNER-ME 041/94: Solos - preparação de amostras para ensaios de caracterização*, DNER, Rio de Janeiro, pp. 1-4.
- Departamento Nacional de Estradas de Rodagem - DNER (1994), *DNER-ME 049/94 (1994): Solos - determinação do Índice de Suporte Califórnia utilizando amostras não trabalhadas*, DNER, Rio de Janeiro, pp. 1-14.
- Departamento Nacional de Estradas de Rodagem - DNER (1994), *DNER-ME 080/94: Solos - análise granulométrica por peneiramento*, DNER, Rio de Janeiro, pp. 1-4.
- Departamento Nacional de Infraestrutura de Transportes - DNIT (2018), *Norma DNIT 134/2018 ME: Pavimentação - Solos - Determinação do módulo de resiliência - Método de ensaio*, DNIT, Rio de Janeiro, RJ, 18 p.
- Departamento Nacional de Infra-Estrutura de Transportes - DNIT (2006), *Manual de pavimentação*, 3a ed., DNIT, Rio de Janeiro.
- Farh, N.K., Awed, A.M. & El-Badawy, S.M. (2020), "Artificial Neural Network Model for Predicating Resilient Modulus of Silty Subgrade Soil", *American Journal of Civil Engineering and Architecture*, vol. 8, no. 2, pp. 52–55, DOI: 10.12691/ajcea-8-2-4.
- Ferreira, J.G.H.D.M. (2008), Tratamento de dados geotécnicos para predição de módulos de resiliência de solos e britas utilizando ferramentas de data mining, Tese de Doutorado em Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ.
- Franco, F.A.C.P. (2007), Método de dimensionamento mecânico-empírico de pavimentos asfálticos - SISPAV, Tese de Doutorado em Engenharia Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ.
- Haider, S.W., Masud, M.M. & Chatti, K. (2020), "Influence of moisture infiltration on flexible pavement cracking and optimum timing for surface seals", *Canadian Journal of Civil Engineering*, vol. 47, no. 5, pp. 487–497, DOI: 10.1139/cjce-2019-0008.
- Han, B. et al. (2018), "Resilient Interface Shear Modulus for Characterizing Shear Properties of Pavement Base Materials", *Journal of Materials in Civil Engineering*, vol. 30, no. 12, DOI: 10.1061/(ASCE)MT.1943.
- Hanandeh, S., Ardah, A. & Abu-Farsakh, M. (2020), "Using artificial neural network and genetics algorithm to estimate the resilient modulus for stabilized subgrade and propose new empirical formula", *Transportation Geotechnics*, vol. 24, p. 100358. DOI: 10.1016/j.trgeo.2020.100358.
- Hataf, N., Ghadir, P. & Ranjbar, N. (2018), "Investigation of soil stabilization using chitosan biopolymer", *Journal of Cleaner Production*, vol. 170, pp. 1493–1500. DOI: 10.1016/j.jclepro.2017.09.256.
- James, J. (2020), "Sugarcane press mud modification of expansive soil stabilized at optimum lime content: Strength, mineralogy and microstructural investigation", *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 12, no. 2, pp. 395–402, DOI: 10.1016/j.jrmge.2019.10.005.

- Khasawneh, M.A. & Al-jamal, N.F. (2019), "Modeling resilient modulus of fine-grained materials using different statistical techniques", *Transportation Geotechnics*, vol. 21, p. 100263. DOI: 10.1016/j.trgeo.2019.100263.
- Kök, B.V., Mehmet Yılmaz, M. & Geçkil, A. (2012), "The Effect of Cement Stabilized Subgrade on Cost of the Flexible Pavement", *Journal of Engineering Sciences*, vol. 18, no. 3, pp. 165-172, DOI: 10.5505/pajes.2012.39974.
- Martins, H.M. & Belchior, I.M.R.M. (2018), "Estabilização de um solo argiloso com rejeito de beneficiamento de carvão para sub-base e subleito de pavimentos", *Revista Técnico-Científica de Engenharia Civil*, vol. 1, pp. 69–84.
- Mello, L.B. et al. (2021) "Solo-Brita em Bases de Pavimentos Flexíveis: Avaliação quando à Fadiga Utilizando o MeDiNa", *Anuário do Instituto de Geociências*, vol. 44, pp. 1–13, DOI: 10.11137/1982-3908_2021_44_35192
- Miraki, H. et al. (2022), "Clayey soil stabilization using alkali-activated volcanic ash and slag", *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 14, no. 2, pp. 576–591. DOI: 10.1016/j.jrmge.2021.08.012.
- Oluyemi-Ayibiowu, B.D. (2019), "Stabilization of lateritic soils with asphalt-emulsion", *Nigerian Journal of Technology*, vol. 38, no. 3, p. 603. DOI: 10.4314/njt.v38i3.9.
- Qian, J. et al. (2020), "Resilient properties of soil-rock mixture materials: Preliminary investigation of the effect of composition and structure", *Materials*, vol. 13, no. 7, DOI: 10.3390/ma13071658.
- Ren, J. et al. (2019), "The resilient moduli of five Canadian soils under wetting and freeze-thaw conditions and their estimation by using an artificial neural network model", *Cold Regions Science and Technology*, vol. 168. DOI: 10.1016/j.coldregions.2019.102894.
- Ribeiro, A.J.A. (2016), Um modelo de previsão do módulo de resiliência dos solos no estado do ceará para fins de pavimentação, Tese de Doutorado em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, CE, disponível em: <https://repositorio.ufc.br/handle/riufc/18958>
- Saha, S. et al. (2018), "Use of an Artificial Neural Network Approach for the Prediction of Resilient Modulus for Unbound Granular Material", *Transportation Research Record*, vol. 2672, no. 52, pp. 23–33. DOI: 10.1177/0361198118756881.
- Silva, J.A., Bello, M.I.M.C.V. & Ferreira, S.R.M. (2020), "Comportamento geotécnico de um solo expansivo estabilizado com cinza de casca de arroz e cal hidratada", *Journal of Environmental Analysis and Progress*, vol. 5, no. 2, pp. 232–256. DOI: 10.24221/jeap.5.2.2020.3205.232-256.
- Solanki, P., Zaman, M. & Ebrahimi, A. (2009), "Regression and artificial neural network modeling of resilient modulus of subgrade soils for pavement design applications", in Gopalakrishnan, K., Celylan, H. & Attoh-Okine (ed.), *Intelligent and Soft Computing in Infrastructure Systems Engineering: Recent Advances*, Berlin, Springer, pp. 269–304. DOI: 10.1007/978-3-642-04586-8_10.
- Solihu, H. (2020), "Cement Soil Stabilization as an Improvement Technique for Rail Track Subgrade, and Highway Subbase and Base Courses: A Review", *Journal of Civil and Environmental Engineering*, vol. 10, no. 3, DOI: 10.37421/jcde.2020.10.344.
- Vendrusculo, J.I. et al. (2018), "Comparação entre pavimentos dimensionados com os Métodos do DNER (1981) E MEDINA(2018): Estudo de caso com solos de subleito da cidade de Santa Maria/RS", artigo apresentado no 32º Congresso de Pesquisa e Ensino em Transporte da ANPET, Gramado, Rio Grande do Sul, 4-7 novembro, pp. 1190-1199.
- Viana, H.M.F. (2007), Estudo do comportamento resiliente dos solos tropicais grossos do interior do Estado de São Paulo, Tese de Doutorado em Engenharia Civil, Universidade de São Paulo, São Paulo, SP, disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18143/tde-07042008-111017/publico/HELIOVIANA.pdf>
- Zeghal, M. & Khogali, W. (2005), "Predicting the resilient modulus of unbound granular materials by neural networks", artigo apresentado no BCRA 2005, Trondheim, Norway, 27-29 June, pp. 1–9.

Recebido: 16 jan. 2023

Aprovado: 2 mai. 2023

DOI: 10.20985/1980-5160.2023.v18n1.1856

Como citar: Costa, S.C.F.E., Lucena, A.E.F.L., Paiva, W. (2023). Análise e predição do comportamento resiliente de solos com adição de cimento empregando-se técnicas de inteligência artificial. *Revista S&G* 18, 1. *Revista S&G* 18, 1. <https://revistasg.emnuvens.com.br/sg/article/view/1856>