



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES

MATHEUS JESUS RIBEIRO ARAÚJO

**ANÁLISE DO COMPORTAMENTO PLÁSTICO DE SOLOS PARA OTIMIZAÇÃO
DOS ENSAIOS DE DEFORMAÇÃO PERMANENTE EM PAVIMENTOS**

FORTALEZA

2023

MATHEUS JESUS RIBEIRO ARAÚJO

ANÁLISE DO COMPORTAMENTO PLÁSTICO DE SOLOS PARA OTIMIZAÇÃO DOS
ENSAIOS DE DEFORMAÇÃO PERMANENTE EM PAVIMENTOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia de Transportes. Área de concentração: Infraestrutura de Transportes.

Orientadora: Profa. Dra. Suelly Helena de Araújo Barroso.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a)
autor(a)

- A69a Araújo, Matheus Jesus Ribeiro.
Análise do Comportamento Plástico de Solos para Otimização dos Ensaios de Deformação Permanente em Pavimentos / Matheus Jesus Ribeiro Araújo. – 2023.
135 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2023.
Orientação: Profa. Dra. Suelly Helena de Araújo Barroso.
1. pavimentos. 2. modelos de previsão. 3. Redes Neurais Artificiais. 4. Random Forest. 5. Deformação Permanente. I. Título.

CDD 388

MATHEUS JESUS RIBEIRO ARAÚJO

ANÁLISE DO COMPORTAMENTO PLÁSTICO DE SOLOS PARA OTIMIZAÇÃO DOS
ENSAIOS DE DEFORMAÇÃO PERMANENTE EM PAVIMENTOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia de Transportes. Área de concentração: Infraestrutura de Transportes.

Aprovada em: 15/09/2023.

BANCA EXAMINADORA

Profa. Dra. Suelly Helena de Araújo Barroso (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Jorge Barbosa Soares
Universidade Federal do Ceará (UFC)

Prof. Dr. Antônio Júnior Alves Ribeiro
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Prof. Dr. Luiz Guilherme Rodrigues de Mello
Departamento Nacional de Infraestrutura de Transportes (DNIT)

A Deus.

Aos meus pais, família e amigos.

AGRADECIMENTOS

À Instituição Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) e ao Departamento Nacional de Infraestrutura de Transportes (DNIT), pelo apoio financeiro durante o mestrado. À Universidade Federal do Ceará (UFC), especificamente ao Programa de Pós Graduação em Engenharia de Transportes (PETRAN), por todo o conhecimento passado dentro e fora de sala de aula. Agradeço a todos os professores que me proporcionaram a oportunidade de adquirir experiências essenciais na construção de habilidades acadêmicas e práticas na Engenharia de Transportes.

Aos colegas da turma de mestrado, por compartilharem as angústias desse processo e por muitas vezes me ajudarem em minhas limitações. Ao Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Campus Juazeiro (IFCE) e a meus companheiros no laboratório de solos, por toda ajuda prestada, na adaptação à nova instituição e na realização dos numerosos ensaios. Ao grupo envolvido no projeto DNIT, em especial ao Francisco de Assis Franco Vieira, pelo treinamento necessário e auxílio na execução de grande parte dos ensaios envolvidos nesta dissertação.

À Profa. Dra. Suelly Helena de Araújo Barroso, pela excelente orientação. Agradeço por toda atenção, dedicação e cuidado durante esta pesquisa de mestrado, tendo sido uma excelente profissional e ser humano. Ao Prof. Dr. Antônio Júnior Alves Ribeiro, por me receber com tanto entusiasmo em seu laboratório, por diariamente dedicar sua atenção no auxílio aos trabalhos experimentais e acadêmicos. Foi incrível conhecer e trabalhar com profissionais como vocês. Também agradeço aos professores participantes da banca examinadora Jorge Barbosa Soares e Luiz Guilherme Rodrigues de Mello, pela disposição e pelas valiosas colaborações e sugestões.

A toda minha família, por sempre incentivarem meu crescimento profissional, e por demonstrarem sua presença e auxílio em momentos delicados. À minha mãe, por todo esforço incansável durante toda a minha trajetória até aqui, mesmo diante de todas as adversidades. Também agradeço a meus amigos, com os quais sempre pude contar para tratar a vida de forma mais leve e “equilibrada”. Finalmente, agradeço de todo coração a todas as pessoas que me receberam com tanto carinho e acolhimento em seu lar, no Juazeiro do Norte. Muito obrigado pela generosidade de todas vocês, em especial dona Quinha.

“Quanto custa um sonho?

Alguma coisa ele sempre custa.

Muitas vezes muitas coisas ele custa,
outras vezes outros sonhos ele custa.

Não importam os percalços, os sacrifícios,
os espinhosos enredos.

Não importa.

Uma vez vivido,

o sonho está sempre num ótimo preço!” (Elisa
Lucinda)

RESUMO

As novas diretrizes do Método de Dimensionamento Nacional (MeDiNa) propõem a utilização da Deformação Permanente (DP) na análise do comportamento plástico de solos do subleito e das camadas estruturais de pavimentos asfálticos. Entretanto, fatores como o tempo do procedimento de laboratório e os custos relacionados ao equipamento triaxial podem dificultar e onerar essa prática. Nesse sentido, esta pesquisa sugere a análise dos parâmetros do ensaio de DP para o desenvolvimento de modelos de previsão otimizados de materiais geotécnicos aplicados em pavimentos. Para tanto, foram analisadas 7 amostras representativas de solos do estado do Ceará. Após a caracterização da DP dos solos por 9 pares de tensão e 150.000 ciclos de aplicação de carga, foram desenvolvidas 3 principais abordagens. Na primeira abordagem, foi realizado o ajuste de modelos de previsão, baseados em propriedades geotécnicas e índices físicos, utilizando algoritmos de Random Forest e Redes Neurais Artificiais. Ambos os modelos chegaram a um desempenho satisfatório, com coeficientes de correlação (R^2) superiores a 0,99, sendo ainda comparadas estratégias de identificação das variáveis mais relevantes. Na segunda abordagem, foram implementadas redes neurais na previsão do comportamento plástico de solos em cada ensaio de estágio único. Após a definição de uma arquitetura ótima, foi possível selecionar uma metodologia para facilitar a caracterização dos solos com um número reduzido de ciclos de aplicação de cargas. Assim, foram retirados os 1.000 ciclos iniciais do ensaio de DP no treinamento dos modelos, verificando-se que os afundamentos de trilha de roda obtidos no software MeDiNa com a redução para 30.000 ciclos de carga foram similares aqueles com 150.000 ciclos recomendados pela norma. Na terceira abordagem, foi analisada a redução de ciclos em ensaios que apresentaram shakedown plástico. O método indicado não gerou erros significativos nos afundamentos obtidos após cerca de 30.000 ciclos, enquanto o desenvolvimento de uma árvore de decisão permitiu a identificação de ensaios na faixa A de acomodamento dentro dos primeiros 10.000 ciclos. Desse modo, espera-se que os resultados deste trabalho permitam a análise preliminar de materiais para uso em obras de pavimentação à luz da mecânica dos pavimentos, assim como favoreçam a redução do período de ensaio de deformação permanente, promovendo economia de tempo e recursos na construção de rodovias.

Palavras-chave: pavimentos; modelos de previsão; Redes Neurais Artificiais; Random Forest; Deformação Permanente; materiais granulares.

ABSTRACT

The new guidelines of the National Design Method (MeDiNa) propose the use of Permanent Deformation (PD) in the analysis of the plastic behavior of subgrade soils and structural layers of flexible pavements. However, factors such as laboratory procedure time and the cost of triaxial equipment might jeopardize this method. In this sense, this research suggests the analysis of PD test parameters for the development of optimized prediction models for geotechnical materials applied to pavement. For this purpose, 7 representative soil samples from the state of Ceará were assessed. After characterizing the PD of the soils using 9 stress pairs and 150,000 load application cycles, 3 main approaches were developed. In the first approach, predictive models based on geotechnical properties and physical indices were adjusted using Random Forest algorithms and Artificial Neural Networks. Both models performed satisfactorily, with correlation coefficients (R^2) greater than 0.99. In the second approach, neural networks were implemented to predict the plastic behavior of soils in each single-stage test. After defining an optimal architecture, it was possible to identify a methodology to facilitate soil characterization with a reduced number of load application cycles. Thus, the initial 1,000 cycles of the PD test were removed when training the models, verifying that the rutting obtained from the MeDiNa software by reducing to 30,000 load cycles were similar to those with 150,000 cycles recommended by the regulations. The third approach analyzed the reduction of cycles in tests that showed plastic shakedown. The recommended method did not generate significant errors in the rutting obtained after around 30,000 cycles, while the development of a decision tree enabled the classification of tests in the A range of accommodation within the first 10,000 cycles. It is therefore hoped that the results of this work will permit the preliminary analysis of materials for use in paving works in the light of pavement mechanics, as well as helping to reduce the Permanent Deformation test period, thereby saving time and resources in road construction.

Keywords: pavements; prediction models; Artificial Neural Networks; Random Forest; Permanent Deformation; granular materials.

LISTA DE ABREVIATURAS E SIGLAS

AEMC	Análise Elástica de Múltiplas Camadas
ATR	Afundamentos de Trilha de Roda
AASHTO	<i>American Association of State Highway and Transportation Officials</i>
CBR	<i>California Bearing Ratio</i>
DNIT	Departamento Nacional de Infraestrutura de Transportes
DNER	Departamento Nacional de Estradas de Rodagem
DP	Deformação Permanente
MeDiNa	Método de Dimensionamento Nacional
MR	Módulo de Resiliência
RF	<i>Random Forest</i>
RLT	<i>Repeated Load Triaxial</i>
RMSE	<i>Root Mean Squared Error</i>
RNA	Redes Neurais Artificiais

LISTA DE FIGURAS

Figura 1 – Metodologia proposta para o Artigo 1.....	21
Figura 2 – Metodologia proposta para o Artigo 2.....	21
Figura 3 – Metodologia proposta para o Artigo 3.....	21
Figura 4 – Metodologia de condução para Revisões Sistemáticas	24
Figura 5 – Apresentação do critério PICOC para definição da revisão apresentada.....	25
Figura 6 – Relação entre os trabalhos aceitos na seleção inicial e a base de dados de origem	26
Figura 7 – Relação entre os trabalhos aceitos na seleção inicial e a base de dados de origem para a segunda busca	27
Figura 8 – Processo de seleção das publicações	28
Figura 9 – Localização dos pontos de extração das amostras de solo estudadas	41
Figura 10 – Estrutura de um Perceptron com uma única camada escondida	47
Figura 11 – Matriz de correlação entre as variáveis propostas.....	51
Figura 12 – Deformação acumulada em cada solo nos ensaios realizados	52
Figura 13 – Definição dos parâmetros de entrada do modelo de RF no Rstudio.....	55
Figura 14 – Variação do RMSE pelo número de épocas	56
Figura 15 – Gráficos de dispersão entre valores previstos e observados para a base de treinamento e teste dos modelos de RF e RNA.....	57
Figura 16 – Distribuição dos erros gerados pelos modelos	58
Figura 17 – Contribuição das variáveis para os modelos desenvolvidos	59
Figura 18 – Estágios do comportamento plástico de solos frente à aplicação de cargas sucessivas	66
Figura 19 – Divisão dos dados para um ensaio de estágio único quanto à adoção da metodologia proposta	75
Figura 20 – Duração em ensaio em horas para os intervalos de ciclos propostos.....	76
Figura 21 – Representação básica da abordagem proposta para arquitetura das redes neurais	78
Figura 22 – Composição da estrutura de pavimento flexível proposta	79
Figura 23 – Resultados para os ensaios de DP realizados nos pares de tensão analisados	81
Figura 24 – Variação do RMSE pelo número de neurônios para as 5 amostras de solo, considerando 3 camadas escondidas	84
Figura 25 – Variação RMSE pela progressão do número de épocas para as 5 amostras de solo,	

considerando a melhor arquitetura identificada (15 neurônios em 3 camadas escondidas).....	85
Figura 26 – Valores observados pelos valores previstos nas bases de teste dos ensaios de estágio único a 80 kPa × 240 kPa.....	86
Figura 27 – ATR obtido para cada condição de teste – solo A3	87
Figura 28 – ATR obtido para cada condição de teste – solo A1	87
Figura 29 – ATR obtido para cada condição de teste – solo A2-1.....	88
Figura 30 – ATR obtido para cada condição de teste – solo A4-1.....	88
Figura 31 – ATR obtido para cada condição de teste – solo A6	88
Figura 32 – Erro absoluto de ATR entre os testes realizados e os valores de ensaio a 150.000	90
Figura 33 – Comparação entre os valores previstos e ensaiados de DP para duas amostras de solo separadas para validação	92
Figura 34 – Classificação do shakedown.....	98
Figura 35 – Definição de critérios de classificação entre as faixas B e C	100
Figura 36 – Premissas de metodológicas quanto à classificação dos solos e implementação no MeDiNa.....	104
Figura 37 – Variação da taxa de crescimento da DP pela deformação vertical acumulada..	109
Figura 38 – Impacto da redução de ciclos no ATR obtido em ensaios na faixa A.....	113
Figura 39 – Avaliação de desempenho para otimização e estrutura pós-poda da AD proposta	114
Figura 40 – Interface e código de acesso ao aplicativo online desenvolvido para demonstração do método proposto.....	119

LISTA DE TABELAS

Tabela 1 –	<i>Strings</i> de busca utilizados na pesquisa.....	25
Tabela 2 –	Resumo dos principais aspectos sobre os modelos de previsão da Deformação Permanente para a literatura selecionada	32
Tabela 3 –	Principais configurações do ensaio de Deformação Permanente utilizadas pelos autores	33
Tabela 4 –	Resumo de parâmetros utilizados na construção de modelos de previsão da DP por propriedades físicas de solos	39
Tabela 5 –	Conjunto de pares de tensão sugeridos	43
Tabela 6 –	Comportamento da função ReLU e de sua derivada.....	48
Tabela 7 –	Estatísticas básicas da base de dados	50
Tabela 8 –	Caracterização das amostras de solo	50
Tabela 9 –	Impacto no RMSE de testes após a retirada de variáveis por algoritmos de RandomForest	60
Tabela 10 –	Parâmetros de ensaio da DP em diferentes regiões do mundo.....	68
Tabela 11 –	Caracterização das amostras de solo	73
Tabela 12 –	Configurações de ensaio de DP propostas pela norma DNIT (2018a).....	73
Tabela 13 –	Exemplo da configuração de banco de dados para um ensaio de estágio único para o caso da amostra A3 80x80.....	74
Tabela 14 –	Funções de erro delimitadas para problemas de regressão na biblioteca h2o	77
Tabela 15 –	Principais resultados dos ensaios de caracterização básica e MR.....	80
Tabela 16 –	Critérios de shakedown propostos na literatura	101
Tabela 17 –	Intervalos de variação da DP propostos como parâmetros de entrada	107
Tabela 18 –	Principais resultados dos ensaios de caracterização básica e MR.....	108
Tabela 19 –	Classificação dos solos quanto ao shakedown	111
Tabela 20 –	Matriz de confusão da AD gerada	115
Tabela 21 –	Medidas de avaliação do desempenho da AD.....	116

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Problema de pesquisa	17
1.2	Justificativa	17
1.3	Objetivos	19
<i>1.3.1</i>	<i>Objetivo geral</i>	19
<i>1.3.2</i>	<i>Objetivos específicos</i>	19
1.4	Estrutura da dissertação	19
2	REVISÃO SISTEMÁTICA SOBRE O DESENVOLVIMENTO DE MODELOS DE PREVISÃO DA DEFORMAÇÃO PERMANENTE DE SOLOS	23
2.1	Introdução	23
2.2	Métodos	24
2.3	Seleção bibliográfica de publicações sobre o desenvolvimento de modelos de previsão da Deformação Permanente	26
2.4	Análise qualitativa dos resultados sobre a Deformação Permanente	28
<i>2.4.1</i>	<i>Previsão da DP de solos a partir de coeficientes de modelos constitutivos</i>	28
<i>2.4.2</i>	<i>Previsão direta da DP de solos</i>	30
2.5	Conclusões	34
3	PREVISÃO DA DEFORMAÇÃO PERMANENTE DE SOLOS UTILIZANDO DIFERENTES ALGORITMOS DE MACHINE LEARNING	36
3.1	Introdução	36
3.2	Preparação dos dados a partir da coleta e ensaios nos solos	41
3.3	Modelos de previsão	43
<i>3.3.1</i>	<i>Modelagem com Random Forests</i>	44
<i>3.3.2</i>	<i>Modelagem com Artificial Neural Networks</i>	46
<i>3.3.3</i>	<i>Parâmetros de desempenho</i>	49
3.4	Resultados e discussões	50
<i>3.4.1</i>	<i>Análise do comportamento das variáveis das amostras ensaiadas</i>	50
<i>3.4.2</i>	<i>Desenvolvimento do Modelo de Random Forest</i>	54
<i>3.4.3</i>	<i>Desenvolvimento do modelo de RNA</i>	55
<i>3.4.4</i>	<i>Análise do desempenho dos modelos</i>	56
<i>3.4.5</i>	<i>Análise de sensibilidade e seleção de variáveis de entrada</i>	58
3.5	Conclusões	61
4	APLICAÇÃO DE MACHINE LEARNING NA PREVISÃO DA DEFORMAÇÃO	

	PERMANENTE DE SOLOS EM ENSAIOS DE ESTÁGIO ÚNICO.....	63
4.1	Introdução	63
4.2	Fundamentação teórica	65
4.2.1	<i>Deformação Permanente</i>	<i>65</i>
4.2.2	<i>Método MeDiNa de dimensionamento de pavimentos brasileiros</i>	<i>69</i>
4.2.3	<i>Redes Neurais Artificiais</i>	<i>70</i>
4.3	Materiais e métodos	72
4.3.1	<i>Materiais.....</i>	<i>72</i>
4.3.2	<i>Organização da base de dados.....</i>	<i>74</i>
4.3.3	<i>Definição dos parâmetros do modelo</i>	<i>76</i>
4.3.4	<i>Testes no MeDiNa</i>	<i>78</i>
4.4	Resultados e discussões.....	80
4.4.1	<i>Modelo neural.....</i>	<i>80</i>
4.4.2	<i>Avaliação dos valores de ATR obtidos</i>	<i>86</i>
4.4.3	<i>Sugestão de aplicação da metodologia abordada na redução do tempo de procedimento nas parametrizações brasileiras 179/2018 - IE (DNIT, 2018a)</i>	<i>92</i>
4.5	Conclusões	93
5	IDENTIFICAÇÃO DE NOVOS CRITÉRIOS DE PARADA PARA ENSAIOS DE DEFORMAÇÃO PERMANENTE DE MATERIAIS GRANULARES.....	95
5.1	Introdução	95
5.2	Referencial teórico	97
5.2.1	<i>Análise da deformação permanente</i>	<i>97</i>
5.2.2	<i>A Abordagem Empírica-Mecanicista</i>	<i>101</i>
5.3	Materiais e métodos	102
5.3.1	<i>Materiais.....</i>	<i>102</i>
5.3.2	<i>Experimentos</i>	<i>102</i>
5.3.3	<i>Análise do impacto da redução do número de ciclos</i>	<i>103</i>
5.3.4	<i>Seleção de critérios de classificação shakedown por Árvore de Decisão</i>	<i>104</i>
5.3.5	<i>Parâmetros de entrada</i>	<i>106</i>
5.3.6	<i>Critérios de avaliação dos modelos de Árvore de Decisão</i>	<i>107</i>
5.4	Resultados e discussões.....	107
5.4.1	<i>Classificação dos solos.....</i>	<i>107</i>
5.4.2	<i>Impacto da interrupção dos ensaios Tipo A na obtenção do ATR pelo software MeDiNa</i>	<i>111</i>

5.4.3	<i>Critério preliminar de classificação para o conjunto de amostras</i>	113
5.5	Conclusões	116
6	PRINCIPAIS CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.	119
6.1	Principal contribuição do trabalho	119
6.2	Principais limitações do trabalho	120
6.3	Principais conclusões com relação à revisão da literatura	120
6.4	Principais conclusões do artigo 1	120
6.5	Principais conclusões do artigo 2	121
6.6	Principais conclusões do artigo 3	121
6.7	Sugestão para futuros trabalhos	122
	REFERÊNCIAS	123

1 INTRODUÇÃO

Por muitos anos o Departamento Nacional de Estradas de Rodagem (DNER), atual Departamento Nacional de Infraestrutura de Transportes (DNIT), definiu como método vigente para a concepção de estruturas rodoviárias a abordagem empírica desenvolvida pelo professor Murilo Lopes de Sousa. Essa estratégia baseou-se na avaliação da capacidade de suporte dos materiais granulares, a partir do ensaio *California Bearing Ratio* (CBR), de maneira a proteger a camada de subleito de deformações elevadas. Embora traga certa praticidade e economia, sobretudo pela adequação atual das empresas aos procedimentos necessários, a utilização do CBR não garante a correta caracterização de materiais quanto à influência de cargas dinâmicas aplicadas pelo tráfego, levando as rodovias a ter um desempenho observado muitas vezes inferior ao esperado (BERNUCCI *et al.*, 2008; DNIT, 2020).

Diante disso, vem sendo implementado um novo método de dimensionamento de pavimentos mecanístico-empírico, o Método de Dimensionamento Nacional de Pavimentos (MeDiNa). Essa mudança busca aprimorar a análise do comportamento das camadas constituintes frente às tensões e deformações, além de otimizar o uso de materiais potencialmente descartados pela abordagem anterior. Assim, o novo software de dimensionamento de pavimentos asfálticos MeDiNa opera uma análise elástica de camadas múltiplas por meio de uma rotina de Análise Elástica de Múltiplas Camadas (AEMC) para minimizar a fadiga de misturas asfálticas e as deformações acumuladas (DNIT, 2020).

A análise das camadas das rodovias necessita então de parâmetros de entrada que descrevam o comportamento dos materiais empregados em cada uma delas. Para a caracterização de solos e materiais granulares, são necessários os ensaios de Módulo de Resiliência (MR) e Deformação Permanente (DP). Ambos os procedimentos são executados por meio do Equipamento Triaxial de Cargas Repetidas, capaz de verificar o comportamento resiliente e plástico diante das ações de carregamentos dinâmicos. Entretanto, uma série de fatores - como os custos associados à aquisição e manutenção do equipamento e o tempo necessário para os ensaios - dificulta a ampla execução dos ensaios mencionados.

Dessa maneira, é necessária a criação de métodos e ferramentas capazes de facilitar a obtenção de tais propriedades de forma otimizada, trazendo flexibilidade aos projetistas quanto aos resultados, considerando uma certa margem de erro (TITI *et al.*, 2015). Órgãos como *American Association of State Highway and Transportation Officials* (AASHTO) sugerem a criação de correlações entre parâmetros de rigidez como o MR e propriedades e índices físicos de solos. Todavia, o método especifica que um programa experimental completo ainda se faz

necessário para rodovias de tráfego pesado, nas quais o nível de precisão requerido é mais severo (ZHOU *et al.*, 2015; HOSSAIN, 2009).

Com esse objetivo, diversos modelos de previsão foram desenvolvidos na estimação do MR de materiais geotécnicos por características associadas à granulometria, compactação e limites de consistência (MALA e JOSHI *et al.*, 2007; HOSSAIN *et al.*, 2009; NAZZAL e TATARI *et al.*, 2013; KIM *et al.*, 2015; RIBEIRO, 2016; KHASAWNEH *et al.*, 2019; GHORBANI *et al.*, 2020; HEIDARABADIZADEH *et al.*, 2021; CHOWDHURY *et al.*, 2021; IKEAGWUANI *et al.*, 2021). Entretanto, a variedade de métodos e ferramentas utilizados na obtenção do MR não é observada em estudos relacionados à DP (PUPPALA e MOHAMMED *et al.*, 1999; ALNEDAWI *et al.*, 2019; CABRAL *et al.*, 2020).

Nesse sentido, atribui-se a ideia de que materiais granulares com elevados valores de MR estariam associados a baixos valores de DP, o que nem sempre ocorre. Alguns solos, mesmo apresentando valores de MR satisfatórios para uso em obras de pavimentação, também podem resultar em deformações acumuladas elevadas (PUPPALA *et al.*, 1999; VENKATESH *et al.*, 2020). Desse modo, a caracterização de resultados apenas em relação às deformações resilientes de materiais a serem utilizados em camadas de pavimentos pode implicar em defeitos relacionados a deformações plásticas excessivas. Conseqüentemente, afundamentos elevados irão implicar no surgimento progressivo de diversos tipos de trincas, resultado em um processo de deterioração precoce (BA, 2015; LUO *et al.*, 2017; GU *et al.*, 2020).

Além disso, é importante atentar-se aos padrões e características de ensaios internacionais, que divergem das especificações brasileiras de modo geral na caracterização do comportamento plástico de materiais geotécnicos. Em algumas regiões (como Europa e Austrália), as parametrizações quanto ao número de ciclos de aplicação, a frequência de ensaio, número e magnitude dos pares de tensão aplicados e o tipo de sequência de ensaio (estágio único ou múltiplo) diverge das indicações observadas na norma proposta pelo método MeDiNa. Uma vez que essas características afetam diretamente nas deformações acumuladas obtidas, a adequação de novos modelos torna-se necessária, assim como o direcionamento de novas propostas para solucionar problemas específicos dessa abordagem.

Nesse sentido, faz-se necessário a construção de novos estudos que se voltem para a caracterização de amostras de solo brasileiros quanto à DP e o desenvolvimento de modelos de previsão baseados nas parametrizações propostas pelo método MeDiNa. A princípio, a caracterização de amostras representativas não só contribui para a formação de um banco de dados relevante, como também proporciona um panorama geral sobre o comportamento dos solos de área específica. Paralelamente, à proporção que permitem obter de forma preliminar

informações importantes para o dimensionamento de pavimentos, a modelagem das deformações plásticas acumuladas pode contribuir de diversas formas na construção e manutenção de estruturas mais duráveis.

1.1 Problema de pesquisa

O dimensionamento de pavimentos asfálticos pelo novo método mecanístico-empírico MeDiNa requer a avaliação da Deformação Permanente dos solos utilizados em camadas granulares e subleito para o projeto de pavimentos asfálticos duráveis. Entretanto, sua obtenção demanda tempo e recursos consideráveis, sobretudo comparada às abordagens em estágio múltiplo, o que pode dificultar a execução dos ensaios laboratoriais e a obtenção da DP. Desse modo, é possível que a caracterização inadequada ou ausência de análise dessa propriedade no projeto de rodovias possa reduzir a vida útil dessas estruturas.

1.2 Justificativa

Existe uma série de fatores que podem restringir a execução de ensaios de DP. A princípio, a disponibilidade do equipamento triaxial no país é muitas vezes limitada aos centros de pesquisa, especialmente devido aos custos de aquisição de cerca de R\$ 650.000,00 (cotação de julho de 2021). Para além disso, também se destaca a necessidade de equipes especializadas no manuseio e manutenção (GHORBANI *et al.*, 2020; HEIDEBARADIZANEH *et al.*, 2021). Nesse cenário, o preço atribuído aos ensaios laboratoriais utilizando o equipamento supera consideravelmente custos de execução de ensaios convencionais.

Pelas parametrizações da norma brasileira (DNIT, 2018a), a execução do ensaio de Deformação Permanente pode levar cerca de 21 horas para um único par de tensões em ensaios de estágio único, sendo aplicada a frequência sugerida de 2 Hz. Embora busque se adequar às especificidades das propriedades identificadas nos solos brasileiros pela pesquisa de Guimarães (2009), essa abordagem demanda um período de ensaio de cerca de 9 dias úteis (9 pares de tensão sugeridos). Esse intervalo é superior aos procedimentos propostos em outras regiões, como Europa e Austrália (CEN, 2004) e Austrália (AUSTROADS, 2007).

Ambas as normas internacionais citadas propõem a aplicação de 10.000 ciclos no equipamento triaxial de cargas repetidas, em ensaios de estágio múltiplo. O tempo médio do procedimento para, no mínimo 3 pares de tensão, deve ser inferior a 4 horas e meia para cada amostra de solo. Também é possível citar o procedimento proposto por Puppala, Saride e

Chomtid (2009), conduzido para a análise da deformação de solos americanos, que tem duração ainda menor. Esse método também foi adaptado para estudos como o de Rahman, Islam e Gassman (2021), e orienta a avaliação de diversos pares de tensão entre 3000 e 2500 ciclos de aplicação para diferentes tipos de solos, o que representa menos de uma hora com o uso de 2 Hz de frequência.

Uma das consequências desse cenário é a adoção de métodos menos assertivos em relação à previsão do comportamento dos pavimentos, como métodos empíricos, muitas vezes baseados em ensaios como o CBR, ou mesmo a análise de amostras unicamente pelo Módulo de Resiliência. Uma vez que nem sempre é possível avaliar corretamente o comportamento de um solo por essas estratégias, as rodovias construídas podem apresentar vida útil menor que o período de projeto.

Entretanto, a quantidade de dados sobre a DP de solos nacionais é severamente limitada para a maior parte das regiões. Diante disso, a análise do comportamento plástico dos solos brasileiros se torna ainda mais desafiadora. Assim, os aspectos levantados não só dificultam a tomada de decisão preliminar em obras de pavimentação como também não favorecem o processo de calibração e desenvolvimento de modelos de previsão.

Por essa razão, é preciso ponderar sobre a possibilidade de estabelecer correlações baseadas em propriedades mais simples e usando técnicas de Inteligência Artificial (IA), especialmente para emprego em obras de baixo e médio volume de tráfego. Autores como Alnedawi *et al.* (2019), Cabral *et al.* (2020) e Rahman *et al.* (2021) desenvolveram modelos de previsão para obter as deformações acumuladas de solos em diferentes pares de tensão, além de investigarem a adaptação de Rede Neurais Artificiais e modelos estatísticos ao comportamento em cada estado de tensão. Essa estratégia se mostrou promissora, à medida que o desempenho dos modelos foi satisfatório em relação aos erros e grau de ajuste.

Dessa forma, a aplicação de modelos de previsão pode se tornar um método efetivo para aprimorar e facilitar a implementação da caracterização de DP de solos nas diretrizes brasileiras. Todavia, ainda é necessário investigar essa metodologia de acordo com as especificações nacionais, uma vez que a literatura abrange apenas ensaios de estágio múltiplo e intervalos de ciclos inferiores a 10.000. Por fim, a análise dos parâmetros de ensaio e delimitação de critérios de parada, com foco no procedimento nacional, pode impactar positivamente no tempo e custos de associados ao programa laboratorial.

1.3 Objetivos

1.3.1 Objetivo geral

Investigar ferramentas e métodos para otimizar a obtenção da Deformação Permanente de solos para facilitar a aplicação de métodos de dimensionamento mecanístico-empírico, baseados na análise de ensaios a longos intervalos de ciclos de carga.

1.3.2 Objetivos específicos

Como objetivos específicos, podem ser mencionados os seguintes:

- a) investigar o estado da arte a respeito de modelos de previsão da DP de materiais granulares, identificando os principais métodos e ferramentas utilizados na literatura;
- b) analisar o desenvolvimento de modelos de previsão da progressão da DP a partir de propriedades e índices físicos sob os parâmetros de ensaio brasileiro, para fomentar métodos de análise preliminar do comportamento plástico de solos para aplicação em camadas de pavimentos;
- c) avaliar o impacto do uso de modelos de previsão da progressão da DP pela evolução do número de ciclos de carga em ensaios de estágio único no cálculo de Afundamentos de Trilha de Roda (ATR), de modo a otimizar o tempo de procedimento;
- d) identificar a influência da interrupção de ensaios de estágio único de DP nos parâmetros brasileiros com base em critérios associados à classificação de shakedown dos solos.

1.4 Estrutura da dissertação

A dissertação está dividida em 6 capítulos e apresentada em formato de artigos para o caso dos Capítulos 3, 4 e 5. O primeiro capítulo buscou introduzir o tema abordado, além de descrever o problema, questões de pesquisa e objetivos que nortearam o desenvolvimento deste estudo.

O segundo capítulo descreve uma revisão sistemática sobre os principais artigos que buscaram estimar a DP por propriedades e índices físicos dos solos. Dessa maneira, a

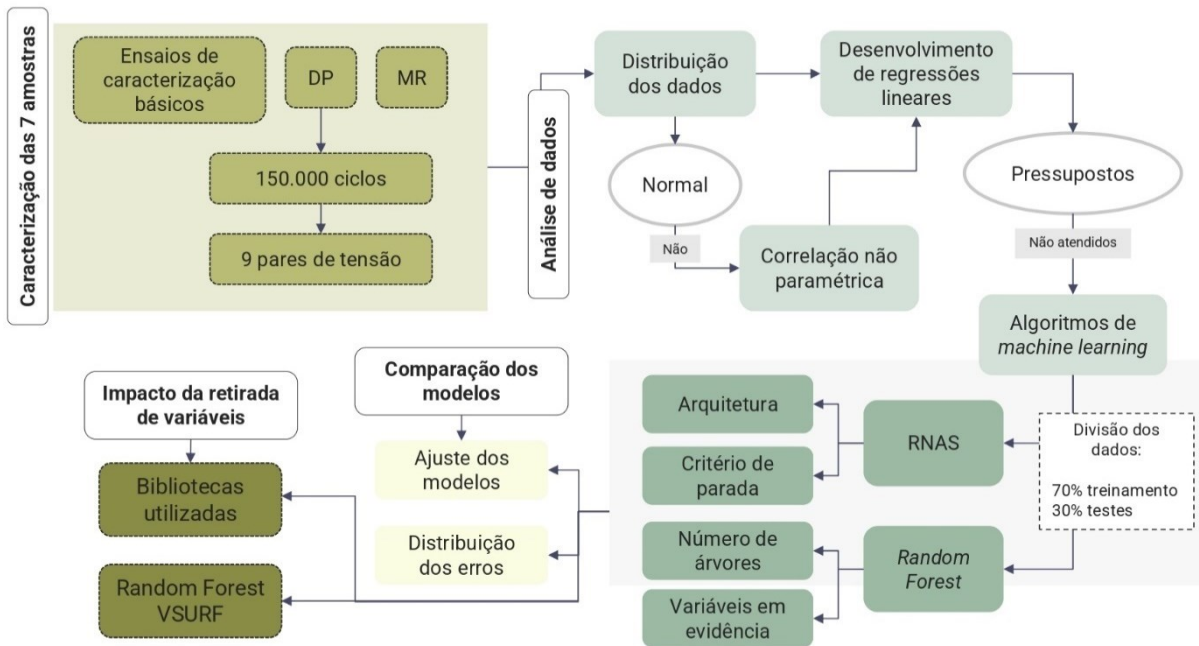
revisão percorreu sobre os principais métodos, ferramentas e variáveis utilizadas, assim como o desempenho obtido em cada caso. Assim, foram fornecidas informações importantes sobretudo para o desenvolvimento dos modelos apresentados nos demais capítulos.

O Capítulo 3 abordou o desenvolvimento de um modelo de previsão da DP a partir de propriedades relacionadas à composição granulométrica, compactação e capacidade de suporte, expansão e plasticidade, sendo planejada a submissão do texto como artigo submissão em periódico adequado. Para isso foram considerados dois algoritmos de machine learning, comparando os resultados obtidos por ambos os métodos. Para tanto, foram caracterizadas 7 amostras de solos selecionadas em função de tipos diferentes e características pedológicas. As amostras foram ensaiadas conforme as condições especificadas na norma brasileira (DNIT, 2018a), seguindo 9 pares de tensão em ensaios de estágio único, com 150.000 ciclos de aplicação.

O Capítulo 4 é referente ao artigo de previsão do comportamento plástico acumulado de solos em cada ensaio de estágio único, fazendo uso de algoritmos de Redes Neurais Artificiais (RNAs), também sendo esperada a submissão futura desse trabalho. Esse capítulo teve como objetivo estimar a progressão da DP até 150.000 ciclos (intervalo sugerido no Brasil) a partir do treinamento dos modelos neurais por uma parte dos ciclos dos ensaios em diferentes estados de tensão, o estudo. Nesse sentido, ao obter os coeficientes do modelo de Guimarães (2009) para o conjunto de 9 pares de tensão, foram esperados valores de afundamentos de trilha de rodas (ATR) próximos aos obtidos pelo ensaio completo (150.000 ciclos) a partir de uma quantidade reduzida de ciclos iniciais, o que impactou diretamente no tempo necessário para a realização dos procedimentos.

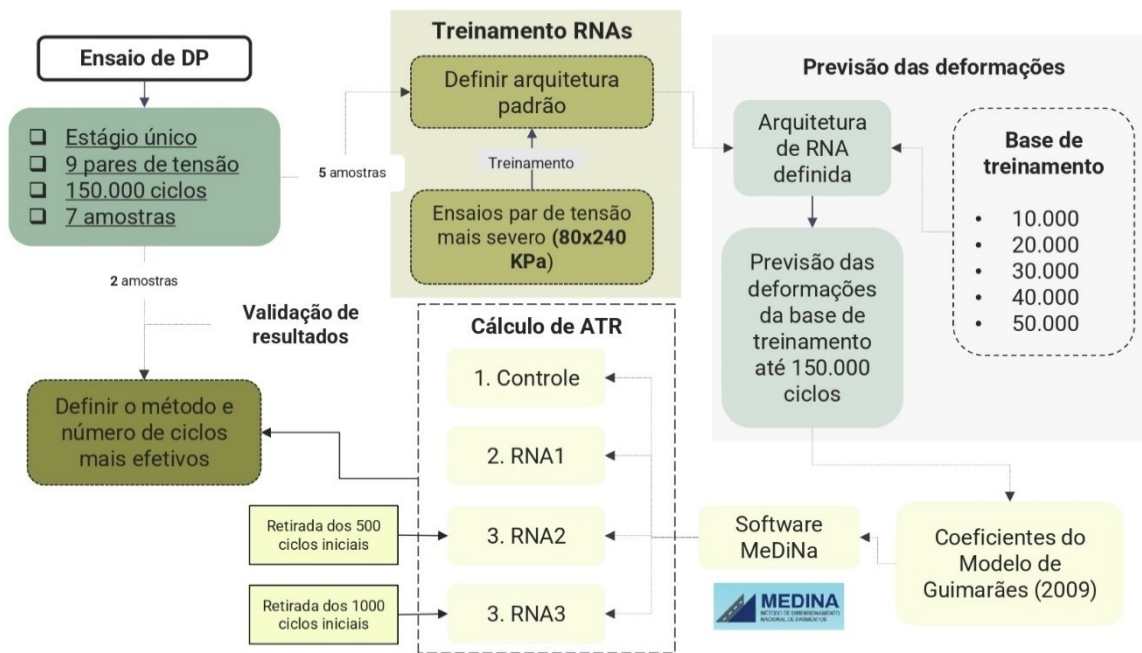
O quinto capítulo tratou da classificação dos solos da região estudada quanto ao acomodamento plástico, e como a interrupção prévia de ensaios classificados como Tipo A impactou nos afundamentos calculados, cujo texto foi submetido no primeiro semestre de 2023 em um periódico. Para além disso, também foi abordada a criação de critérios de parada anteriores a 10.000 ciclos para identificar o tipo de ensaio, sendo utilizados algoritmos de árvore de decisão. De modo simplificado, a metodologia proposta para o desenvolvimento dos artigos mencionados nos Capítulos 3, 4 e 5 foi ilustrada nos esquemas apresentados nas Figuras 1, 2 e 3, respectivamente.

Figura 1 – Metodologia proposta para o Artigo 1



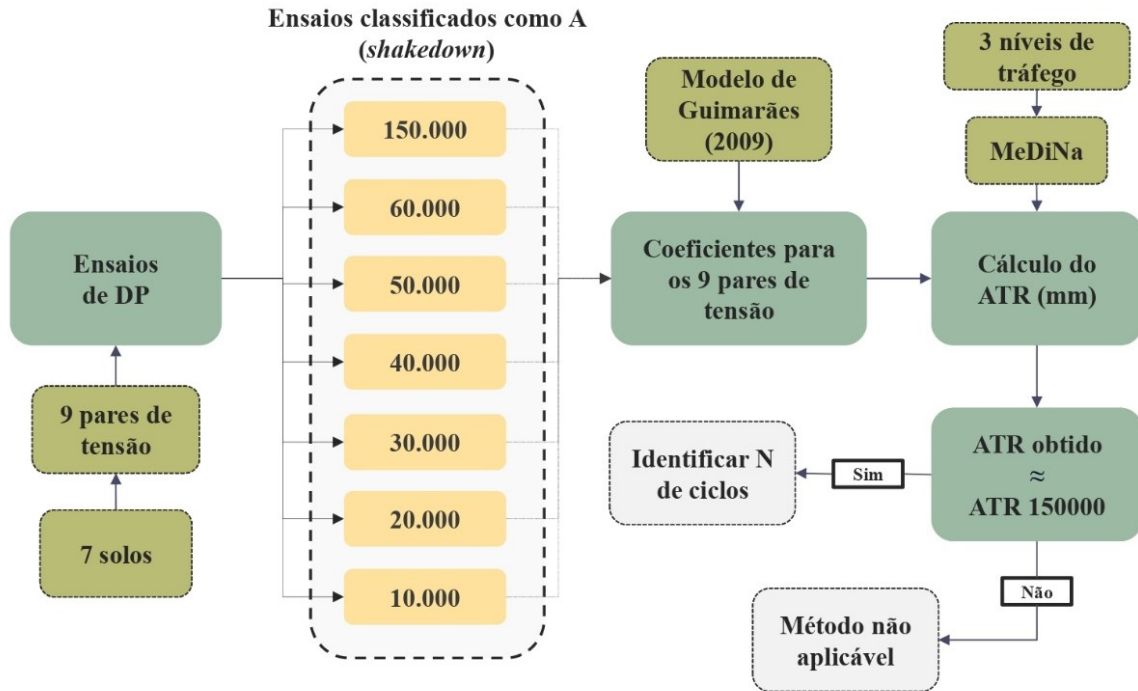
Fonte: elaborado pelo autor (2023)

Figura 2 – Metodologia proposta para o Artigo 2



Fonte: elaborado pelo autor (2023)

Figura 3 – Metodologia proposta para o Artigo 3



Fonte: elaborado pelo autor (2023)

2 REVISÃO SISTEMÁTICA SOBRE O DESENVOLVIMENTO DE MODELOS DE PREVISÃO DA DEFORMAÇÃO PERMANENTE DE SOLOS

2.1 Introdução

A execução de procedimentos que dependem do equipamento triaxial de cargas repetidas pode implicar em custos significativos para obras de pavimentação, além de demandarem um período de ensaios considerável. Dessa maneira, para otimizar a obtenção desses parâmetros, é necessário buscar métodos que facilitem o processo de caracterização de solos, como o desenvolvimento de modelos de previsão. Esses modelos, muitas vezes relacionam essas propriedades a ensaios de baixo custo e fácil implementação. Para tanto, são verificados diversos registros de estudos relacionados ao tema na literatura, sobretudo a respeito do Módulo de Resiliência.

A maior parte dos trabalhos utiliza métodos estatísticos tradicionais, como regressões múltiplas, na associação entre coeficientes de modelos constitutivos e propriedades e índices físicos dos solos. Além dos métodos estatísticos tradicionais, é crescente a utilização de algoritmos de *machine learning* ou aprendizado de máquina, que garantem a interpretação de informações importantes em um conjunto de dados, favorecendo a extração de regras e características complexas (MAHESH, 2020; SHOLEVAR, GOLROO e ESFAHAHI, 2022). Esses algoritmos vêm sendo amplamente empregados na previsão do características de materiais geotécnicos (PAHNO *et al.*, 2021; HEIDARABADIZADEH *et al.*, 2021; IKEAGUUANI *et al.*, 2021).

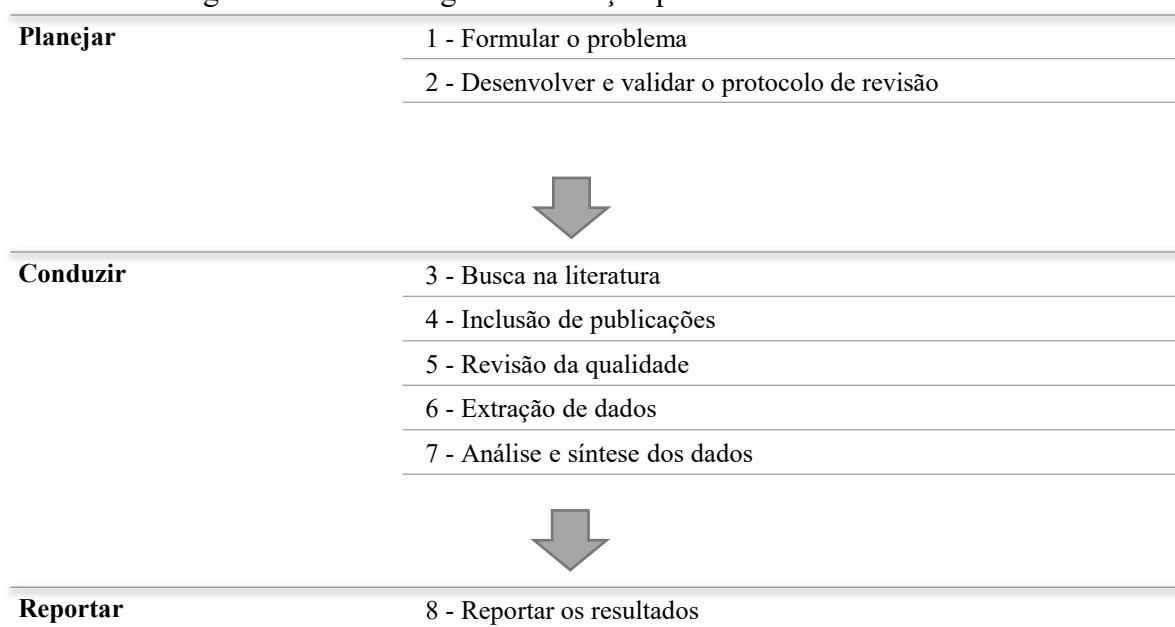
Apesar da vasta quantidade de estudos referentes ao MR, o desenvolvimento de modelos de previsão da DP de solos representa um número limitado de artigos. Entretanto, autores como Alnedawi *et al.* (2019) e Cabral *et al.* (2020) demonstraram a viabilidade dessa técnica, apesar da sugestão de configurações de ensaios distintos. Portanto, este capítulo busca desenvolver uma revisão sistemática para investigar as questões gerais sobre os principais estudos relacionados ao tema. Ao passo que se busca fornecer uma análise sobre métodos e variáveis empregados, espera-se que esse levantamento contribua para justificar e otimizar o desenvolvimento de novos modelos de previsão, que auxiliem em facilitar a implementação do novo método de dimensionamento mecanístico-empírico brasileiro (MeDiNa).

2.2 Métodos

A metodologia seguida neste capítulo foi baseada nos passos propostos por Watson e Xiao (2017), descritos na Figura 4. Inicialmente, foi necessário o levantamento de questões de pesquisa específicas para a revisão sistemática, que delimitassem o problema a ser estudado e servissem como direcionamento:

- a) qual a relevância atual do tema abordado?
- b) que tipo de métodos são utilizados e quais são mais efetivos?
- c) quais as principais variáveis, relacionadas às propriedades dos solos, que são utilizadas nos modelos?

Figura 4 – Metodologia de condução para Revisões Sistemáticas



Fonte: Adaptado de XIAO e WATSON (2017)

Definidas as questões de pesquisa, foi proposto o critério PICOC (*Population - População, Intervention - Intervenção, Control - Controle, Outcomes and Context – Saídas e Contexto*), na formulação do protocolo de pesquisa, o que estreita o direcionamento da revisão, garantindo sua aplicabilidade (Figura 5).

Figura 5 – Apresentação do critério PICOC para definição da revisão apresentada

<i>Population</i>	<ul style="list-style-type: none"> • Estudos relacionados à estimação da DP de solos
<i>Intervention</i>	<ul style="list-style-type: none"> • Desenvolvimento de modelos baseados em propriedades dos solos e índices físicos
<i>Control</i>	<ul style="list-style-type: none"> • Alnedawi <i>et al</i> (2019)
<i>Outcomes</i>	<ul style="list-style-type: none"> • Análise do estado da arte sobre o tema. Investigação de métodos, composição de banco de dados de treinamento e precisão dos modelos gerados
<i>Context</i>	<ul style="list-style-type: none"> • Estudos com objetivo de otimizar a obtenção da DP, a partir do desenvolvimento de correlações e modelos de previsão com outras propriedades

Fonte: elaborado pelo autor (2023)

Na fase de condução, foram realizadas pesquisas sobre a disponibilidade de trabalhos científicos a respeito do tema abordado, consultando as bases de dados *Web of Science* e *Scopus*, em setembro de 2021 e em março de 2022. Ambas as plataformas são relevantes quanto à produção de revistas internacionais e conseguem abranger artigos contemplados por outras bases de dados. Para identificar, tanto o histórico quanto o cenário atual sobre o desenvolvimento de modelos de previsão da Deformação Permanente (DP), foram definidas *strings* de busca para os principais objetos de estudo deste capítulo (Tabela 1).

Tabela 1 – *Strings* de busca utilizados na pesquisa

Parâmetros de investigação	<i>Strings</i> de busca
Deformação Permanente	<ul style="list-style-type: none"> • ("predicting" OR "prediction" OR "estimation" OR "estimating") AND "permanent deformation" AND ("subgrade soils" OR "soils") • "permanent deformation" AND ("unbound materials" OR "soils")

Fonte: elaborado pelo autor (2023)


Os resultados foram organizados a partir do programa de código livre *State of the Art through Systematic Review* (START). A exclusão de artigos para a subsequente inclusão na base de dados considerou apenas artigos referentes aos modelos de previsão de materiais geotécnicos baseados em parâmetros de ensaios convencionais. Para a etapa 5, os artigos selecionados passaram novamente por um processo de exclusão, retirando estudos sobre o desenvolvimento apenas de modelos constitutivos e ausência de clareza na apresentação da

metodologia e resultados. Por fim, os artigos selecionados foram avaliados para a extração das principais informações sobre os modelos de previsão (Etapa 6), dando sequência a análise dos resultados e sua apresentação (Etapas 7 e 8) na seção seguinte.

2.3 Seleção bibliográfica de publicações sobre o desenvolvimento de modelos de previsão da Deformação Permanente

A busca sistemática sobre o desenvolvimento de modelos de previsão de Deformação Permanente, utilizando o primeiro e grupo de *strings* de busca (Tabela 1), resultou em 183 trabalhos científicos. Na seleção inicial, a base bibliográfica foi limitada a 29 estudos, sendo 10 deles considerados duplicados (Figura 6a). Dentre essas publicações, cerca de 79% foram obtidas pela base de dados *Scopus* (Figura 6b).

Figura 6 – Relação entre os trabalhos aceitos na seleção inicial e a base de dados de origem
 (a) Quantidade de trabalhos relacionados à DP aceitos na seleção inicial
 (b) Base de dados referentes aos artigos encontrados




Fonte: elaborado pelo autor (2023)

É notável, já na seleção inicial, a disponibilidade restrita de publicações referentes ao tema de DP aqui abordado, especialmente comparando aos modelos de previsão do Módulo de Resiliência, o que pode indicar a relevância no desenvolvimento de novos trabalhos que contemplem esse objetivo. O primeiro trabalho selecionado foi brasileiro, publicado no periódico *Advances in Civil Engineering* (Cabral *et al.*, 2020), enquanto o segundo foi canadense, publicado em 2016 no *Canadian Journal of Civil Engineering* (Djonkamla *et al.*, 2016). Uma vez que apenas 2 artigos foram selecionados na etapa final, uma nova busca foi realizada de maneira mais abrangente ao estudo da DP a partir do segundo grupo de *strings* de

busca (Tabela 1), sendo obtidos os resultados mostrados na Figura 7.

Figura 7 – Relação entre os trabalhos aceitos na seleção inicial e a base de dados de origem para a segunda busca

(a) Quantidade de trabalhos relacionados à DP aceitos na seleção inicial (b) Base de dados referentes aos artigos encontrados

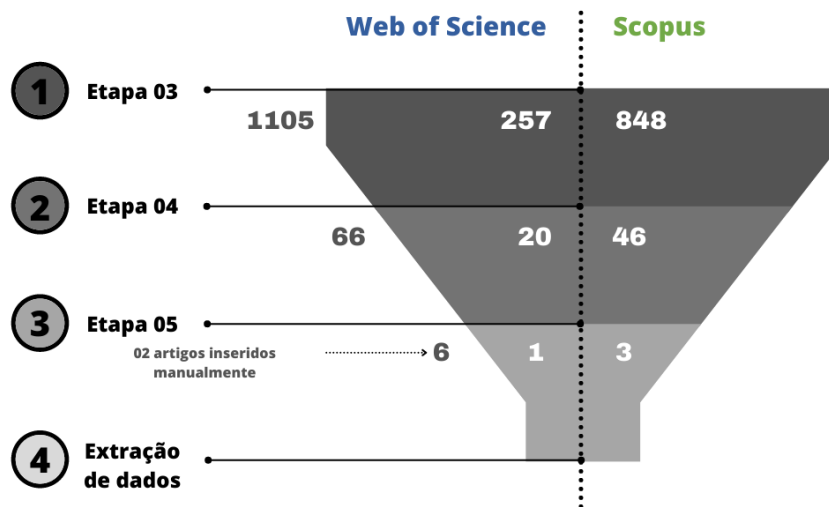


Fonte: elaborado pelo autor (2023)

Na etapa de seleção final da busca, foram considerados 2 publicações americanas, cuja primeira é referente ao congresso *Geotechnical Engineering for Transportation Projects* (Zhao *et al.*, 2004) e a segunda foi publicada no *International Journal of Geotechnical Engineering* (Rahman *et al.*, 2021). Ainda foram avaliados 2 trabalhos cujos resultados se alinham aos objetivos das buscas, uma publicação australiana (referente ao periódico *Journal of Rock Mechanics and Geotechnical Engineering* - Alnedawi *et al.*, 2019), e um artigo norte-americano, publicado no *Journal of Materials in Civil Engineering* (Puppala *et al.*, 1999), inseridos manualmente para posterior extração de dados.

Pela observação dos principais aspectos relacionados ao desenvolvimento de grande parte das publicações encontradas, pode-se dizer que a limitação no número de artigos selecionados para a etapa de extração acontece pelo fato da maioria dos trabalhos relacionados ao tema ainda tentar entender a relação entre diversos parâmetros do solo e a variação da DP, ou por proporem a análise e ajuste de modelos constitutivos. O processo de seleção de publicações até a etapa de extração pode ser exemplificado na Figura 8, que mostra os resultados conjuntos para ambas as buscas pelos dois grupos de *strings*.

Figura 8 – Processo de seleção das publicações



Fonte: elaborado pelo autor (2023)

2.4 Análise qualitativa dos resultados sobre a Deformação Permanente

2.4.1 Previsão da DP de solos a partir de coeficientes de modelos constitutivos

As publicações relacionadas à estimação da DP podem ser divididas em dois principais grupos, as que buscam correlações entre coeficientes de modelos constitutivos e parâmetros de ensaio, e a obtenção direta da deformação plástica como variável dependente. Observa-se que a obtenção direta da DP se mostra mais recente (a partir de 2019), muitas vezes aliada à aplicação de algoritmos de *machine learning*. É importante ressaltar que a configuração dos testes, nos quais inúmeras deformações são medidas para diferentes ciclos de aplicação de carga e estados de tensão, resultam em bancos de dados extensos quanto à progressão do comportamento plástico de solos.

Já no fim dos anos 90, Puppala *et al.* (1999) propuseram a obtenção dos coeficientes de um modelo constitutivo de DP de solos por parâmetros de granulometria e compactação. Os autores empregaram regressão linear múltipla para prever as constantes de um modelo logarítmico, que relaciona as deformações acumuladas ao número de ciclos, tensão octaédrica e tensão atmosférica (Equação 1). Foram utilizadas 3 amostras distintas de solos, sendo considerados diferentes teores de umidade para cada caso. As regressões alcançaram valores de coeficiente de determinação (R^2) entre 0,68 a 0,71 para A, a, B.

$$\log \varepsilon_p = \log A + a \log N + B \log \left(\frac{\sigma_{oct}}{\sigma_{atm}} \right) \quad (1)$$

Onde:

- ε_p : Deformação permanente;
- N: número de ciclos;
- σ_{oct} : Tensão octaédrica cisalhante;
- σ_{atm} : Tensão octaédrica normal;
- A, a, B: constantes do modelo.

Zhao *et al.* (2004) buscaram incorporar outras características dos solos à previsão dos coeficientes do modelo de Monismith *et al.* (1975), demonstrado na Equação 2. Foram propostas novas Equações (3 e 4) para associar as constantes A e b à tensão desvio e à tensão de pico estática, parâmetro que é função da densidade seca e teor de umidade. Assim, cada constante foi relacionada aos índices físicos e outras propriedades dos solos, a partir de regressões lineares múltiplas, obtendo valores de R² entre 0,59 a 0,99. Foram realizados testes no equipamento triaxial com 8 solos americanos, considerando 3 teores de umidades para cada tipo.

$$\varepsilon_p = AN^b \quad (2)$$

$$\log A = c + d \log SR \quad (3)$$

$$\log b = e + f \log SR \quad (4)$$

Onde:

- ε_p : Deformação permanente;
- N: número de ciclos;
- A e b: constantes do modelo de Monismith *et al.* (1975);
- SR: razão entre a tensão desvio (σ_d) e força de compressão não confinada (q_u);
- c, d, e e f: constantes que relacionam A e b à razão de tensões.

Djonkamla *et al.* (2016) utilizaram 6 amostras de solos argilosos e 5 arenosos na tentativa de estabelecer correlações entre os coeficientes a e b do modelo constitutivo proposto por Huurman (1997), descrito na Equação 5. Foram obtidos coeficientes de determinação de cerca de 0,60 para os parâmetros a e b. Comparando valores previstos e medidos, foi possível perceber que, apesar das limitações do modelo, o comportamento previsto foi bastante semelhante à DP medida.

$$\varepsilon_p = a \left(\frac{N}{1000} \right)^b \quad (5)$$

Onde:

ε_p : Deformação permanente;

N: número de ciclos;

a e b : constantes do modelo.

Ainda seguindo a mesma estratégia, Rahman *et al.* (2021) utilizaram regressões lineares múltiplas para correlacionar a DP de 8 amostras de solos da Carolina do Sul (EUA), considerando 3 diferentes teores de umidade. O ensaio consistiu na aplicação de 5 tensões desvios em um mesmo corpo de prova até 2500 ciclos. Para isso, foram previstos os coeficientes do modelo construtivo proposto por Puppala *et al.* (2009), mostrado na Equação 6. O modelo garantiu ajustes com R^2 em torno de 0,80 para os materiais analisados. As variáveis independentes utilizadas na previsão de cada coeficiente foram determinadas por testes estatísticos, identificando a significância das mesmas para os modelos gerados. Os autores também analisaram a relação entre MR e DP, percebendo que, para o conjunto de amostras estudadas, melhores comportamentos resilientes (módulos maiores) correspondem a menores deformações plásticas acumuladas ao longo da aplicação de cargas.

$$\varepsilon_p = a_1 N^{a_2} \left(\frac{\sigma_{oct}}{P_a} \right)^{a_3} \left(\frac{T_{oct}}{P_a} \right)^{a_4} \quad (6)$$

Onde:

ε_p : Deformação permanente;

N: número de ciclos;

P_a : Pressão atmosférica;

σ_{oct} : Tensão octaédrica cisalhante;

T_{oct} : Tensão octaédrica normal;

a_1 , a_2 , a_3 e a_4 : constantes do modelo.

2.4.2 Previsão direta da DP de solos

Paralelamente ao desenvolvimento de modelos que correlacionaram variáveis aos coeficientes de modelos constitutivos, também se identificou na literatura a previsão direta da DP de materiais geotécnicos (Alnedawi *et al.*, 2019; Cabral *et al.*, 2020). Basicamente,

propriedades e índices físicos dos solos foram utilizados para ajustar um modelo dependente do estado de tensão e progressão de cargas dinâmicas. A previsão da DP ocorreu, para cada par de tensões, em função do número de ciclos de aplicação de carga.

Nesse tipo de abordagem, os autores compartilham a utilização de algoritmos de *machine learning* para ajustar modelos de previsão, possivelmente motivados pelos resultados alcançados na previsão da deformação resiliente de solos (PARK *et al.*, 2009; NAZZAL e TATARI *et al.*, 2013; PAL e DESWAL, 2015; HEIDARABADIZADEH *et al.*, 2021). Além disso, deve-se destacar as limitações de modelos estatísticos como regressões lineares quanto aos pressupostos na base de dados e no comportamento esperado dos resíduos.

Alnedawi *et al.* (2019) avaliaram 4 amostras de solos, moldando 3 corpos de prova para cada uma delas em 3 diferentes teores de umidade (umidade ótima, abaixo da ótima e acima da ótima). Com base nesses dados, os autores desenvolveram Redes Neurais Artificiais (RNAs) do tipo *perceptron* multicamadas. Pela abordagem australiana, foram empregados 3 pares de tensão e 10000 ciclos de aplicação de carga, mantendo a tensão confinante constante para reduzir a análise desse efeito na DP. Em ambos os casos, o ajuste do modelo foi excelente, com coeficientes de correlação de 0,99. Os autores sugerem que número de ciclos e teor de umidade foram as variáveis com maior influência na construção do modelo. Por fim, foi percebido que amostras com teor de umidade inferior à umidade ótima apresentaram menor DP que amostras compactadas em um teor acima do ótimo.

Também foram construídos modelos de previsão para cada par de tensões, relacionando apenas o número de ciclos (N) como variável de entrada na previsão da DP acumulada como saída. A comparação entre o uso de redes neurais e modelos constitutivos para prever o comportamento plástico de solos pela progressão do número de ciclos de aplicação de carga evidenciou o melhor desempenho da ferramenta computacional frente aos métodos estatísticos tradicionais.

Já Cabral *et al.* (2020) utilizaram duas amostras de subleito e uma mistura entre elas para criar uma rede neural com DP como variável de saída, empregando 12 pares de tensão baseadas na metodologia proposta no Brasil, conforme DNIT (2018a). Os autores chegaram a um coeficiente de correlação de 0,85, o que sugere bom ajuste. Em uma extensão dessa pesquisa, Cabral (2021) chegou a comparar o ajuste de regressões múltiplas e redes neurais, utilizando como entrada índices físicos, propriedades dos solos, tensões atuantes, número de ciclos e MR. Percebeu-se que as regressões lineares não conseguem fornecer modelos que se adequem de forma efetiva na previsão da variável alvo pelo base nos parâmetros de entrada indicados.

As Tabelas 2 e 3 resumem as principais características referentes à construção dos modelos desenvolvidos nos trabalhos selecionados. Na Tabela 2 são mostrados o método, as variáveis empregadas nos modelos e os coeficientes de determinação (R^2). Já na Tabela 3 descrevem-se as configurações de ensaio de DP executadas de acordo as informações disponibilizadas nos artigos.

Tabela 2 – Resumo dos principais aspectos sobre os modelos de previsão da Deformação Permanente para a literatura selecionada

Títulos	Autores	Anos	Métodos	Qualidade do ajuste (R^2)	Variáveis de entrada
Permanent Deformation Characterization of subgrade soils from RLT test	Puppala, Anand J. Mohammad Louay N.	1999	Regressão linear múltipla	Entre 0,68 e 0,71 para os parâmetros do modelo	Teor de umidade; Densidade seca; porcentagem de areia e porcentagem de argila.
Prediction of subgrade permanent strain using simple soil properties	Zhao, YS and Dennis, ND and Elliott, RP	2004	Regressão linear múltipla	Entre 0,59 e 0,99 para os parâmetros dos modelos	Umidade ótima; Limite de Plasticidade; Limite de Liquidez; densidade seca máxima; teor de finos (%); teor de argila (%);
Development of a prediction model of permanent deformation considering the physical properties of subgrade soil	Djonkamla, Youdjari and Dore, Guy and Bilodeau, Jean-Pascal	2016	Regressão linear múltipla	0,60 para a e b	Grau de saturação; densidade seca; Coeficiente de Curvatura; Valor de Azul e porcentagens que passam nas peneiras 0,08 mm e 0,002 mm.
Correlations of permanent strain and damping coefficients with resilient modulus for coarse-grained subgrade soils	Rahman, Md Mostaqur and Islam, Kazi Moinul and Gassman, Sarah L.	2021	Regressão linear múltipla	Entre 45% e 87% para os 4 coeficientes do modelo.	Densidade máxima; densidade; umidade ótima, teor de umidade; limites de consistência, Índice de Plasticidade; Coeficiente de Uniformidade e porcentagem passante na peneira #4.
Neural network-based model for prediction of permanent deformation of unbound granular materials	Ali Alnedawi, Riyadh Al-Ameri and Kali Prasad Nepal	2019	Redes Neurais Artificiais	0,99 para cada conjunto de solos	Coeficiente de Curvatura; Coeficiente de Uniformidade; teor de umidade; tensão desviatória e número de ciclos.
Study of the Permanent Deformation of Soil Used in Flexible Pavement Design	Cabral, W. S. and Barroso, S. H. A. and Torquato, S. A.	2020	Regressão múltipla Redes Neurais Artificiais	0,64 0,85	Classificação AASHTO; umidade ótima, Índice de Plasticidade; CBR; MR; número de ciclos; σ_d e σ_3 .

Fonte: elaborado pelo autor (2023)

Tabela 3 – Principais configurações do ensaio de Deformação Permanente utilizadas pelos autores

Autores	Frequência Hz	σ_3 (kPa)	σ_D (kPa)	Ciclos
Puppala <i>et al</i> (1999).	-*	140	105	1000
Procedimento para solos arenosos.		21	21	100
		21	35	100
		21	52,5	100
		21	70	100
		35	35	100
		35	70	100
		35	105	100
		35	140	100
		70	35	100
		70	70	100
		70	140	100
		70	210	100
		105	70	100
		105	105	100
		105	140	100
105	210	100		
140	70	100		
140	105	100		
140	240	100		
140	280	100		
Procedimento para solos argilosos	-*	42	28	2100
		42	14	100
		42	28	100
		42	42	100
		42	56	100
		42	70	100
		21	14	100
		21	28	100
		21	42	100
		21	56	100
		21	70	100
		0	14	100
		0	28	100
		0	56	100
		0	60	100
Djonkamla <i>et al.</i> (2016)	1,0	20	18	100.000
Alnedawi <i>et al.</i> (2019)	0,5	50	350	10.000
		50	450	10.000
		50	550	10.000
Cabral <i>et al.</i> (2020)	1,0	40	40	10.000
			80	10.000
			120	10.000
			160	10.000
			80	10.000
		120	80	10.000
			120	10.000
			240	10.000
			320	10.000
			120	10.000
240	10.000			
360	10.000			
480	10.000			
Rahman <i>et al.</i> (2021)	-*	-*	-*	2500

* - procedimentos cujos autores não informaram a configuração utilizada nos ensaios.

Fonte: elaborado pelo autor (2023)

2.5 Conclusões

A partir deste capítulo buscou-se levantar os principais métodos e ferramentas utilizados na estimação da DP de solos, implementando uma revisão sistemática. Foram identificados 6 artigos referentes ao desenvolvimento de previsão do comportamento plástico de materiais geotécnicos, muitas vezes baseados em propriedades e índices físicos. Levando em consideração a divergência de parâmetros adotados mundialmente, também foi possível identificar como esses estudos abordam a execução dos ensaios laboratoriais.

Evidenciou-se que os autores adotam parametrizações das regiões nas quais as pesquisas se desenvolvem. Nesse sentido, os pares de tensão e a frequência aplicados são característicos de cada um dos estudos avaliados. Entretanto, verifica-se que ensaios de estágio múltiplo são empregados com unanimidade na caracterização da DP das amostras, até mesmo no artigo brasileiro. Para tanto, é necessário destacar que os resultados observados ainda devem ser validados considerando outras abordagens, como ensaios de estágio único, já que o histórico de tensões impacta diretamente as deformações obtidas.

Outro aspecto referente à padronização dos ensaios de laboratório é o número de ciclos de aplicação de carga dinâmica. A metodologia proposta no novo método de dimensionamento brasileiro para análise de DP (150000 ciclos para 9 pares de tensão) se destaca quanto ao número de ciclos e, conseqüentemente, tempo de ensaio superior aos métodos abordados nos demais trabalhos avaliados. Apesar de grande parte da deformação acumulada ser atingida nos primeiros 10000 ciclos de ensaio, maior intervalo adotado nos artigos analisados, alguns solos brasileiros podem apresentar variação expressiva em seu comportamento até um número muito superior de ciclos. Assim, é preciso identificar como esses modelos podem responder ao comportamento plástico em um intervalo de aplicação de cargas muito mais amplo.

Em relação às variáveis de entrada propostas para o desenvolvimento dos modelos, destaca-se a quantidade de propriedades e índices físicos, sobretudo na construção dos artigos que empregaram regressões múltiplas. De modo geral, a DP se relacionou mais expressivamente com características relacionadas à granulometria e compactação, o que favorece a praticidade da implementação de modelos e sua replicação em obras de forma mais econômica.

Para comparação dos modelos da literatura tomou-se como base o ajuste obtido, a partir dos coeficientes de determinação (R^2). Foi possível perceber então, que os modelos de previsão direta da DP chegaram a melhor desempenho na previsão da deformação acumulada. Para além disso, ferramentas como RNAs podem superar algumas limitações dos métodos

estatísticos convencionais, como os pressupostos necessários no ajuste e validação dos modelos.

Por fim, embora verificados diversos métodos estatísticos e múltiplas ferramentas de *machine learning* aplicados na previsão de outras propriedades do solo (como o Módulo de Resiliência), a revisão sistemática apontou restrição de modelos de previsão da DP apenas por regressões múltiplas e RNAs. As observações finais validam e incentivam a criação de correlações entre DP e propriedades do solo, à medida que apoiam a construção desses modelos sob especificações nacionais.

3 PREVISÃO DA DEFORMAÇÃO PERMANENTE DE SOLOS UTILIZANDO DIFERENTES ALGORITMOS DE MACHINE LEARNING

Resumo

A caracterização apropriada de solos para uso em camadas granulares de pavimentos asfálticos envolve a análise conjunta das deformações resilientes e plásticas. Nesse sentido, utiliza-se o equipamento triaxial de carga repetida para considerar as condições dinâmicas do carregamento impostas pelo tráfego ao longo do tempo de vida da estrutura. Entretanto, esse tipo de procedimento pode exigir recursos financeiros e tempo de ensaio consideráveis, o que pode prejudicar a viabilidade de sua implementação. Dessa maneira, o trabalho em questão busca verificar estratégias para estimar a Deformação Permanente (DP) de solos com base no estado de tensões, na evolução da aplicação das cargas e em propriedades índices dos materiais. A partir da análise de 7 amostras de solos com características distintas, e tomando como base as especificações das normas brasileiras (150.000 ciclos de aplicações em estágio único, 9 pares de tensão e frequência de 2 Hz), foi proposto o ajuste de modelos de previsão por algoritmos de *machine learning* (*Redes Neurais Artificiais* e *Random Forest*) que podem gerar bons resultados mesmo em configurações de dados nas quais regressões estatísticas convencionais não se aplicam. Para a avaliação dos modelos, foram analisados parâmetros de erro e ajuste, investigando-se a distribuição dos erros absolutos obtidos e a relação entre valores observados e previstos. Já quanto à previsão da DP por outras propriedades e índices físicos de solos, ambos os modelos demonstraram excelentes resultados, com valores de R^2 superiores a 0,99 na base de dados de teste. Assim, os modelos propostos podem auxiliar na seleção preliminar de materiais para obras de pavimentação possibilitando a análise de uma variável de obtenção complexa e com ajuste adequado.

Palavras chave: Redes Neurais Artificiais, *Random Forests*, Modelos de previsão, Pavimento Flexível.

3.1 Introdução

Os pavimentos asfálticos são formados por múltiplas camadas construídas sobre o subleito, que tem como principal função garantir o tráfego seguro e confortável de veículos. A organização vertical dessas estruturas ocorre de forma decrescente quanto à capacidade de suporte dos materiais empregados, de modo que a distribuição do carregamento de tráfego incidente ocorrerá proporcionalmente à profundidade da rodovia, garantindo menores magnitudes de tensões nas camadas menos resistentes e no subleito. (SINGH e SAHOO, 2021).

A caracterização adequada das camadas granulares e do subleito desempenha um papel importante no desempenho dos pavimentos, sendo determinante para seu sucesso ou falha. À medida que o tráfego rodoviário atua sobre a estrutura, os materiais utilizados sofrem deformações que podem resultar em diversos defeitos, prejudicando o conforto dos usuários e diminuindo a vida útil dos pavimentos. Entre esses problemas, destaca-se o surgimento progressivo de deformações que contribuem para a formação de afundamentos de trilha de rodas

(ATR).

Esses afundamentos não apenas aumentam o risco de aquaplanagem na superfície do revestimento, mas também afetam as condições de drenagem e a segurança do tráfego. Portanto, controlar as deformações plásticas nos materiais granulares utilizados na construção de rodovias é fundamental para garantir estruturas duráveis, reduzindo a probabilidade de manifestações patológicas adicionais, como trincas térmicas em regiões de clima frio e trincas induzidas pelo tráfego (BA e FALL, 2015; LUO *et al.*, 2017; GU *et al.*, 2020; KHASAWNEH *et al.*, 2020).

Nesse cenário, a abordagem de dimensionamento mecanístico-empírico desempenha um papel fundamental na compreensão do comportamento dos materiais geotécnicos utilizados em pavimentação. Essa abordagem propõe o desenvolvimento de modelos matemáticos que levam em consideração critérios de fadiga e afundamentos de trilha de rodas admissíveis. Para alcançar esse objetivo, são necessários diversos testes que permitam identificar a relação entre os solos e os principais fatores que influenciam seu comportamento mecânico (ERLINGSON *et al.*, 2017).

Entretanto, a análise dos solos para uso em pavimentação se baseia muitas vezes no conhecimento do comportamento resiliente dos materiais. Acredita-se que solos com altos valores de Módulo de Resiliência (MR) apresentariam baixas deformações plásticas acumuladas, ou seja, baixa Deformação Permanente (DP). No entanto, foi observado que algumas misturas de solo e materiais com altos teores de finos podem apresentar um comportamento que foge a essa expectativa, resultando em valores consideravelmente altos de MR, mas também em deformações acumuladas elevadas (PUPPALA *et al.*, 1999; VENKATESH *et al.*, 2020).

Na década de 1970, Monismith *et al.* (1975) propuseram a utilização do equipamento triaxial cíclico para caracterizar a Deformação Permanente (DP) de solos do subleito. Esse método, normalmente empregado na caracterização do Módulo de Resiliência (MR), permitia estimar a DP por meio da previsão de coeficientes em modelos constitutivos baseados na teoria da elasticidade dos materiais. Esses coeficientes eram dependentes do estado de tensão e/ou da progressão dos ciclos de aplicação de cargas.

A partir do estudo da propriedade de comportamento plástico, foi identificado que materiais geotécnicos apresentam três estágios distintos (WERKMEISTER, 2003). O primeiro estágio tem uma duração curta, abrangendo apenas algumas centenas de ciclos, e é caracterizado por um rápido crescimento das deformações, que diminuem gradualmente ao longo do tempo (KHASAWNEH, 2020). O segundo estágio é mais prolongado, com milhões de aplicações de

carga, e nele são observadas pequenas deformações com uma taxa de variação aproximadamente constante. O terceiro estágio é marcado por mudanças significativas na taxa de deformação, levando eventualmente à falha do material. É importante ressaltar que os métodos mecanísticos-empíricos geralmente consideram apenas os dois primeiros estágios, uma vez que obter informações sobre o comportamento nos três estágios exigiria um tempo de ensaio e recursos significativos, devido à complexidade dos modelos necessários (PUPPALA *et al.*, 2009; BA *et al.*, 2015).

Apesar da necessidade de estimar o comportamento plástico de materiais granulares, é importante considerar as limitações associadas ao uso do equipamento triaxial de cargas repetidas para caracterizar adequadamente os solos. Esse equipamento requer mão de obra especializada para manuseio, possui um alto custo de aquisição e manutenção, além de demandar um tempo considerável para obtenção dos resultados. Essas questões podem restringir o acesso a tais procedimentos, principalmente em países com recursos financeiros e humanos limitados (NAZZAL e MOHAMMAD, 2010).

Considerando as limitações mencionadas, a *American Association of State Highway and Transportation Officials* (AASHTO) propôs a utilização de diferentes abordagens para a análise de solos em relação às deformações recuperáveis, com base no nível de tráfego previsto. O *Mechanistic Empirical Pavement Design Guide* (MEPDG) estabelece três níveis de tráfego para dimensionamento. Para tráfego pesado (nível 1), são recomendados ensaios mais precisos conforme as normas vigentes. Para tráfego intermediário, é possível empregar estimativas obtidas por meio de correlações com outras propriedades do solo. Por fim, para tráfego leve, os parâmetros de caracterização podem ser obtidos a partir da média de valores de um banco de dados da região (HOSSAIN, 2010; ZHOU *et al.*, 2015).

É importante ressaltar que a caracterização mecânica dos materiais utilizados em obras de pavimentação, por meio das propriedades de Módulo de Resiliência (MR) e Deformação Permanente (DP), é influenciada por uma série de fatores que afetam seu comportamento elástico e plástico no campo. Entre esses fatores, destacam-se a granulometria, umidade, compactação, velocidade de tráfego e tensões aplicadas (LIMA *et al.*, 2021a). Diante disso, diversos estudos têm buscado desenvolver modelos de previsão que permitam obter, de maneira prática e rápida, a estimativa das deformações plásticas dos solos com base em suas características e propriedades físicas. Conforme mencionado por Titi *et al.* (2015), o objetivo é proporcionar uma certa flexibilidade aos projetistas, permitindo alcançar resultados satisfatórios, considerando a disponibilidade de recursos e a precisão necessária para o projeto.

Apesar da ampla disponibilidade de artigos relacionados à previsão do MR, a

estimação do comportamento plástico de solos é ainda restrita na literatura. A Tabela 4 apresenta os principais estudos relacionados ao desenvolvimento de modelos de previsão da Deformação Permanente (DP) de materiais granulares com base em propriedades geotécnicas e outras características dos solos.

Tabela 4 – Resumo de parâmetros utilizados na construção de modelos de previsão da DP por propriedades físicas de solos

Título	Autores	Ano	Método	Qualidade do ajuste (R^2)	Variáveis de entrada
Permanent Deformation Characterization of subgrade soils from RLT test	Puppala, Anand J. Mohammad Louay N.	1999	Regressão linear múltipla	Entre 0,68 e 0,71 para os coeficientes do modelo	Teor de umidade; Densidade seca; porcentagem de areia e porcentagem de argila.
Prediction of subgrade permanent strain using simple soil Properties	Zhao, YS and Dennis, ND and Elliott, RP	2004	Regressão linear múltipla	Entre 0,59 e 0,99 para os coeficientes dos modelos	Umidade ótima; Limite de Plasticidade; Limite de Liquidez; densidade seca máxima; teor de finos (%); teor de argila (%);
Development of a prediction model of permanent deformation considering the physical properties of subgrade soil	Djonkamla, Youdjari and Dore, Guy and Bilodeau, Jean-Pascal	2016	Regressão linear múltipla	0,60 para a e b	Grau de saturação; densidade seca; Coeficiente de Curvatura; Valor de Azul e porcentagens que passam nas peneiras 0,08 mm e 0,002 mm.
Characterization and prediction of permanent deformation properties of unbound granular materials for pavement ME design	Gu, Fan and Zhang, Yuqing and Luo, Xue and Sahin, Hakan and Lytton, Robert L.	2017	Regressão linear múltipla	0,88 para deformação, 0,90 e 0,87 para β e ρ	Densidade máxima; umidade; Índice de Angularidade; Índice de Forma; Textura; graduação do agregado; valor de azul de metileno e percentual de finos.
Correlations of permanent strain and damping coefficients with resilient modulus for coarse-grained subgrade soils	Rahman, Md Mostaqur Islam, Kazi Moinul and Gassman, Sarah L.	2021	Regressão linear múltipla	Entre 45% e 87% para os 4 coeficientes do modelo.	Densidade máxima; densidade; umidade ótima, teor de umidade; limites de consistência, Índice de Plasticidade; Coeficiente de Uniformidade e porcentagem passante na peneira #4.
Neural network-based model for prediction of permanent deformation of unbound granular materials	Ali Alnedawi, Riyadh Al-Ameri and Kali Prasad Nepal	2019	Redes Neurais Artificiais	0,99 para cada conjunto de solos	Coeficiente de Curvatura; Coeficiente de Uniformidade; teor de umidade; tensão desviatória e número de ciclos.

Tabela 4 – Resumo de parâmetros utilizados na construção de modelos de previsão da DP por propriedades físicas de solos (conclusão)

Título	Autores	Ano	Método	Qualidade do ajuste (R ²)	Variáveis de entrada
Study of the Permanent Deformation of Soil Used in Flexible Pavement Design	Cabral, W. S. and Barroso, S. H. A. and Torquato, S. A.	2020	Redes Neurais Artificiais	0,85 para o modelo	Classificação AASHTO; umidade ótima, Índice de Plasticidade; CBR; MR; número de ciclos; σ_d e σ_3 .
Exploration, comparative analysis and modeling of the Permanent Deformation of granular materials from the microregion of Mossoró/RN	Cabral, W. S.	2021	Redes Neurais Artificiais Regressão múltipla	0,85 para o modelo 0,64 para o modelo	Classificação AASHTO; umidade ótima, Índice de Plasticidade; CBR; MR; número de ciclos; σ_d e σ_3

Fonte: elaborado pelo autor (2023)

É importante destacar que, assim como na previsão do Módulo de Resiliência, alguns autores têm se concentrado em modelos que buscam estabelecer equações relacionando a variável resposta aos coeficientes de modelos constitutivos. Exemplos desses modelos são os de Puppala *et al.* (1999), Zhao *et al.* (2004), Djonkamla *et al.* (2016), Gu *et al.* (2017) e Rahman *et al.* (2021). Por outro lado, outros pesquisadores desenvolveram equações de previsão direta da DP, como Alnedawi *et al.* (2019) e Cabral *et al.* (2020).

Enquanto a previsão dos coeficientes de modelos constitutivos geralmente é realizada por meio de métodos estatísticos tradicionais, alguns estudos, como o de Alnedawi *et al.* (2019) e Cabral (2021), adotaram algoritmos de *machine learning* para analisar os modelos propostos, obtendo resultados promissores na previsão da Deformação Permanente de solos em ensaios de estágio múltiplo, especificamente a 10.000 ciclos de carga. No entanto, é importante ressaltar que a literatura analisada não apresenta um modelo que demonstre eficácia na utilização de propriedades e índices dos solos para estimar a DP considerando a combinação de diferentes pares de tensão obtidos em ensaios de estágio único e a progressão da deformação ao longo de uma ampla faixa de ciclos de aplicação, como sugerem a norma brasileira 179/2018 - IE (DNIT, 2018).

Inicialmente, é importante destacar que, em comparação às diretrizes brasileiras (150.000 ciclos de aplicação e 9 pares de tensão em estágio único) a análise da parcela acumulada de Deformação Permanente (DP) até 10.000 ciclos iniciais pode subestimar ou superestimar a deformação final acumulada, especialmente para alguns tipos de solos, comprometendo a precisão da análise mecanicista realizada. Além disso, a realização de ensaios

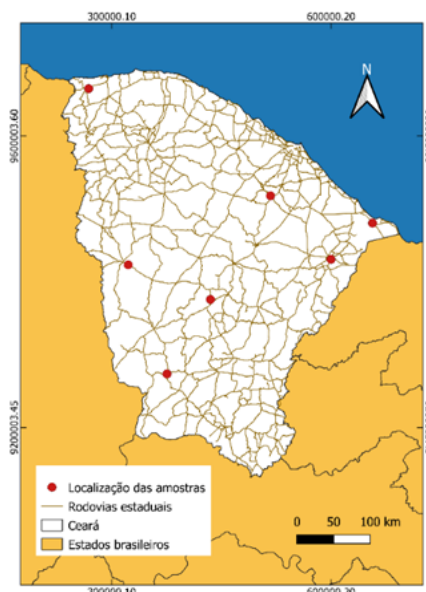
em estágios múltiplos também afeta a obtenção desse parâmetro, especialmente à medida que o material continua sendo solicitado nos últimos pares de tensão para um mesmo corpo de prova (LIMA *et al.*, 2021b; WERKMEISTER, 2003).

Portanto, este artigo tem como objetivo analisar o desenvolvimento de modelos de previsão da DP de solos em uma região brasileira, levando em consideração a progressão dos ciclos de aplicação de carga, o estado de tensões, propriedades como compactação, composição granulométrica, CBR, expansão e limites de consistência dos materiais geotécnicos. Através dessa investigação, busca-se criar modelos preliminares de acordo com as diretrizes brasileiras, a fim de facilitar a análise prévia dos materiais disponíveis em determinada área e otimizar os recursos necessários para obras de pavimentação.

3.2 Preparação dos dados a partir da coleta e ensaios nos solos

Foram consideradas sete amostras de solos do estado do Ceará, localizado na região Nordeste do Brasil, levando em consideração a variabilidade espacial de suas características. Essa análise foi realizada com base em diferentes características geomorfológicas e na classificação da AASHTO (*American Association of State Highway and Transportation Officials*). Para garantir a representatividade, a seleção das localizações (ilustrado na Figura 9) buscou associar os aspectos pedológicos, geológicos, e a distribuição de distritos operacionais do Ceará.

Figura 9 – Localização dos pontos de extração das amostras de solo estudadas



Fonte: elaborado pelo autor (2023)

Na caracterização básica dos solos foram executados os ensaios de Limites de Consistência (DNER-ME 082/94 e DNER-ME 122/94), Granulometria (DNER-ME 051/94), Densidade Real (DNER-ME 093/94), Compactação (DNER-ME 162/94) – empregando a energia intermediária - e *California Bearing Ratio* (DNIT 172/2016-ME). Para a análise da deformação plástica das amostras, foram realizados ensaios de Deformação Permanente, seguindo as diretrizes da norma brasileira DNIT 179/2018-IE.

A preparação dos corpos de prova (CP) foi realizada a partir da compactação dos solos dentro do teor de umidade ótimo, utilizando um cilindro tripartido com diâmetro de 100 mm e altura de 200 mm. Foi aplicada uma energia de compactação intermediária durante o processo. A medição das deformações por deslocamento plástico dos corpos de prova foi realizada por meio de um equipamento triaxial de cargas repetidas, que estava equipado com dois transdutores de deslocamento linear (LVDTs) de alta precisão, com uma precisão de 0,001 mm. Nesse equipamento, o carregamento axial foi medido e transferido para o corpo de prova por meio de uma célula de carga, enquanto uma pressão confinante específica foi aplicada pelo sistema de ar comprimido. Os parâmetros do ensaio foram definidos e o monitoramento foi realizado por meio de um display eletrônico digital acoplado ao equipamento.

São recomendados 9 pares de tensão para a caracterização do comportamento plástico de cada solo, conforme a norma brasileira, utilizando 150.000 ciclos de aplicação (ver Tabela 5). Inicialmente, é sugerida a aplicação de 50 ciclos, em que a deformação é desprezada para garantir um contato adequado entre a amostra e o pistão. Nesse estágio, é empregada uma tensão confinante de 30 kPa. Cada par de tensão gera 88 pontos de deformação permanente acumulada ao longo dos ciclos de aplicação de carga, conforme os dados fornecidos pelo equipamento. Foram realizados um total de 63 testes de laboratório, com uma frequência de 2 Hz, o que corresponde a uma carga de aplicação de 0,1 s e um período de repouso de 0,4 s, como recomendado pela norma.

No entanto, alguns materiais com consistência arenosa, classificados como AASHTO A-3 e A-1-b, apresentaram rompimento sob a aplicação dos últimos pares de tensão (120 kPa/240 kPa e 120 kPa/360 kPa) apresentados na Tabela 5, devido a deformações superiores às deformações máximas admissíveis pelo equipamento. Da mesma forma, os resultados dos pares de tensão relacionados a uma amostra argilosa foram inconsistentes e não foram considerados. Além disso, alguns ensaios foram encerrados antes de atingir o número de ciclos de aplicação de 150.000 (encerrados após 90.000 ciclos) devido a falhas relacionadas ao sistema. Assim, o conjunto de ensaios resultou na composição de um banco de dado de 5.213 pontos.

Tabela 5 – Conjunto de pares de tensão sugeridos

Sequência	Tensão confinante (kPa)	Tensão desvio (kPa)
1		40
2	40	80
3		120
4		80
5	80	160
6		240
7		120
8	120	240
9		360

Fonte: elaborada pelo autor (2023)

3.3 Modelos de previsão

O desenvolvimento de modelos estatísticos, como as regressões lineares múltiplas, requer a observação de uma série de suposições quanto ao comportamento das variáveis e dos resíduos gerados. Algumas delas, como a linearidade entre as variáveis, podem ser superadas por estratégias tais como a transformações de dados. Entretanto, as medidas que compõem o banco de dados deste estudo descumprem a suposição de independência entre as observações, visto que se atribui diversas medidas de deformação a cada par de tensão de cada solo. Winter (2013) afirma que a independência dos dados é essencial para prevenir o alcance de resultados hipotéticos, nos quais o p-valor pode ser completamente insignificante. Além disso, o desenvolvimento de modelos preliminares mostrou que não se observa a normalidade e a homoscedasticidade (homogeneidade de variância dos erros) nos resíduos. Portanto, o desenvolvimento de modelos lineares não deve ser a melhor abordagem na solução do problema proposto.

Já modelos de *machine learning*, tais como RNAs e os métodos *ensemble Random Forest* (RF), não necessariamente demandam algum tipo de relação específica ou restrição entre as variáveis dependentes e independentes (CHANG, 2005). Dessa forma, identificando as limitações observadas pelo uso das regressões, foi sugerido o desenvolvimento e comparação de modelos por duas abordagens já empregadas na previsão de parâmetros semelhantes (MR de solos), RF e RNA. O desenvolvimento desses algoritmos foi conduzido a partir dos pacotes

“randomForest” (LIAW e WIENER, 2002) e “h2o” (Aiello *et al.*, 2018). Paralelamente, com o objetivo de evitar ao máximo a ocorrência de ajuste excessivo aos valores de treinamentos (*overfitting*), a base de dados foi dividida em duas partes. Enquanto 70% (3565 pontos) dos dados foram utilizados para o treinamento do modelo, a parcela restante, representada por 30% (1528 pontos), foi empregada na avaliação do desempenho alcançado (GHORBANI *et al.*, 2020).

3.3.1 Modelagem com Random Forests

Os métodos *ensemble* são algoritmos de *machine learning* que utilizam diversos previsores distintos para estimar uma variável desejada. Os resultados são calculados por meio de médias ponderadas dos valores obtidos em cada um dos previsores (DIETERICH, 2000). Dentre esse grupo, os modelos Random Forest são os mais populares, constantemente aplicados na solução de problemas em diversas áreas de estudo, tanto para classificação quanto para regressão (PAHNO *et al.*, 2021). Esses modelos são capazes de gerar previsões razoáveis nos mais distintos cenários, sendo formados por um conjunto de árvores de decisão que dependem de um vetor aleatório, determinado de modo independente para cada uma delas. O erro generalizado desse tipo de algoritmo está associado aos resultados e à correlação entre cada árvore de decisão, ao passo que converge após um certo número de árvores de decisão (BREIMAN, 1999).

As *Random Forests* foram desenvolvidas com base na metodologia CART (*classification and regression tree*), na qual a divisão em cada árvore segue por partições binárias ("splits"), que ocorrerem sucessivamente em relação às variáveis independentes. Inicialmente, observa-se o nó denominado como "raiz" de cada árvore, correspondente ao conjunto total de dados. Já na parte final da árvore, nos nós denominados “terminais”, não serão efetuadas novas divisões. Os nós intermediários se dividem em duas partes descendentes, à esquerda e à direita, o que irá depender do valor menor ou maior ao delimitado, respectivamente. O critério utilizado em cada *split* busca maximizar o aprimoramento do modelo pela melhor configuração possível, possibilitando a medida da qualidade do ajuste em cada nó (CUTLER *et al.*, 2012; CHEN e ISHWARAM, 2012; MEI *et al.*, 2014).

Entretanto, as RFs se diferenciam das árvores de decisão ao passo que possibilitam delimitar um número de variáveis aleatórias m , ou características em evidência, entre M variáveis independentes na seleção dos critérios de divisão em cada nó das árvores. Esse método, também chamada de *random subspace* busca diminuir a correlação entre árvores de

decisão que formam a floresta. Adicionalmente, também se aplica uma estratégia denominada *bagging*, objetivando solucionar a alta variância observada no desenvolvimento de árvores de decisão. Para isso, é selecionada parte da base de dados aleatoriamente, seguida pela seleção, também aleatória, dos *splits* dentro de cada árvore.

Esse processo leva à formação de amostras não utilizadas *out-of-bag* (OOB), que podem servir para a validação de resultados. Desse modo, são produzidas numerosas árvores de decisão, obtendo os resultados finais pela média dos valores de cada uma delas para regressões (HASTIE *et al.*, 2009; GRÖMPING, 2009; ZHOU *et al.*, 2020 e ATHEY *et al.*, 2019). Basicamente, considerando um número p de T árvores ($T_1(X)$, $T_2(X)$, ..., $T_p(X)$), adotando X como um vetor de n entradas ($X = x_1, x_2, \dots, x_n$), tem-se um vetor $Y_1 = T_1(X)$, $Y_2 = T_2(X)$, ..., $Y_C = T_C(X)$ de saídas, cujo valor final “ y ” se dará pela média calculada.

Dentre as principais vantagens associadas às *Random Forest*, destaca-se a facilidade e rapidez no treinamento e ajuste de parâmetros, mesmo frente aos métodos mais populares, como RNAs. Além disso, RFs são bastante adaptáveis, robustas quanto à presença de pontos destoantes (*outliers*) e não requerem necessariamente múltiplos procedimentos de treino como o *cross validation* (AHMAD e REZGUI, 2017; MEI *et al.*, 2014). Ainda, pode-se dizer que o modelo sempre irá convergir quanto aos valores de erro, apesar do desempenho ser diretamente proporcional ao aumento do número de árvores de decisão até um determinado ponto (MEI *et al.*, 2014; AHMAD e REZGUI, 2017; GALIANO *et al.*, 2015; GONG *et al.*, 2018).

Ademais, algoritmos baseados em árvores de decisão são descritos como ótimas ferramentas de seleção de variáveis para a composição de modelos de regressão e classificação (CHO *et al.*, 2010; SCHAUMLÖFFEL *et al.*, 2019 e BAGHERZADEH-KHIABANI *et al.*, 2016). Existem diversos métodos dispostos na literatura que utilizam RF para definir a relevância de atributos na composição de modelos. Dentre eles, o método associado ao pacote VSURF (GENUER *et al.*, 2015) no software R se destaca por menores erros e menor parcimônia - menor quantidade de variáveis (SPEISER *et al.*, 2019 e SANCHEZ-PINTO *et al.*, 2018). Segundo Genuer *et al.* (2015), para cada árvore t (variando de 1 a n árvores na floresta), o erro atribuído a uma amostra OOB_t é permutado aleatoriamente entre x e j para obter uma nova amostra \widetilde{OOB}_t^j , e calcular o erro de um preditor atribuído a ela. Assim, a importância da variável será descrita por:

$$VI(X^j) = \frac{1}{n} \sum_t (\text{erro}\widetilde{OOB}_t^j - \text{erro}OOB_t) \quad (7)$$

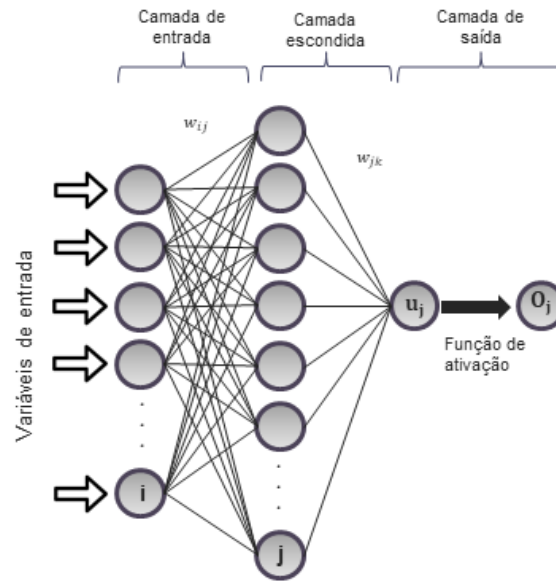
O diferencial do método do pacote VSURF está na abordagem totalmente orientada por dados, na qual a importância das variáveis será estimada após repetições nas florestas, em vez de assumir a normalidade de VI (Equação 7) como réplicas independentes. Basicamente, o processo ocorre em 2 fases. Na primeira as variáveis são elencadas conforme VI, sendo eliminadas as variáveis de menor importância. A segunda fase é dividida entre interpretação e predição. Na interpretação, são desenvolvidos modelos aninhados com k atributos, que varia de 1 até m , verificando as variáveis que levam ao menor erro OOB. Por fim, as variáveis delimitadas na etapa de interpretação são usadas em modelos ascendentes de RF, testando sua importância em uma estratégia *stepwise* (GENUER *et al.*, 2015).

3.3.2 Modelagem com Artificial Neural Networks

O desenvolvimento de Redes Neurais Artificiais tem se mostrado promissor à medida que proporciona a resolução de problemas complexos e multidisciplinares, abordando aspectos estatísticos e computacionais (KOVÁCS, 2002). Essas ferramentas, desenvolvidas para identificar padrões em um banco de dados, simulam a capacidade de processamento e aprendizagem dos neurônios humanos, cujo poder de processamento está na configuração da rede e de como os neurônios artificiais estão interligados (AGATONOVIC e BERESFORD, 2000).

A configuração da rede neural, ou seja, sua arquitetura, pode ser classificada em diferentes categorias. As redes *Feedforward*, por exemplo, são amplamente utilizadas em diversas aplicações e têm a capacidade de identificar padrões complexos em várias áreas das ciências (BENARDOS e VOSNIAKOS, 2007). Um dos tipos de redes *Feedforward* mais populares é o *Perceptron*, que pode ter uma ou várias camadas. A estrutura do Perceptron multicamadas é ilustrada na Figura 10. Esses algoritmos são compostos por camadas interconectadas que processam informações, começando pelas unidades de entrada, passando pelas unidades escondidas e chegando às unidades de saída. Quando a rede neural possui duas ou mais camadas escondidas, ela é chamada de rede de aprendizagem profunda, usada para resolver problemas complexos (ABIODUM *et al.*, 2018; JAIN *et al.*, 1996).

Figura 10 – Estrutura de um Perceptron com uma única camada escondida



Fonte: adaptado de LIU *et al.*, 2021

Pode-se dizer que as Redes Neurais Artificiais são projetadas para receber e processar sinais entre neurônios artificiais interconectados. Cada neurônio artificial calcula sua resposta com base em critérios predefinidos, levando em consideração os valores de entrada. Na camada escondida, a função de transferência computa as saídas para um vetor n -dimensional, com i neurônios na camada de entrada e avaliando os sinais da rede no neurônio j . Esse processo envolve uma combinação dos parâmetros do vetor X com coeficientes conhecidos como pesos - uma analogia às conexões entre axônios e dendritos em neurônios biológicos - como mostrado na Equação 8 (ZUPAN, 1994 e BEHRANG *et al.*, 2010).

$$y_j = f\left(\sum_{j=1}^m w_{jk} + f\left(\sum_{i=1}^n w_{ij}X_i\right)\right) \quad (8)$$

Onde

$f(X)$: função de transferência.

X_i ; vetor de sinais da camada de entrada.

w_{ij} : conexões ou pesos entre a camada de entrada e camadas escondidas.

w_{jk} : conexões ou pesos entre as camadas escondidas e camada de saída.

As funções de transferência podem ter diversas configurações, sendo mais indicada a aplicação de funções não lineares caso se identifique problemas não linearmente separáveis.

Dentre os principais exemplos pode-se citar a função hiperbólica e a sigmoideal (ZOU, 2008). Já nos últimos anos, com o avanço nos processos e softwares aplicáveis, a função de ativação *Rectified Linear Unit* (ReLU) vem sendo fortemente recomendada na construção de algoritmos de regressão, seja pela facilidade na execução de cálculos, ou mesmo pela alta velocidade de convergência (LIN e SHEIN, 2018; DUBEY e JAIN, 2019). O comportamento da função está descrito na Tabela 6.

Tabela 6 – Comportamento da função ReLU e de sua derivada

ReLU	
Função	$F(z) = \begin{cases} 0, & z < 0 \\ z, & z \geq 0 \end{cases}$
Derivada	$F'(z) = \begin{cases} 0, & z < 0 \\ 1, & z \geq 0 \end{cases}$

Fonte: adaptado de Dubey e Jain (2019)

Dentre os vários algoritmos de treinamento das RNAs, o *Backpropagation* é amplamente utilizado e foi aplicado neste estudo. O processo de análise de erros ocorre da camada de saída em direção à camada de entrada, comparando os dados da camada de saída com os valores alvo da base de dados. As conexões entre os neurônios são continuamente atualizadas até que um valor de erro aceitável seja alcançado, de acordo com o critério pré-estabelecido (KHAN *et al.*, 2011; NASR *et al.*, 2021). Na atualização dos pesos, é importante utilizar algoritmos que permitam ajustes para alcançar valores mínimos de erro. Um dos algoritmos comumente utilizados é o *Stochastic Gradient Descent* (SGD), que é o padrão atribuído ao algoritmo no software RStudio. O SGD propõe a atualização das conexões com base no gradiente de uma função de perda, demonstrando maior rapidez, confiabilidade e menor probabilidade de convergir para um mínimo local subótimo em comparação com o método padrão de gradiente descendente (BOTTOU, 1991).

Dessa maneira, a construção do modelo neural neste artigo foi orientada pela análise e seleção da quantidade de camadas escondidas e do número de neurônios que as compõem em um *perceptron* multicamadas. Para isso, foram realizados processamentos em sequência, considerando: (a) uma camada - suficiente para a solução de problemas linearmente separáveis - e (b) duas e (c) três camadas escondidas - que permitem gerar bons resultados na maior parte dos problemas. Em cada camada, atribuir poucos neurônios pode gerar erros elevados por não representarem a complexidade do problema em questão (*underfitting*). Entretanto, um número muito elevado de neurônios nas camadas ocultas possivelmente ocasiona ajuste excessivo à base de dados (*overfitting*), devendo-se limitar essa quantidade a duas vezes o valor de

parâmetros de entrada (KARSOLYIA, 2012 e CIABURRO e VENKATESWARAM, 2017).

Ademais, Gökhan *et al.* (2019) e Jayalakshmi e Santhakumaran (2011) adicionam que o tratamento inicial dos dados de entrada das RNAs é tão importante quanto o ajuste dos parâmetros do algoritmo, aumentando a qualidade do modelo, impedindo análises mais complexas, longas e reduzindo ruído. Configurando um dos tipos de processos mais aplicados nessa tarefa, a normalização busca escalonar o vetor de entrada a uma mesma unidade, proporcionando maior velocidade no processamento do aprendizado da rede. A normalização estatística adotada neste artigo consiste na divisão da subtração entre a variável y do i -ésimo termo e a média μ pelo desvio padrão σ_i , como descrito na Equação 9, obtendo uma variável y' de média zero. Os demais parâmetros da biblioteca “h2o” foram delimitados na opção *default*.

$$y' = \frac{y_i - \mu_i}{\sigma_i} \quad (9)$$

3.3.3 Parâmetros de desempenho

Como métrica de avaliação de erros, foi proposto o uso do *Root Mean Squared Error* (RMSE), como é demonstrado na Equação 10. Chai e Draxler (2014) sugerem que esse parâmetro geralmente retorna bons resultados na análise do desempenho de modelos distintos e evita o uso de valores absolutos de erro, como faz o *Mean Absolut Error* (MAE). Ainda, como parâmetro de comparação para o ajuste de modelos, foi utilizado o coeficiente de determinação R^2 (Equação 11).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (10)$$

$$R^2 = \left[\frac{N \sum_{i=1}^N (\hat{y}_i y_i) - \sum_{i=1}^N \hat{y}_i \sum_{i=1}^N y_i}{N \sum_{i=1}^N y_i^2 - (\sum_{i=1}^N y_i)^2 \sqrt{N \sum_{i=1}^N \hat{y}_i^2 - (\sum_{i=1}^N \hat{y}_i)^2}} \right] \quad (11)$$

Onde y representa os valores observados, \hat{y} os valores previstos, N é o número de observações que variam em i , assumindo valores de 1 até N .

3.4 Resultados e discussões

3.4.1 Análise do comportamento das variáveis das amostras ensaiadas

A configuração dos resultados obtidos pela execução dos testes de caracterização básica (granulometria, compactação, CBR, expansão e limites de consistência) para os 7 tipos de solos analisados, foi estatisticamente descrita na Tabela 7 e então resumidos na Tabela 8.

Tabela 7 – Estatísticas básicas da base de dados

Variáveis	Descrição	Unidades	Min	Max	Média	Mediana
DP	Deformação Permanente	%	0,01	4,974	0,68	0,29
σ_d	Tensão Desvio	kPa	40	120	77,12	80
σ_3	Tensão Confinante	kPa	40	360	148,3	120
N	Número de ciclos	-	1	150000	30450	21000
IP	Índice de Plasticidade	%	0	20	5,52	0
Wotm	Teor ótimo de umidade	%	8,8	13,5	10,6	10,0
D.max	Massa específica seca máxima	g/cm ³	1,79	2,11	1,942	1,910
CBR	California Bearing Ratio	%	3,00	34,00	13,59	7,00
N10	Porcentagem passante na peneira #10	%	74,18	99,95	90,99	97,10
N40	Porcentagem passante na peneira #40	%	49,60	92,95	70,79	70,86
N200	Porcentagem passante na peneira #200	%	4,31	48,90	28,07	31,93
D.real	Densidade Real	-	2,46	2,66	2,60	2,63
Cu	Coefficiente de Uniformidade	-	3,00	200,00	71,10	51,43
Cc	Coefficiente de Curvatura	-	0,74	4,50	2,34	1,33

Fonte: elaborada pelo autor (2023)

Tabela 8 – Caracterização das amostras de solo


Amostras	Class AASHTO	IP	Wotm	D.max	Exp	CBR	N10	N40	N200	D.real	Cu	Cc
A3	A-3	NP	10	1,79	0,00	22	99,95	92,95	7,25	2,66	3,00	1,33
A2-1	A-2-4	NP	8,8	2,11	0,17	6	98,07	71,85	31,93	2,61	72,50	3,87
A4	A-4	NP	13,5	1,95	0,00	7	97,10	76,10	48,4	2,63	51,43	0,84
A6	A-6	13	11	1,97	0,30	3	86,71	67,09	41,47	2,46	200,0	4,50
A1	A-1-b	NP	9,5	1,98	0,00	34	74,18	49,60	1,89	2,64	5,91	0,74
A4-2	A-4	7	9,6	2,09	0,13	15	78,14	60,88	37,61	2,67	44,44	1,17
A2-2	A-2-7	20	10	2,54	3,30	5	69,01	46,68	34,5	1,99	200	0,72

Fonte: elaborada pelo autor (2023)

A análise do comportamento dessas variáveis teve como objetivo possibilitar o direcionamento aos principais critérios e metodologias, indicando a abordagem mais adequada

para inferir a força de associação entre elas. Nesse sentido, para identificar o grau de correlação existente entre os parâmetros a serem utilizados nos modelos de previsão, é necessária a avaliação de características como a normalidade dos dados, que configuram premissas necessárias à aplicação de teste paramétrico. Após a realização do teste de Kolmogorov-Smirnov, com valor p de $2.2e-16$, rejeitando a hipótese nula (valor de p inferior a 0,05) foi constatada a não normalidade no conjunto analisados. Assim, foi proposta a utilização do coeficiente de correlação de Kendall para construir a matriz de correlação mostrada na Figura 11.

Figura 11 – Matriz de correlação entre as variáveis propostas



Fonte: elaborado pelo autor (2023)


A matriz de correlação apresentada classifica o grau de correlação entre as variáveis a partir das cores azul e vermelho. Quanto mais próxima a 1, mais forte o tom de vermelho e maior a correlação positiva entre as variáveis. De modo semelhante, quanto mais próximo a -1, mais intenso o tom de azul e maior a correlação negativa.

Foi observada uma correlação positiva entre a deformação permanente (DP) e as tensões atuantes, sendo evidente a maior influência da tensão de desvio na variável resposta, conforme indicado pelo maior coeficiente de correlação obtido. Nesse sentido, a variação da

tensão de desvio teve um impacto significativo em amostras de solos arenosos e siltosos-arenosos (A3, A1), resultando em deformações plásticas superiores a 4%. Essa conclusão é reforçada pelo rompimento de amostras arenosas romperam sob as tensões mais elevadas, como observado nos pares de tensão 120×240 e 120×360 KPa para o solo A3, enquanto o solo A1 não suportou a aplicação do par de tensão 120×360 KPa. Um comportamento semelhante foi verificado em alguns solos argilosos (ZAGO *et al.*, 2021).

Por outro lado, quando as tensões desvio foram mantidas constantes, observou-se que o aumento da tensão confinante resultou em menores valores de deformação plástica acumulada. Esse efeito pode estar associado à maior proximidade entre os grãos dos solos (LING *et al.*, 2017; ZHANG *et al.*, 2021). Além disso, o aumento da tensão confinante também provocou uma maior variação nas deformações verticais medidas, conforme discutido por Werkmeister (2009). A Figura 12 ilustra a variação da deformação plástica máxima (%) obtida após 150.000 ciclos de aplicação nos ensaios para as 7 amostras.

Figura 12 – Deformação acumulada em cada solo nos ensaios realizados



Fonte: elaborado pelo autor (2023)

A porcentagem passante na peneira N° 200 e a umidade ótima demonstraram correlações negativas com a deformação acumulada dos solos analisados. Pode-se dizer que a granulometria exerce influência no comportamento plástico dos materiais geotécnicos, uma vez que o aumento da quantidade de finos em uma amostra tende a reduzir a deformação observada, devido ao aumento da capacidade do solo em resistir à aplicação de esforços (CAO *et al.*, 2018; DUONG *et al.*, 2016; JING *et al.*, 2018). Nesse contexto, a relação negativa entre a deformação do solo e o teor de umidade também pode estar associada à presença de finos nas amostras, bem

como à possibilidade de um comportamento laterítico dos materiais (CAO *et al.*, 2018).

Além disso, foi observada uma associação negativa entre a DP e o Coeficiente de Uniformidade (Cu), com um coeficiente de correlação de -0,17. Isso indica que um aumento no valor do coeficiente de uniformidade, que reflete uma maior variabilidade na dimensão dos grãos, confere maior resistência ao cisalhamento (CAI *et al.*, 2018; GUIMARÃES, 2009; PINTO, 2000).

No que se refere à capacidade de suporte, a matriz de correlação indica uma relação positiva entre o CBR e as deformações plásticas acumuladas. Isso significa que, para o grupo de solos analisados, valores mais elevados de CBR não estão associados a menores deformações plásticas. De acordo com os critérios do método empírico de dimensionamento de pavimentos asfálticos brasileiro, a capacidade de suporte dos solos é um parâmetro crítico para determinar a aplicabilidade dos materiais estudados. Com base somente nos critérios de CBR, os solos de A3 e A1 poderiam ser utilizados em camadas de sub-base, uma vez que apresentam um CBR superior a 20% e baixa expansão. Já as demais amostras seriam adequadas apenas como material de subleito para a possível construção de rodovias, com exceção do solo A2-2, que apresenta expansão elevada (maior que 3%).

Por outro lado, os materiais arenosos, classificados como A3 e A1, apresentaram maior deformação plástica após a aplicação dos 150.000 ciclos no equipamento triaxial, mesmo tendo os maiores valores de CBR entre as amostras analisadas, como indica a correlação positiva. Por outro lado, o solo argiloso A6 de Mombaça mostrou deformações máximas inferiores a 0,7%, apesar de apresentar valores de CBR mais baixos e IP maior que 6%. Esses resultados estão em conformidade com um estudo realizado por Cabral (2021), que também observou uma maior deformação permanente acumulada em solos classificados como A-1-b e A-3 em comparação com amostras classificadas como A-2-4 e A-7-6, que foram coletadas em uma região adjacente à área estudada no estado do Ceará.

Pode-se perceber que os critérios ainda adotados quanto ao CBR e classificação AASHTO não estão alinhados à análise de parâmetros do novo método mecanístico-empírico. Nesse sentido, essas especificações são consideradas limitadas para avaliação prévia da qualidade de materiais geotécnicos do estado do Ceará quanto à deformação plástica acumulada por carregamentos dinâmicos. Assim, torna-se importante a análise e obtenção desse tipo parâmetro para o melhor entendimento acerca das possíveis limitações da aplicação dos métodos empíricos no dimensionamento dos pavimentos. É importante destacar que o uso de metodologias como a da classificação MCT (Miniatura, Compactado, Tropical) pode explicar melhor o comportamento desses solos em relação aos parâmetros mencionados.

Outras variáveis, como número de ciclos de aplicação de carga e Densidade Real também demonstram correlações positivas com a deformação acumulada das amostras superiores a 0,1. Apesar das demais propriedades apresentaram coeficientes de correlação entre -0,1 e 0,1, todas as variáveis independentes elencadas foram consideradas na composição dos modelos, de modo a verificar a resposta dos algoritmos quando à influência dos parâmetros de entrada.


3.4.2 *Desenvolvimento do Modelo de Random Forest*

No desenvolvimento de modelos de *Random Forest* deve ter como foco dois principais parâmetros, número “ m ” de variáveis em evidência e “ n ” árvores de decisão (GENUER *et al.*, 2010 e ALNAHIT *et al.*, 2022). Em regressões, o valor inicial sugerido para “ m ” é o de um terço do número de variáveis independentes, embora essa delimitação deva ocorrer a partir de testes, já que valores diferentes podem trazer resultados melhores (HASTIE *et al.*, 2009). Para observar a influência da variação do número m de variáveis, foi definido o intervalo de testes entre 4 e 14 variáveis, quando todas as variáveis de entrada seriam aplicadas na previsão da DP, configurando a aplicação simplesmente da estratégia de *bagging*. O particionamento (*random subspace*) de dados adotado como uma das principais estratégias de modelos de RF permite a análise de uma espécie de grupos de dados de validação, *out-of-bag* (OOB).

Nesse sentido, foi avaliado a variação do erro OOB para identificar o valor mais adequado de m dentro do intervalo sugerido e adotando um fator de crescimento de 1.5, com um número constante de 500 árvores. É notável que o erro observado diminui progressivamente com incremento do número de variáveis em evidência, como também constataram Ahmad e Rezgui (2017). Entretanto, a redução do erro é mínima entre 12 e 14 variáveis, o que indica a seleção de um m igual a 13 como mais adequada para garantir menor correlação entre as árvores formadas (Figura 13a).

Como esperado, o aumento no número de árvores resulta no decréscimo do erro observado, percebendo-se a estabilização da taxa de redução por volta de 100 árvores, quando o modelo converge para resultados constantes (Figura 13b). Optou-se por definir o número mínimo de nós finais (*nodesize*) como 5, seguindo os valores indicados na literatura para regressões, como especificado por Probst *et al.* (2019). Os demais parâmetros da biblioteca “randomforest” foram delimitados como *default*.

Figura 13 – Definição dos parâmetros de entrada do modelo de RF no Rstudio



(a) Influência do número m no modelo

(b) Evolução do erro pelo aumento no número de árvores

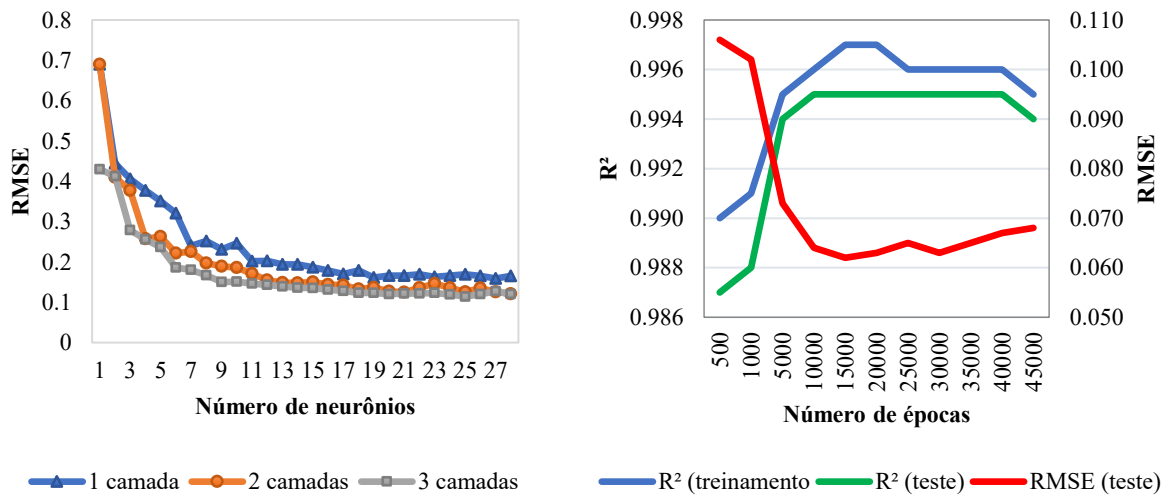
Fonte: elaborado pelo autor (2023)

3.4.3 Desenvolvimento do modelo de RNA

Foram testadas topologias com 1, 2 e 3 camadas escondidas, variando o número de neurônios de 1 a 28 em cada camada, e definindo um número de épocas igual a 100 de forma preliminar. A Figura 14 mostra os resultados de erro para a base de testes pela variação do número de neurônios e camadas escondidas. A partir de cerca de 12 neurônios a taxa de variação dos erros se reduz. De modo geral, o desempenho de 1 camada escondida é inferior à abordagem de *deep learning* (2 e 3 camadas). O menor valor de RMSE é obtido então a partir de 25 neurônios e 3 camadas escondidas (Figura 14a).

Delimitando a arquitetura composta por 3 camadas escondidas de 25 neurônios, ainda foi necessário definir o número de iterações do modelo, já que o critério de parada foi definido para um número fixo de épocas. O gráfico mostrado na Figura 14b demonstra a variação do RMSE de testes e dos coeficientes R^2 das bases de treinamento e testes perante o acréscimo no número de épocas. Inicialmente os erros da base de testes decrescem rapidamente até se estabilizarem, iniciando uma tendência de crescimento após 15.000 épocas. Paralelamente, os valores de R^2 de treinamento começam a decrescer, também após 15.000 épocas, sendo esse ponto definido como número de iterações a ser adotado.

Figura 14 – Variação do RMSE pelo número de épocas



(a) Variação do RMSE pelo número de camadas escondidas e neurônios.

Fonte: elaborado pelo autor (2023)


(b) Determinação do critério de parada pelo número de épocas.

3.4.4 Análise do desempenho dos modelos

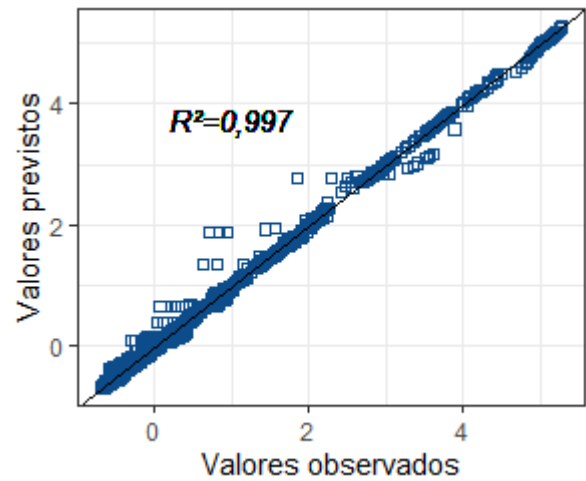
Inicialmente, cabe ressaltar a praticidade do treinamento de modelos de *Random Forest* frente às RNAs. Para otimizar os resultados, a definição do número de hiperparâmetros e a quantidade de testes necessários à seleção da arquitetura ótima de uma rede neural podem demandar horas. Em contrapartida, o desenvolvimento do algoritmo *ensemble* foi efetuado com maior rapidez e menor esforço computacional. Entretanto, deve-se considerar que o algoritmo baseado em árvores de decisão não consegue prever dados em um intervalo fora da faixa de treinamento (número de ciclos e tensões atuantes).

Foram construídos gráficos de dispersão entre os valores previstos e observados de treinamento e teste para os modelos finais, após a retirada das variáveis menos significativas, como ilustrado na Figura 15. Tanto a análise de RMSE quanto os coeficientes de correlação observados permitem inferir que os modelos de *Random Forest* alcançam melhores resultados, mesmo sabendo-se que as divergências entre os erros obtidos não foram tão expressivas. Por conseguinte, a análise gráfica da relação entre os valores previstos e observados demonstra que houve melhor ajuste para o modelo de *Random Forest*, uma vez que os pontos se concentram de forma mais uniforme sobre a reta diagonal traçada, que representa a trajetória sobre a qual os valores observados são iguais aos valores previstos.

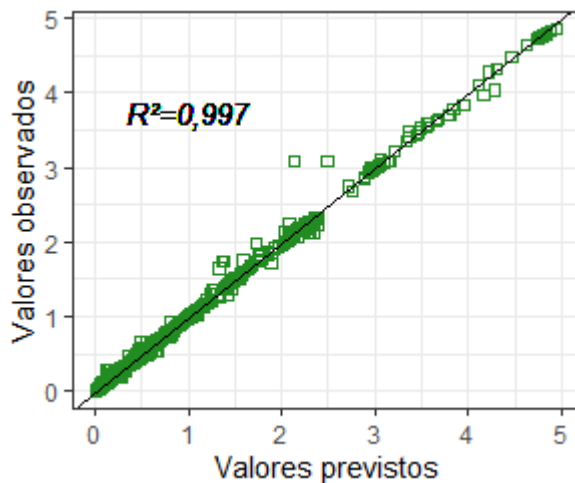
Figura 15 – Gráficos de dispersão entre valores previstos e observados para a base de treinamento e teste dos modelos de RF e RNA




(a) Gráfico de dispersão da base de treinamento, modelo RF.



(b) Gráfico de dispersão da base de treinamento, modelo RNA.



(c) Gráfico de dispersão da base de testes, modelo RF.



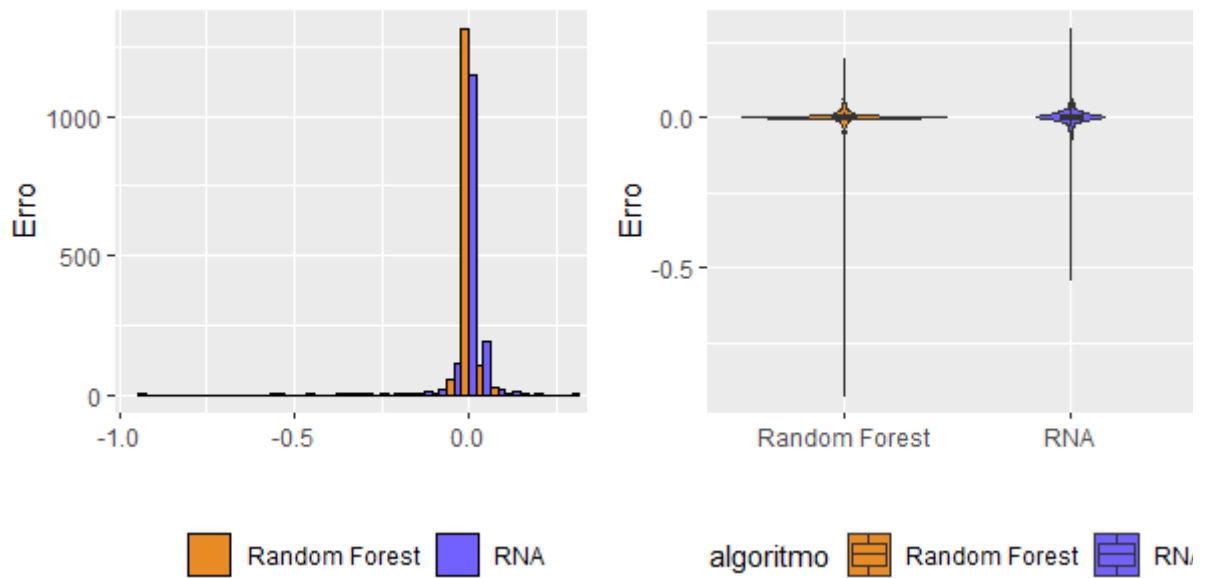
(d) Gráfico de dispersão da base de testes, modelo RNA.

Fonte: elaborado pelo autor (2023)

Foram gerados os histogramas mostrados na Figuras 16a e gráficos de violino aliados a *boxplots*, Figura 16b, que expõem a configuração dos resíduos gerados pelos dois modelos propostos. O deslocamento dos histogramas para a direita e a amplitude das retas verticais que ultrapassam os limites dos *boxplots* gerados evidenciaram a existência de pontos destoantes, ou *outliers*. Por outro lado, os erros entre valores observados e previstos se concentraram próximos a zero, justificando o formato dos histogramas e *boxplots* achatados, até mesmo dificultando a visualização dos gráficos de violino gerados. Apesar das semelhanças entre os resultados obtidos, é possível apontar maior frequência de menores valores de erro (mediana mais próxima a zero e formato do histograma) e menor variabilidade (*boxplots* mais

achatados) para o modelo de RF. Entretanto, o modelo *ensemble* também gerou pontos destoantes com maior amplitude de erros.

Figura 16 – Distribuição dos erros gerados pelos modelos



(a) Histograma dos resíduos dos modelos

(b) Gráficos de violino + *boxplots* dos resíduos dos modelos

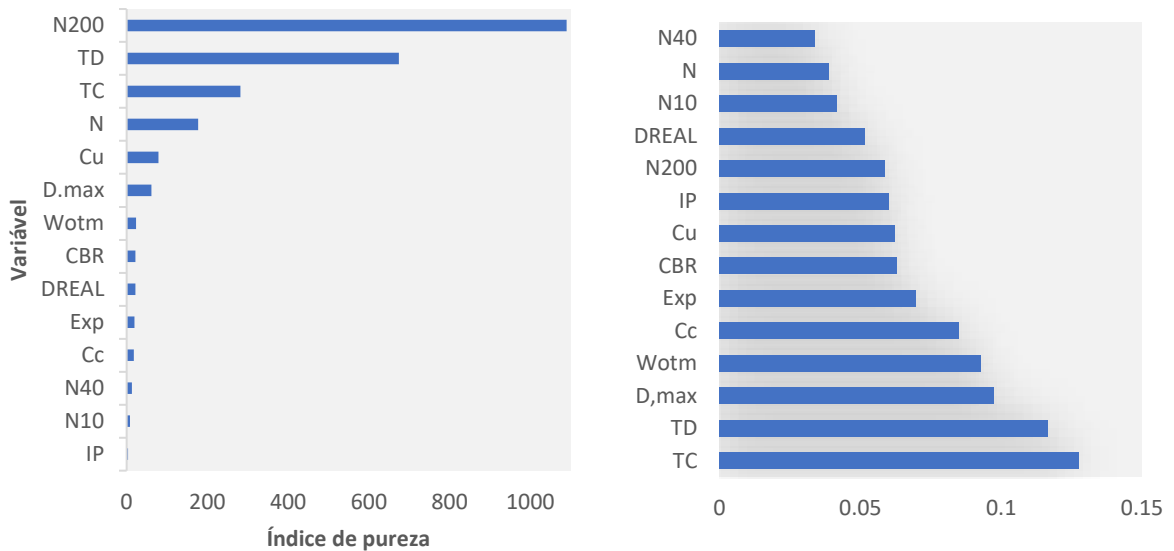
Fonte: elaborado pelo autor (2023)

3.4.5 Análise de sensibilidade e seleção de variáveis de entrada

Uma das formas para analisar a importância de uma variável para o modelo em *Random Forest* é pela avaliação do grau do aumento na pureza dos nós pela remoção de determinada variável independente. Basicamente, esse índice mede o decréscimo na pureza dos nós dentro das divisões realizadas em uma variável, levando em consideração a média de todas as árvores da floresta. Sua medida é efetuada pela soma dos quadrados, e quanto maior o valor obtido, maior a pureza e a importância da variável para o modelo (PAHNO *et al.*, 2021; e HAN *et al.*, 2016). Já para modelos neurais, a análise de sensibilidade garante a avaliação da importância de cada variável na previsão da característica desejada. Estima-se que um número alto de variáveis de entrada tende a gerar melhores resultados, mas variáveis redundantes ou irrelevantes podem prejudicar seu desempenho (GETAHUN *et al.*, 2018; WAGH *et al.*, 2017 e ALNEDAWI *et al.*, 2019).

Na Figura 17 pode ser observada a variação do índice de pureza (IncNodePurity) para cada variável independente proposta no modelo de RF (17a) e a contribuição percentual de cada variável para o modelo de RNAs (17b).

Figura 17 – Contribuição das variáveis para os modelos desenvolvidos



(a) RF

(b) RNA

Fonte: elaborado pelo autor (2023)

Com exceção das tensões atuantes e número de ciclos de aplicação de carga, os modelos divergem em elencar a relevância de cada variável na composição dos modelos. Além disso, enquanto no modelo RNA nenhuma variável exerceu influência majoritária em comparação às outras, no modelo de RF notou-se a ocorrência de variáveis com índice de pureza muito superior às demais. A porcentagem passante na peneira #200, o coeficiente de curvatura e a densidade máxima se destacaram, enquanto as demais características e propriedades físicas dos solos apresentaram índices próximos a 0.

Deve-se considerar que a redução no número de atributos previsores pode otimizar o processo de previsão da DP, à medida que minimiza o número de ensaios necessários. Dessa forma, restringir o número menor de parâmetros de entrada, caso não haja prejuízos ao ajuste dos modelos, é uma ótima alternativa de incrementar o desempenho da metodologia proposta. Especificamente, o ajuste com maior parcimônia (menor número de variáveis) otimiza o trabalho laboratorial, necessitando da realização de menos ensaios, assim como favorece a inserção de dados disponíveis na literatura para incrementar o poder de generalização dos modelos de previsão. Essa questão é especialmente importante na previsão da DP de solos, tendo em vista a limitação no número de dados disponíveis, sobretudo de ensaios realizados nas especificações atuais brasileiras.

A primeira estratégia aplicada foi a retirada das variáveis com índice de pureza

próximo a zero. Nesse sentido, apenas as tensões atuantes, número de ciclos, Densidade Máxima e Coeficiente de Curvatura (Cu) e porcentagem passante na peneira N° 200 foram consideradas como parâmetros de entrada. Ainda, foi utilizado o pacote VSUR para identificar as variáveis relevantes ao modelo, buscando otimizar os resultados obtidos. Após as duas etapas do procedimento, foram identificadas como atributos a serem mantidos as tensões atuantes, número de ciclos e porcentagem passante na peneira N° 200, o que também reafirma os quatro atributos com maior índice de pureza no modelo desenvolvido anteriormente.

Dessa forma, o que o teor de finos, referente à porcentagem N° 200, foi identificado como um parâmetro essencial na explicação do comportamento plástico dos solos da região analisada. Com objetivo de comparar os resultados, os testes para RF foram executados com m igual o número de entradas e a arquitetura das RNAs foi executada conforme a estrutura apontada como ótima na seção 3.4.3. A Tabela 9 permite comparar os erros (RMSE) de testes após a retirada das variáveis com menor relevância pelos dois pacotes.

Tabela 9 – Impacto no RMSE de testes após a retirada de variáveis por algoritmos de RandomForest

Métodos	Modelos	RMSE (teste)
Todas as variáveis	RF	0,033
<i>Randomforest</i>	RF	0,034
<i>Vsurf</i>	RF	0,024
Todas as variáveis	RNA	0,062
<i>Randomforest</i>	RNA	0,063
<i>Vsurf</i>	RNA	0,061

Fonte: elaborada pelo autor (2023)

A retirada de atributos com Índice de Pureza próximo a 0 pela biblioteca *randomforest* não causou variações significativas nos erros da base de dados de teste dos modelos de RF e RNA, com acréscimos de 0,001 no RMSE obtido. Por outro lado, apesar de propor a retirada de duas variáveis a mais (Densidade Máxima e Coeficiente de Uniformidade) o pacote *VSURF* ocasionou redução de 0,001 no RMSE em comparação ao modelo com todas as variáveis, indicando maior efetividade do método. A redução do número das variáveis independentes proposta em ambas as estratégias favorece a implementação dos modelos, uma vez que reduz a necessidade da realização de ensaios como limites de consistência, CBR e Densidade Real.

3.5 Conclusões

Este capítulo buscou analisar a criação e ajuste de modelos de previsão da Deformação Permanente de solos de uma região brasileira por meio de suas propriedades geotécnicas. Foi considerada uma ampla variação de pares de tensão atuantes (pelo menos 9 estados de tensão para cada solo), fazendo uso de ensaios de estágios múltiplos, em um intervalo de 150.000 ciclos de aplicação de carga. As principais contribuições da pesquisa desenvolvida são expressas a seguir:

- a) embora ainda sugerida em especificações brasileiras atuais, a avaliação de solos por critérios somente da classificação AASHTO e CBR não é indicada para a região analisada. Essa abordagem pode apontar solos com elevadas deformações plásticas acumuladas como materiais de comportamento satisfatório, mesmo em camadas de sub-base. Portanto, enfatiza-se a necessidade de métodos auxiliares, que busquem identificar de forma preliminar a DP de materiais geotécnicos, de modo a mitigar as limitações trazidas por esse tipo de análise, de modo que se possa encorajar o emprego de abordagens empíricas-mecanísticas.
- b) a avaliação dos erros e do ajuste dos modelos sinaliza efetividade dos métodos de RF e RNA na previsão da DP a partir de propriedades e índices físicos dos solos, considerando diferentes estados de tensão em ensaios de estágio único e dentro de um amplo intervalo de ciclo de aplicações. Todavia, o emprego dessas ferramentas na previsão do comportamento de solos ainda requer a adição de novas amostras à base de dados. Nesse sentido, a incorporação de novos solos deve elevar o poder de generalização dos modelos, tendo em vista a variabilidade espacial no comportamento de uma área tão extensa como é o caso do Estado do Ceará.
- c) a variável porcentagem passante na peneira N° 200 foi indicada como efetiva na previsão da estimação dos valores de DP por duas diferentes abordagens baseadas em *Random Forest*. Para tanto, pode-se inferir que o comportamento plástico dos materiais da região analisada depende substancialmente da quantidade de finos presentes. Entretanto, também é importante mencionar que, à medida que novos materiais são inseridos na base de dados de treinamento, essa relação pode sofrer modificações, atribuindo-se maior importância a outras propriedades. Sendo assim, o desenvolvimento de modelos futuros deve

considerar um grupo amplo de variáveis, como sugerido neste artigo.

- d) os modelos desenvolvidos neste estudo demonstraram alto desempenho para ambos os algoritmos propostos. Foram alcançados valores de RMSE de 0,062 para Redes Neurais e 0,042 para *Random Forest*, além de coeficientes de correlação superiores a 0,99. Assim, os modelos demonstraram excelente ajuste diante das condições de ensaio brasileiras (longo intervalo de ciclos de aplicação de carga e ensaios de estágio único). Logo, a metodologia analisada pode ser implementada na previsão da DP de solos em rodovias, à medida que seja organizado um banco de dados mais robusto de amostras de solo para aumentar a assertividade frente à variabilidade espacial de características de materiais geotécnicos.
- e) embora os dois métodos (RNA e RF) tenham demonstrado bom ajuste quanto ao problema proposto, o algoritmo de *Random Forest* resultou em coeficientes de correlação, nas bases de treino e teste, além de valores de RMSE ligeiramente superiores. A avaliação da distribuição dos erros absolutos também corrobora com essa constatação, à medida que indica menores valores de erro e variabilidade para o método ensemble. Porém, o principal benefício observado é referente ao período de treinamento consideravelmente superior para redes neurais, denotando a superioridade de *Random Forest* quanto à facilidade e rapidez no desenvolvimento dos modelos de regressão pelo software utilizado. Apesar disso, essa ferramenta não permite a previsão de dados fora da faixa de tensões e ciclos de aplicação da base de treinamento, sendo importante levar em conta essa limitação quanto à aplicabilidade dessa estratégia.

Assim, a presente pesquisa demonstrou a viabilidade dos métodos propostos na previsão da deformação plástica de solos para uso em pavimentação, considerando as especificações indicadas pelas normas brasileiras. Dessa forma, esses modelos de previsão podem permitir a identificação prévia das propriedades de materiais disponíveis em uma área, possibilitando economia de recursos e de tempo para o gestor e a obra como um todo. Entretanto, é necessária a calibração contínua dos modelos propostos, expandindo o banco de dados para assegurar melhor poder de previsão e generalização dessas ferramentas.

4 APLICAÇÃO DE MACHINE LEARNING NA PREVISÃO DA DEFORMAÇÃO PERMANENTE DE SOLOS EM ENSAIOS DE ESTÁGIO ÚNICO

Resumo

A caracterização de solos quanto às deformações plásticas acumuladas é essencial para entender seu comportamento frente às sucessivas aplicações de cargas provenientes do tráfego. A ausência do controle dessa propriedade pode acarretar no surgimento de afundamentos elevados, prejudicando a estrutura de pavimentos em aspectos funcionais e estruturais. Nesse sentido, utiliza-se o equipamento triaxial de cargas repetidas para obtenção da Deformação Permanente (DP) de materiais geotécnicos pela aplicação progressiva de diferentes pares de tensões. Entretanto, esse tipo de análise demanda recursos humanos, materiais e tempo consideráveis, especialmente pelas especificações brasileiras, que consideram a realização de ensaios de estágio único e adoção de 150.000 ciclos e 9 estados de tensão. Desse modo, este trabalho busca reduzir o número de ciclos necessário para o ensaio, a partir da aplicação de modelos de previsão. Foram analisadas 7 amostras de solos, 5 para o desenvolvimento dos modelos e 2 para validação dos resultados. A partir do uso de Redes Neurais Artificiais, e com a retirada dos 1.000 ciclos iniciais no treinamento dos modelos, foi possível obter deformações que levaram a Afundamentos de Trilha de Roda (ATR) próximos ao obtido com 150.000 ciclos, tomando apenas 30.000 ciclos do ensaio. Desse modo, à medida que foram alcançados erros inferiores a 0,09 mm em condições de tráfego severo, o método proposto demonstrou-se uma boa alternativa à execução convencional do ensaio de DP, permitindo a redução de até aproximadamente 50% na caracterização de amostras quanto às deformações plásticas.

Palavras chave: Redes Neurais Artificiais, Dimensionamento, Pavimentos asfálticos, Materiais granulares

4.1 Introdução

Um dos principais objetivos do projeto e construção de pavimentos asfálticos rodoviários é garantir sua capacidade de resistir à deformação plástica dentro de limites toleráveis, evitando deformações irreversíveis significativas (WERKMEISTER, 2003). Ao longo do tempo, essas deformações acumulam-se nas diferentes camadas da estrutura, resultando em afundamentos que reduzem a capacidade de serviço do pavimento. Portanto, a avaliação da deformação experimentada pelos materiais devido ao tráfego está associada tanto à condição estrutural quanto à funcionalidade dos pavimentos asfálticos (SINGH e SAHOO, 2021).

Para caracterizar a deformação dos solos do subleito e dos materiais granulares utilizados nas camadas dos pavimentos, utiliza-se o equipamento triaxial de cargas repetidas. Esse equipamento permite analisar tanto as deformações resilientes ou recuperáveis quanto as deformações plásticas ou permanentes (DP). Enquanto as deformações recuperáveis são

medidas por meio do ensaio de Módulo de Resiliência (MR), a DP é avaliada pelos deslocamentos verticais causados pela aplicação de cargas sucessivas (GU *et al.*, 2017). No entanto, os procedimentos realizados no equipamento triaxial exigem tempo e recursos significativos, o que pode limitar sua utilização no projeto e execução de obras viárias (RAHMAN *et al.*, 2021; NAZZAL e MOHAMED, 2010). Além disso, é importante ressaltar que a análise isolada do Módulo de Resiliência nem sempre garante a correta caracterização dos materiais, uma vez que alguns solos podem apresentar alta deformação acumulada mesmo quando possuem valores de MR recomendados (PUPPALA *et al.*, 1999; VENKATESH *et al.*, 2020).

No Brasil, o novo método mecanístico-empírico de dimensionamento de pavimentos especifica a análise tanto da deformação permanente 179/2018 - IE (DNIT, 2018a) quanto resiliente 134/2018-ME (DNIT, 2018b) na avaliação das propriedades dos materiais e do terreno de fundação da rodovia. No entanto, além das dificuldades associadas aos custos do equipamento triaxial e de sua manutenção no país, estima-se que o tempo total de ensaio de DP seja de 21 horas por corpo de prova para cada par de tensão, adotando 150.000 ciclos de aplicação de carga e 2 Hz de frequência recomendada, o que resulta em cerca de 8 dias consecutivos de ensaio para 9 pares de tensão. Assim, leva-se aproximadamente duas semanas para a caracterização completa de uma única amostra de solo, considerando todas as paradas necessárias, o que dificulta ainda mais o emprego desse tipo de análise na construção de rodovias brasileiras. Nessa situação, acredita-se que as estruturas construídas, sem a análise dos parâmetros de rigidez (MR e DP), podem apresentar redução em seu desempenho ao longo de sua vida útil, uma vez que a ausência no controle das deformações acumuladas pode levar ao surgimento de elevados afundamentos e o progressivo surgimento de trincas (ZHANG *et al.* 2017; BA *et al.*, 2015).

De acordo com Lima *et al.* (2021), considerando os parâmetros adotados no Brasil, foi observado que a redução de 150.000 ciclos para 80.000 não resultou em uma grande divergência nos valores de Afundamento de Trilha de Rodas (ATR) obtidos pelo software nacional MeDiNa. Além disso, os autores sugeriram a programação do equipamento triaxial quando ocorrer o fenômeno de shakedown, quando a taxa de variação da deformação acumulada é muito pequena (cerca de 10^{-7}), a fim de otimizar o procedimento. Por outro lado, ainda não é possível implementar uma técnica, aplicável a diferentes tipos de amostras de solo no país, que viabilize a redução significativa no tempo total do ensaio de forma generalizada, bem como que indique a possibilidade de interrupção nos ensaios.

Para estimar o comportamento da deformação acumulada, alguns autores

desenvolveram modelos constitutivos, dependentes do estado de tensão e do número de ciclos de aplicação de carga (PAUTE *et al.*, 1996; WANG *et al.*, 2009; PUPPALA *et al.*, 2009 e GUIMARÃES, 2009). Porém, pesquisas como a de Guimarães (2009) e Zago *et al.* (2021) sugerem que a caracterização de solos brasileiros por modelos constitutivos para ensaios de estágio único, como Monismith *et al.* (1975) e Barksdale (1972), pode não ser adequada.

Alnedawi *et al.* (2019) ainda compararam a aplicação de Redes Neurais Artificiais a métodos de regressão estatística, modelos constitutivos na previsão da DP em diferentes teores de umidade. Os autores identificaram que o treinamento da previsão da deformação acumulada com base no número de ciclos pelos algoritmos desenvolvidos resultou em melhor ajuste que o emprego de outros 3 modelos constitutivos presentes da literatura. Tais resultados podem elucidar a efetividade do uso de *machine learning* frente aos métodos tradicionais para estimar o comportamento plástico de materiais granulares.

Nesse sentido, este artigo tem por objetivo propor modelos de previsão da evolução da DP de solos, considerando as atuais diretrizes do método de dimensionamento de pavimentos brasileiro MeDiNa, a partir do uso de um número reduzido de ciclos. Esses modelos devem permitir estimar a DP por meio da aplicação sucessiva de ciclos de carga em diferentes situações de carregamento, utilizando um número reduzido de aplicação de carga. O resultado esperado é aproximar o Afundamento de Trilha de Rodas obtido na análise do dimensionamento mecanístico-empírico de pavimentos asfálticos, ao mesmo tempo em que se reduz o tempo e os recursos necessários para realizar o procedimento de caracterização do solo. Essa abordagem pode trazer benefícios significativos para o projeto e a construção de pavimentos, garantindo maior viabilidade em uma abordagem mais eficiente e precisa da deformação dos materiais granulares utilizados.

4.2 Fundamentação teórica

4.2.1 Deformação Permanente

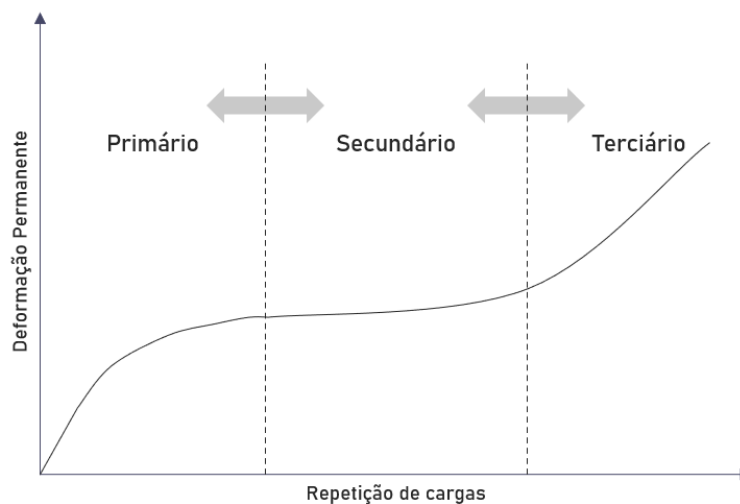
A deformação total (ϵ_{tot}) de materiais sujeitos a carregamentos dinâmicos contínuos em pavimentos é composta por três componentes principais: a deformação resiliente específica ou recuperável (ϵ_r), a deformação permanente específica ou acumulada (ϵ_p) e uma parcela viscoelástica (ϵ_{ve}) associada aos materiais asfálticos. Enquanto a deformação resiliente tende a cessar em materiais geotécnicos, a deformação plástica acumulada resulta em afundamentos irreversíveis na estrutura do pavimento (ZAGO *et al.*, 2021). A Equação 12

descreve a composição da deformação de materiais sujeitos a carregamentos contínuos.

$$\epsilon_{tot} = \epsilon_r + \epsilon_p + \epsilon_{ve} \quad (12)$$

Na Figura 18 ilustra-se as três fases distintas da deformação irreversível observada em um material granular sujeito à aplicação de cargas sucessivas. Essas fases são importantes para compreender o comportamento do material ao longo do tempo e seu potencial de deformação acumulada.

Figura 18 – Estágios do comportamento plástico de solos frente à aplicação de cargas sucessivas



Fonte: Adaptado de Ba *et al.* (2015)

Na fase inicial, que ocorre nas primeiras centenas de ciclos de carga, a deformação do material apresenta uma taxa de crescimento elevada. À medida que os ciclos de carga são aplicados, a taxa de crescimento das deformações tende a diminuir gradualmente. Após a fase inicial, o material entra na segunda fase, que pode durar milhares ou até milhões de ciclos de carga. Nessa etapa, as deformações apresentam taxas de crescimento aproximadamente constantes, quando o material continua sofrendo deformações, mas em uma taxa mais estável e previsível.

A terceira fase é caracterizada por um novo aumento perceptível na taxa de crescimento das deformações, indicando que o material está próximo da falha, quando as deformações aumentam significativamente até atingir um ponto crítico. Devido à complexidade dos modelos matemáticos necessários para descrever completamente o comportamento nessas

três fases, bem como o tempo e os recursos exigidos, as abordagens mecanísticas-empíricas e os modelos constitutivos geralmente consideram apenas as duas primeiras fases na caracterização de materiais geotécnicos (PUPPALA *et al.*, 2009; BA *et al.*, 2015).

Basicamente, a taxa de crescimento da deformação plástica acumulada pode seguir dois comportamentos distintos: (i) aumento contínuo até o rompimento ou (ii) estabilização após um número finito de ciclos de carga. No primeiro caso, se uma carga superior ao limite crítico do solo for aplicada, acontecerá o rompimento do material, seja por fadiga ou por deformações excessivas (GUIMARÃES, 2009; GLUCHOWSKI e SAS, 2020). Entretanto, quando a taxa de crescimento da deformação tende a diminuir consideravelmente ou, se estabilize após um número finito de aplicações de cargas, pode-se dizer que o material chegou ao acomodamento ou *shakedown*, respondendo puramente de forma elástica ao carregamento (COLLINS e BOULBIBANE, 2000).

A abordagem mecanístico-empírica no dimensionamento de pavimentos rodoviários busca desenvolver modelos matemáticos para analisar a relação entre a progressão da deformação e o estado de tensão de materiais granulares utilizados nas camadas do pavimento e no subleito. Distintas normas e diretrizes foram estabelecidas por diferentes órgãos e regiões para caracterizar o comportamento plástico desses materiais por meio da aplicação de cargas dinâmicas. A norma europeia EN 13286-7 (CEN, 2004), por exemplo, propõe procedimentos de estágios múltiplos, nos quais o mesmo corpo de prova é submetido a diferentes pares de tensão consecutivamente. A deformação total é medida após a aplicação de 10.000 ciclos de carga, em pelo menos 3 pares de tensão distintos. Da mesma forma, a norma australiana AG-PT/T053 também sugere um procedimento de estágios múltiplos, com a aplicação de 3 pares de tensão consecutivos, cada um com 10.000 ciclos de carga (ERLINGSSON *et al.*, 2017; ALNEDAWI *et al.*, 2021).

Já a norma brasileira vigente 179/2018 - IE (DNIT, 2018a) baseia-se no modelo constitutivo proposto por Guimarães (2009), demonstrado na Equação 13. Segundo esse autor, o modelo resultou em ajuste adequado às amostras brasileiras de solos finos e pedregulhos estudados, o que também foi observado por (LIMA *et al.*, 2021 e ZAGO *et al.*, 2021). Para a caracterização desses materiais, a norma propõe a realização de ensaios em estágio único (um corpo de prova para cada estado de carregamento), tomando 9 pares de tensão, com 150.000 ciclos de aplicação e 2 Hz de frequência (pode ser utilizada também frequência de 1 até 5 Hz), o que representa um período de ensaio superior ao especificado em outras regiões (Tabela 10).

$$\varepsilon_p = \varphi_1 \left(\frac{\sigma_c}{P_a} \right)^{\varphi_2} \left(\frac{\sigma_d}{P_a} \right)^{\varphi_3} N^{\varphi_4} \quad (13)$$

Onde: ε_p é a deformação permanente específica (%), σ_c é a tensão confinante, σ_d é a tensão desvio, N é o número de ciclos, P_a é a pressão atmosférica e $\varphi_1, \varphi_2, \varphi_3$ e φ_4 são os coeficientes do modelo.

Tabela 10 – Parâmetros de ensaio da DP em diferentes regiões do mundo

Normas	Nº de pares de tensão sugeridos	Nº de ciclos por ensaio	Tipo do ensaio	Execução de um ensaio a 2 Hz (horas)	Caracterização completa a 2 Hz (dias)
EN 13286-7 (Europeia)	Pelo menos 3	10.000	Estágio múltiplo	1,4	1
AG-PT/T053 (Australiana)	Pelo menos 3	10.000	Estágio múltiplo	1,4	1
179/2018 – IE (Brasileira)	9	150.000	Estágio único	21	9

Fonte: elaborado pelo autor (2023)

A possibilidade de aumentar a frequência de aplicação da carga no equipamento triaxial é uma abordagem que pode reduzir o tempo de ensaio. No entanto, essa alteração afeta diretamente as deformações obtidas, havendo uma relação inversamente proporcional entre a frequência e a deformação acumulada (WANG e ZHUANG, 2021; ALNEDAWI *et al.*, 2021; KUMAR *et al.*, 2022). É importante ressaltar que ainda são necessários estudos aprofundados para verificar os impactos do aumento da frequência na obtenção da deformação plástica, levando em consideração as diretrizes propostas para o dimensionamento de pavimentos asfálticos no Brasil.

Ainda, a realização de ensaios em estágios múltiplos permite analisar a deformação plástica diante da variação das tensões atuantes em um único corpo de prova, o que pode economizar tempo e esforço no laboratório. No entanto, é importante considerar que o histórico de tensões influencia diretamente na deformação final obtida. Em outras palavras, a deformação acumulada pode ser menor se a amostra já tiver sido submetida a uma condição de carregamento prévia (RAHMAH e ERLINGSON, 2015; LIMA *et al.*, 2021).

Por fim, o número de ciclos de aplicação de carga é outro parâmetro importante que influencia a análise da progressão da deformação plástica de solos. Embora algumas normas recomendem a aplicação de 10.000 ciclos, é comum observar a estabilização da taxa de deformação após essa faixa. Estudos, como o de Morgan (1966), indicam que em alguns materiais é possível identificar o crescimento da deformação mesmo após milhões de ciclos de

aplicação.

Já Guimarães (2009) observou um aumento significativo na taxa de crescimento das deformações entre 100.000 e 150.000 ciclos em alguns materiais geotécnicos brasileiros, sugerindo essa faixa de valores para a realização de ensaios. Por outro lado, Lima *et al.* (2021) concluíram que os afundamentos obtidos após 80.000 ciclos são semelhantes aos obtidos após 150.000 ciclos, embora as diferenças observadas dependam da acomodação de cada solo, e deixando clara a necessidade de análises criteriosas em cada caso.

Assim, entende-se que a adoção de 150.000 ciclos de aplicação na metodologia brasileira visa aumentar a precisão na previsão das propriedades para o dimensionamento de rodovias. No entanto, é necessário realizar análises adicionais para obter mais informações sobre a influência do intervalo de ciclos de ensaios e os impactos resultantes no dimensionamento mecanístico-empírico brasileiro, a fim de otimizar esse procedimento. Desse modo, será possível otimizar a caracterização dos materiais, resultando em uma alocação mais eficiente de recursos financeiros e reduzindo o tempo necessário para a execução dessas tarefas.

4.2.2 Método MeDiNa de dimensionamento de pavimentos brasileiros

As diretrizes de dimensionamento brasileiras mais atuais propõem o uso do *software* MeDiNa para dimensionamento, análise e reforço de pavimentos asfálticos e semirrígidos. O programa utiliza a teoria da elasticidade, especificamente o método AEMC (Análise Elástica de Múltiplas Camadas) para calcular respostas estruturais das camadas constituintes, verificando se o tráfego previsto irá acarretar trincamento excessivo na superfície do revestimento ou deformações muito elevadas nas camadas da estrutura (DNIT, 2019; KNABEN e CARPIO, 2020 e LIMA, 2020). Para isso, o dimensionamento de pavimentos segundo o método mecanístico-empírico brasileiro requer a inserção de uma série de parâmetros no software, sobretudo quanto às deformações resilientes e permanentes de materiais granulares.

De modo a considerar os principais critérios de avaliação - trincamento por fadiga e Afundamento de Trilhas de Toda (ATR) - deve-se determinar os coeficientes de modelos constitutivos, que descrevem o comportamento do material quanto às deformações elásticas e plásticas pelo estado de tensões e pela progressão da aplicação de cargas. Na caracterização da Deformação Permanente, adota-se o modelo proposto por Guimarães (2009). Ainda, é necessário delimitar a espessura das camadas que constituem a estrutura, pela incidência de tráfego através do Número Equivalente de Eixos Simples Padrão (N) e o período de projeto (da

SILVA e SANTOS, 2021).

A norma 179/2018 – IE (DNIT, 2018a) trata das especificações necessárias para executar os procedimentos de análise da DP de materiais geotécnicos aplicados em camadas do pavimento e do subleito. A partir da inserção dos coeficientes, obtidos pela execução de ensaios de estágio único no equipamento triaxial, o software irá retornar valores de ATR para cada camada da estrutura. Assim, o projetista poderá verificar se o uso de uma amostra é adequado para um determinado projeto. Como padrão, o afundamento total máximo permitido deve variar conforme o tipo da via dimensionada. Tradicionalmente adota-se 12,5 mm como limite admissível de ATR em rodovias brasileiras. Entretanto, esses limites podem variar conforme o tipo de via, sendo 10 mm para vias arteriais principais ou coletoras primárias, e 20 mm para vias arteriais coletoras secundárias e locais.

4.2.3 *Redes Neurais Artificiais*

Recentemente, a solução de problemas em diversas áreas da ciência tem voltado seus esforços no desenvolvimento de ferramentas de *machine learning*. A utilização de métodos estatísticos tradicionais possui uma série de limitações quanto à sua aplicabilidade e pode comumente não resultar em bom ajuste para bases de dados de alta complexidade (Liu *et al.*, 2021). Nesse caso, as Redes Neurais Artificiais (RNAs) vem ganhando popularidade, sobretudo pela variabilidade e efetividade de aplicações distintas, além de possuírem alta capacidade de adequação a funções complexas e de identificação de padrões entre as variáveis de entrada e saída de difícil visualização (BERNARDOS e VONIASKOS, 2007).

Essas ferramentas de *machine learning* tiveram seu desenvolvimento inicialmente baseado em neurônios biológicos, traduzindo comportamentos ou padrões observados na base de dados de entrada, em um processo análogo a uma função matemática (PRIDDY *et al.*, 2005). Sua introdução ocorreu em 1943, com McCulloch e Pitts, que sugeriram o conceito básico de neurônio artificial para simular o complexo processo de ligação entre os neurônios biológicos pela conexão de pesos. Desse modo, um sistema de múltiplos processadores ligados por tais conexões, que por analogia recebem a denominação de neurônios, integram os sinais obtidos e geram uma resposta que pode servir de entrada para outros neurônios (ABRAHAM, 2005; REED e MARSHAL, 1999).

Assim, cada neurônio artificial irá receber e computar informações. Para isso, as informações de entrada x são multiplicadas pelos respectivos pesos w , cujo valor está associado à força de conexão. Então, ocorre a soma dos resultados obtidos em um processo similar a uma

combinação linear (Equação 14). O processamento dos dados irá ocorrer pela implementação de uma função de ativação $y(k)$ (ou transferência), que limita a amplitude e define as saídas do neurônio. As unidades chamadas *bias* são adicionadas a todas as camadas, com exceção da camada de saída (SUZUKI, 2011; DONGARE *et al.*, 2012; RAMCHOUN, 2016 e ARORA, 2015).

$$y(k) = \sum_{i=1}^m (w_i(k)x_i(k)) + bias \quad (14)$$

Dentre as principais funções de ativação utilizadas, a *Rectified Linear Unit (ReLU)*, demonstrada na Equação 15, vem ganhando popularidade em algoritmos de regressão, sobretudo pela velocidade de convergência e de execução (LIN e SHEN 2018, DUBEY e JAIN 2019). Para além disso, a superposição de inúmeras funções de ativação não lineares permite ao *Perceptron* identificar padrões em dados de comportamento fortemente não linear, possibilitado alcançar a solução mais desejável ao problema proposto (GARDNER e DORLING, 1998).

$$f(y(k)) = \max(0, y(k)) \quad (15)$$

O processo pelo qual a rede consegue utilizar informações não identificadas na solução dos problemas propostos quanto à apresentação de um banco de dados é chamado de aprendizado. Pode-se dizer que o aprendizado pode ocorrer de forma supervisionada ou não. O primeiro tipo (supervisionado) se refere ao processamento baseado em uma base de treinamento, quando o ajuste da rede se dá pela relação entre valores observados e calculados. Já o aprendizado não-supervisionado busca identificar padrões sem uma base de treinamento, se adaptando as regularidades observadas, o que é bastante útil para conjuntos sem rótulos (SVOZIL, 1997; REED e MARSHAL, 1999). Para executar esse processo, a rede neural irá buscar minimizar a função de erro, como mostrado na Equação 16 (ARORA, 2015).

$$L(W, B | j) \quad (16)$$

Onde: j refere-se ao exemplo de treinamento; W é o conjunto $\{W_i\}_{1:N-1}$. Para N camadas, W_i é a matriz de pesos ligando as camadas i e $i + 1$; B diz respeito ao conjunto $\{b_i\}_{1:N-1}$, b_i representa o vetor de *bias* em cada camada $i + 1$.

Quando o processamento da rede ocorre de modo unidirecional, das camadas de entrada para a camada de saída, sem haver consideração de nenhum tipo de respostas das saídas para as entradas, tem-se uma rede neural do tipo *feedforward* (SAZLI, 2006). Uma das estruturas mais empregadas na solução de problemas complexos que leva essa abordagem, o *Perceptron* multicamadas, se organiza em camadas contendo diversos neurônios artificiais interligados. Sua arquitetura conta com uma ou mais camadas escondidas entre uma camada de entrada e uma camada de saída (JAIN e MOHIUDDIN, 1996; ABIODUN *et al.*, 2018).

Quanto maior o número de camadas escondidas maior a capacidade da rede em se adaptar à solução de problemas mais complexos, apesar de implicarem em maior custo operacional. Entretanto, na maior parte dos casos, bons resultados são alcançados com 2 ou 3 camadas (KARSOLIYA, 2012). Vale salientar que a otimização do número de neurônios e camadas escondidas é o principal objetivo quanto à obtenção de boa generalização para problemas de regressão e classificação (RAMCHOUN, 2016).

Na busca por obter valores de saída mais próximos aos valores observados da base de treinamento, as redes neurais supervisionadas podem adotar um processo de treinamento denominado *backpropagation*, no qual os pesos entre os neurônios serão continuamente ajustados para minimizar os erros a valores admissíveis. Nesse tipo de RNA, o processo de ajuste ocorre em direção à camada de entrada. Posteriormente, as conexões entre os neurônios são atualizadas em processos contínuos, visando alcançar critérios delimitados (KHAN *et al.*, 2011; WYTHOFF, 1993 e NASR *et al.*, 2012).

4.3 Materiais e métodos

4.3.1 Materiais

A seleção das amostras representativas da região brasileira foi executada com base em mapas pedológicos, buscando localizações próximas a rodovias construídas no estado do Ceará. Foram selecionadas 7 amostras de solo, coletadas em diferentes municípios, visando abordar diferentes classificações da *American Association of State Highway and Transportation Officials* (AASHTO). A caracterização básica das amostras seguiu os ensaios de granulometria, Compactação Proctor na energia intermediária, CBR e limites de consistência. Posteriormente, utilizou-se o equipamento triaxial dinâmico para obter o Módulo de Resiliência (MR) e a Deformação Permanente (DP). Dos 7 solos, 5 foram utilizados para análise de dados e desenvolvimento dos modelos, enquanto 2 solos foram separados para validação de resultados.

Tabela 11 – Caracterização das amostras de solo

Municípios	ID	Class. AASHTO	Limite de Plasticidade	Limite de Liquidez (%)	Umidade Ótima (%)	Dens. Máxima (g/cm ³)	CBR	Objetivo da análise
Aracati	A3	A-3	NP	-	10,0	2,66	22	Desenvolvimento e testes
Baturité	A2-1	A-2-4	NP	-	8,8	2,61	6	Desenvolvimento e testes
Várzea Alegre	A4-1	A-4	NP	-	13,5	2,63		Desenvolvimento e testes
Mombaça	A6	A-6	16	29	11,0	2,64	3	Desenvolvimento e testes
Camocim	A1	A-1-b	NP	-	9,5	2,64	34	Desenvolvimento e testes
Limoeiro	A2-2	A-2-7	29	49	10,0	1,99	5	Validação
Aiuaba	A4-2	A-4	19	26	9,6	2,09	15	Validação

Fonte: elaborado pelo autor (2023)

Os corpos de prova foram preparados na umidade ótima e energia intermediária, em um cilindro tripartido de 100 mm de diâmetro e 200 mm de altura. Conforme a norma brasileira (Tabela 12) para DP, buscou-se realizar 9 pares de tensão, com 150.000 ciclos de aplicação de carga e 2 Hz de frequência, garantindo o descarte dos 50 ciclos iniciais, nos quais se emprega tensão confinante e desvio de 30 kPa. Entretanto, alguns materiais de consistência arenosa (A3 e A1), romperam sob a aplicação dos últimos pares de tensão (120 kPa/240kPa e 120 kPa/360kPa). Ainda, em dois casos os ensaios foram interrompidos por problemas técnicos com o sistema (queda de energia), quando não foi possível chegar aos 150.0000 ciclos. É possível observar na Tabela 12 a quantidade de ensaios de estágio único para cada amostra de solo em relação ao estado de tensão empregado.

Tabela 12 – Configurações de ensaio de DP propostas pela norma DNIT (2018a)

Número de ciclos	Tensão confinante (kPa)	Tensão desvio (kPa)	A3	A2-1	A4-1	A6	A1	A2-2	A4-2
150.000	40	40	X	X	X	X	X	X	X
		80	X	X	X	X	X	X	X
		120	X	X	X	X	X	X	X
	80	80	X	X	X	X	X	X	X
		160	X	X	X	X	X	X	X
		240	X	X	X	X	X	X	X
120	120	X	X	X	X	X	X	X	
	240	Rompeu	X	X	X	X	X	X	
		360	Rompeu	X	X	X	Rompeu	X	

Fonte: elaborado pelo autor (2023)

4.3.2 Organização da base de dados

Para prever o comportamento plástico dos solos e obter os valores de ATR esperados, a metodologia idealizada propõe o desenvolvimento de modelos para cada ensaio de estágio único. Em cada um desses procedimentos laboratoriais, o equipamento triaxial de cargas repetidas registra uma medida de deformação acumulada por intervalos de número de ciclos, em média 88 deformações a cada 150.000 ciclos de aplicação. Para ilustrar a forma como a progressão da deformação plástica acumulada é medida frente às sucessivas aplicações de cargas elaborou-se a Tabela 13. Nessa tabela é possível ilustrar a configuração padrão do banco de dados de um ensaio de estágio único para cada par de tensões aplicado para o caso da amostra A3, para o par de tensões 80x80.

Tabela 13 – Exemplo da configuração de banco de dados para um ensaio de estágio único para o caso da amostra A3 80x80


N	DP (%)	N	DP (%)	N	DP (%)	N	DP (%)	N	DP (%)	N	DP (%)
1	0,0305	200	0,0610	8000	0,0874	23000	0,0951	38000	0,1000	65000	0,1069
2	0,0325	300	0,0650	9000	0,0878	24000	0,0955	39000	0,1000	70000	0,1081
3	0,0341	400	0,0671	10000	0,0890	25000	0,0959	40000	0,1004	80000	0,1106
4	0,0358	500	0,0691	11000	0,0890	26000	0,0959	41000	0,1004	85000	0,1122
5	0,0370	600	0,0707	12000	0,0898	27000	0,0963	43000	0,1012	90000	0,1130
10	0,0386	700	0,0720	13000	0,0906	28000	0,0972	44000	0,1012	95000	0,1146
15	0,0407	800	0,0728	14000	0,0911	30000	0,0976	45000	0,1016	100000	0,1154
20	0,0419	900	0,0736	15000	0,0915	31000	0,0976	46000	0,1016	110000	0,1179
40	0,0463	1000	0,0752	17000	0,0927	32000	0,0980	47000	0,1024	120000	0,1211
50	0,0480	2000	0,0789	18000	0,0927	33000	0,0984	48000	0,1024	130000	0,1232
60	0,0496	4000	0,0833	19000	0,0935	34000	0,0988	49000	0,1024	140000	0,1256
70	0,0508	5000	0,0846	20000	0,0943	35000	0,0988	50000	0,1033	150000	0,1280
90	0,0533	6000	0,0854	21000	0,0943	36000	0,0992	55000	0,1045		
100	0,0545	7000	0,0862	22000	0,0947	37000	0,0996	60000	0,1057		

Fonte: elaborado pelo autor (2023)

Considerando o conjunto total de dados em um ensaio [1, 150.000], buscou-se utilizar como base de treinamento para a rede neural um intervalo inicial dos dados coletados, de 1 até “X” ciclos [1, X], visando ajustar um modelo capaz de prever os valores de deformação para os demais ciclos do ensaio [X, 150.000]. Desse modo, caso os afundamentos obtidos pelo ajuste de modelos constitutivos resultassem em boa aproximação aos valores do ensaio convencional, seria possível concluir que a metodologia, a partir da redução do número de

ciclos, pode ser justificada. Na Figura 19 ilustra-se a composição do banco de dados para um ensaio de estágio único em determinado par de tensões, além da divisão proposta entre parcela de treinamento e os valores desejados para o desenvolvimento dos futuros modelos de previsão.


Figura 19 – Divisão dos dados para um ensaio de estágio único quanto à adoção da metodologia proposta



Fonte: elaborado pelo autor (2023)

Segundo os parâmetros atuais brasileiros, a execução de um único ensaio dura cerca de 21 horas. Desse modo, para definir os intervalos de teste referentes ao número de ciclos iniciais de treinamento, considerou-se a execução de pelo menos dois ensaios por dia, limitando o tempo de um procedimento a 8 horas e duplicando a produtividade potencial. Intervalos superiores a 8 horas ainda resultariam na execução de um único ensaio por dia, o que poderia mitigar o esforço realizado pelo equipamento, mas não representaria qualquer redução no tempo total de procedimentos para uma amostra. Na Figura 20 pode-se observar a comparação entre o número de horas necessária para execução do procedimento pelos intervalos propostos e o ensaio total (150.000 ciclos). Inicialmente, foi delimitada o uso de bases de treinamento compostas para 10.000, 20.000, 30.000, 40.000 e 50.000 ciclos iniciais.

Figura 20 – Duração em ensaio em horas para os intervalos de ciclos propostos



Fonte: elaborado pelo autor (2023)

Também foi programada a retirada de ciclos iniciais das bases de treinamento para conduzir testes adicionais. A princípio, foi observada maior variação na taxa de crescimento da DP na primeira fase do comportamento plástico de solos, seguida por uma tendência à estabilidade no segundo estágio, o que é ocasionado pelo aumento na proximidade entre as partículas (WERKMEISTER, 2003; BA *et al.* 2015). Dessa forma, essa estratégia pode favorecer o ajuste dos modelos gerados, à medida que reduz a complexidade do comportamento dos dados. Além disso, deve-se levar em consideração a execução de ensaios de DP no equipamento triaxial dinâmico se limitar ao segundo estágio (ou estágio secundário), não sendo observada a ocorrência do terceiro estágio ou colapso na maior parte dos estudos (Figura 18). Pela configuração dos dados (Tabela 13) e limitação no número de medidas em cada ensaio, foi proposta a retirada de intervalos inferiores a 1000 ciclos (500 e 1000).

4.3.3 Definição dos parâmetros do modelo

Foi utilizado o *software* de código livre Rstudio na criação de RNAs do tipo *Perceptron* de multicamadas, por meio do pacote h2o (AIELLO *et al.*, 2018). A função de ativação adotada no desenvolvimento dos modelos foi ReLu. Para minimizar os erros obtidos, a biblioteca h2o delimita o uso de uma versão paralelizada do algoritmo *Stochastic Gradient Descent* (SGD). Esse algoritmo propõe a atualização das conexões (pesos) pelo gradiente de uma função de perda, demonstrando maior rapidez, maior confiabilidade e menor probabilidade

de chegar a um mínimo local ruim, em comparação ao método padrão de gradiente descendente (BOTTOU, 1991). Ainda, a biblioteca determina o uso de uma função de perda específica de acordo com o tipo de distribuição abordada. As funções associadas aos algoritmos de regressão podem ser verificadas na Tabela 14, onde $t^{(j)}$ e $o^{(j)}$ referem-se aos valores alcançados e observados, respectivamente. Os demais parâmetros de ajuste foram adotados como padrão da biblioteca.

Tabela 14 – Funções de erro delimitadas para problemas de regressão na biblioteca h2o

Funções	Fórmulas
<i>Mean squared error</i>	$L(W, B j) = \frac{1}{2} \ t^{(j)} + o^{(j)}\ _2^2$
<i>Absolute</i>	$L(W, B j) = \ t^{(j)} + o^{(j)}\ _1$
<i>Huber</i>	$L(W, B j) = \begin{cases} \frac{1}{2} \ t^{(j)} + o^{(j)}\ _2^2 & \text{se } \ t^{(j)} + o^{(j)}\ _1 \geq 1 \\ \ t^{(j)} + o^{(j)}\ _1 - \frac{1}{2} & \end{cases}$

Fonte: elaborada pelo autor (2023)

Para reduzir a probabilidade de ajuste excessivo aos dados, geralmente é proposta a divisão do banco de dados em uma parcela de treinamento e teste. Assim, o desenvolvimento do código foi conduzido com base na segmentação da base entre 70% para treinamento e 30 % para o teste. Como critério de avaliação do desempenho, adotou-se o RMSE, como descrito na Equação 17.

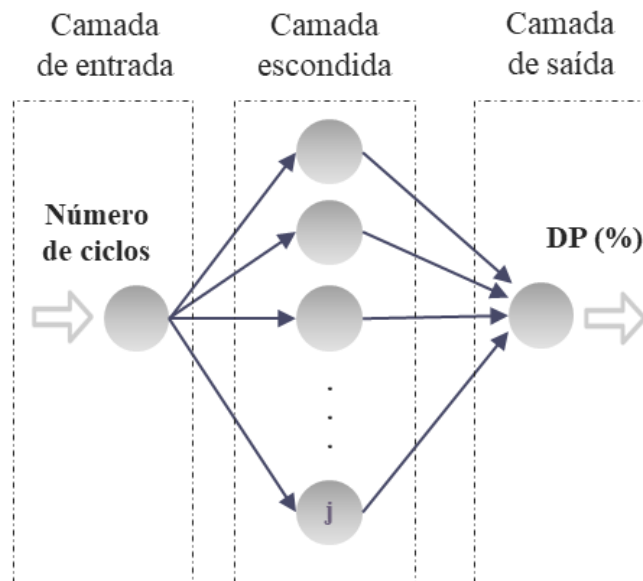
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (17)$$

Onde: y representa os valores observados, \hat{y} os valores previstos, N é o número de observações que variam em i , assumindo valores de 1 até N .

A ideia central da pesquisa foi o desenvolvimento de uma única arquitetura de modelo neural para previsão da deformação permanente acumulada pela progressão do número de ciclos em cada ensaio de estágio único de diferentes materiais. Dessa forma, foram executados testes para identificar a melhor estrutura quanto ao número de camadas escondidas e neurônios. Em seguida, adotando como critério de parada um número fixo de iterações, testes adicionais foram conduzidos para verificar o desempenho das redes pela variação do número

de épocas. Essa abordagem deve proporcionar a generalização de um modelo que possa ser implementado de forma prática e rápida na previsão da DP de solos, sem que seja necessária a seleção inicial de hiperparâmetros em cada execução de ensaios. Na Figura 21 pode-se visualizar uma simplificação da estrutura de rede neural proposta.

Figura 21 – Representação básica da abordagem proposta para arquitetura das redes neurais



Fonte: elaborado pelo autor (2023)

Outra vantagem atrelada ao uso do *software* Rstudio é a praticidade em incorporar os modelos de previsão desenvolvidos à interface de uma aplicação *online*. O pacote responsável por essa tarefa é chamado de *Shiny*. Basicamente, essas aplicações reúnem dois códigos em linguagem R, definindo a aparência e *layout* visível para o usuário, enquanto incorporam instruções e comandos relacionados às entradas requeridas (WOJCIECHOWSKI *et al.*, 2015). Dessa forma, é facilitada a implementação da metodologia proposta, favorecendo a realização de testes e a comunicação com novos usuários.

4.3.4 Testes no MeDiNa

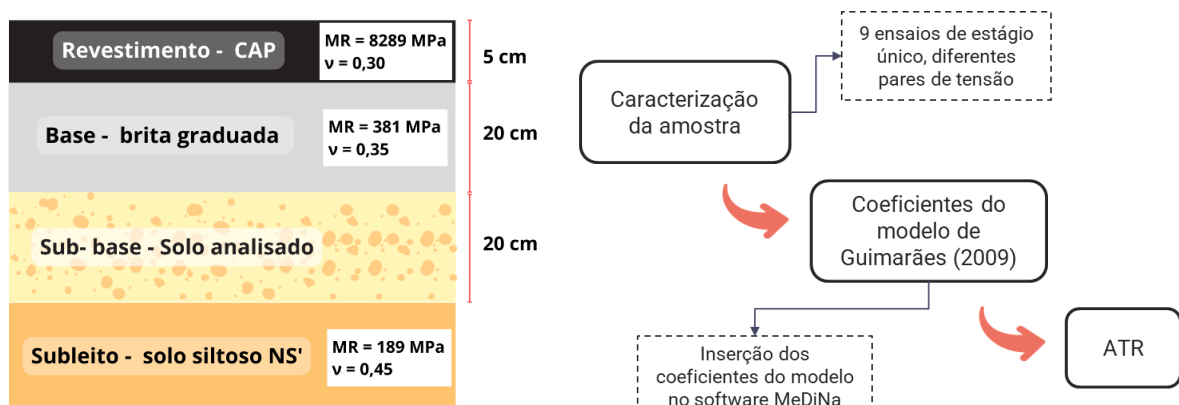
A versão v 1.1.5.0 do *software* MeDiNa foi utilizada para verificar o impacto da implementação da metodologia proposta na obtenção do afundamento de trilha de roda. Após a previsão dos dados em cada ensaio de estágio único, para cada amostra de solo, foram calculados os coeficientes do modelo constitutivo de Guimarães (2009), sendo esses inseridos como parâmetros da DP na interface do programa. A estrutura de pavimento adotada foi executada conforme mostrado na Figura 22 (a), e os valores de referência para comparação do

ATR pelo método convencional foram obtidos pelo processo ilustrado na (Figura 22 - b). Em seguida, o modelo de arquitetura da rede neural selecionado foi aplicado a cada um dos pares de tensão (ensaios de estágio único), variando a base de dados de treinamento nas seguintes condições:

- 1 Controle: Cálculo do ATR considerando apenas a base de dados de treinamento, composta pelos 10.000, 20.000, 30.000 e 40.000 ciclos iniciais de ensaio. A comparação entre esses resultados e o ATR obtido pela metodologia proposta, buscou indicar a relevância frente à previsão da DP pela simples redução no número de ciclos, sem o uso de modelos de previsão;
- 2 RNA1: Utilização da base de dados composta pelos 10.000, 20.000, 30.000 e 40.000 ciclos iniciais na previsão por RNAs das deformações acumuladas até 150.000 ciclos. Nesse caso, o cálculo dos coeficientes do modelo constitutivo utilizou o conjunto formado pela base de treinamento e os valores previstos.
- 3 RNA2: semelhante à abordagem RNA1, mas ignorando os 500 ciclos iniciais em cada ensaio de estágio único apenas no treinamento dos modelos neurais.
- 4 RNA3: semelhante à abordagem RNA2, mas retirando os 1000 ciclos iniciais em cada ensaio de estágio único apenas no treinamento dos modelos neurais.

Referência: Valores de ATR obtidos a partir dos ensaios a 150.000 ciclos de aplicação de carga. Basicamente, são referentes aos afundamentos que o método sugerido buscou atingir.

Figura 22 – Composição da estrutura de pavimento flexível proposta



(a) Estrutura de pavimento proposta

(b) Método para obtenção do ATR no software MeDiNa (DNIT, 2018-a)

Fonte: elaborado pelo autor (2023).

Nas camadas de revestimento, base e subleito, os materiais foram definidos por modelos e materiais pré-existentes no programa. O revestimento asfáltico empregado foi o Concreto Betuminoso Usinado a Quente (CBUQ) RJ CAP 50/70 #12,5mm Sepetiba. Ressalte-se que os materiais testados neste trabalho foram usados para emprego na sub-base da estrutura do pavimento considerado (ver Figura 22a). Na Tabela 15 são descritas com maiores detalhes as principais características dos materiais empregados na seção do pavimento. Por fim, para investigar a influência da variação do nível de tráfego para os valores de ATR obtidos nas situações propostas, foram consideradas 3 configurações de passagens de eixo esperadas - tráfego leve (5×10^5), moderado (5×10^6) e pesado (5×10^7) - ao longo de um período de projeto de 10 anos.

Tabela 15 – Principais resultados dos ensaios de caracterização básica e MR

Revestimento				
MR (Mpa)	Tipo do revestimento	Massa esp. (g/cm ³)	Curva de fadiga	Resistência à Tração MPa
8289	RJ CAP 50/70	2,40	$CF = 3 \times 10^{-13} e_t^{-3,78}$	2,08
Base				
MR (Mpa)	Material	Massa esp. (g/cm ³)	DP – Modelo Guimarães (2009)	Umidade ótima (%)
381	Brita graduada C5	2,21	$0,086 \sigma_3^{-0,208} \sigma_D^{0,893} N^{0,096}$	5,00
Sub-base				
MR (MPa)	Material	DP – Modelo Guimarães (2009)		MR médio
$0,1870 \sigma_3^{0,782} \sigma_D^{0,011}$	A3			233,1
$0,2180 \sigma_3^{0,926} \sigma_D^{0,081}$	A1			199,8
$0,1150 \sigma_3^{0,685} \sigma_D^{-0,071}$	A2-1			191,7
$0,0270 \sigma_3^{0,116} \sigma_D^{-0,307}$	A2-2	Casos de teste seção 4.3.4		230,9
$0,1570 \sigma_3^{0,142} \sigma_D^{-0,306}$	A4-1			212,8
$0,0190 \sigma_3^{0,168} \sigma_D^{-0,289}$	A4-2			385,2
$0,0540 \sigma_3^{0,348} \sigma_D^{-0,473}$	A6			578,8
Subleito				
MR (MPa)	Material	Massa esp. (g/cm ³)	DP – Modelo Guimarães (2009)	Umidade ótima (%)
189	Solo Siltoso NS'	1,80	$0,244 \sigma_3^{-0,419} \sigma_D^{1,306} N^{0,069}$	13,00

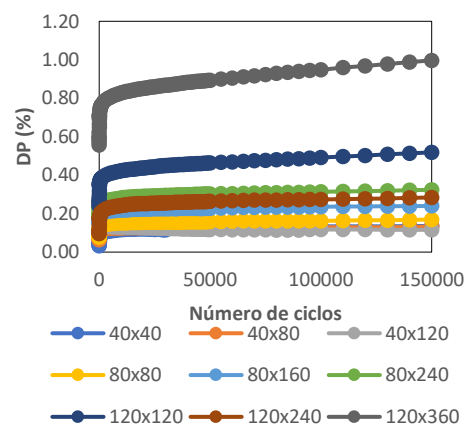





Fonte: elaborada pelo autor (2023)


4.4 Resultados e discussões

4.4.1 Modelo neural

Na Figura 23 são exibidos os gráficos referentes à variação da DP (%) medida em cada ciclo de aplicação de carga, considerando diferentes estados de tensão para as 7 amostras analisadas.

Figura 23 – Resultados para os ensaios de DP realizados nos pares de tensão analisados





(g) A4-2

Fonte: elaborado pelo autor (2023)

O comportamento em relação às deformações acumuladas divergiu conforme o tipo de material analisado, especialmente materiais de caráter arenoso. As amostras A3 e A1 chegaram a DP de aproximadamente 5%, o que equivale a cerca de 10 mm de deformação vertical acumulada no corpo de prova de 200 mm de altura. Caso utilizados em camadas de pavimentos, esses materiais poderiam ocasionar afundamentos elevados, especialmente considerando o rompimento nos últimos estados de tensão aplicados. Cabral (2021) também observou deformações verticais acumuladas de cerca de 7,5 mm em solos do tipo A-3 de uma região adjacente à área de estudo desta pesquisa, mesmo em pares de tensão menos severos. Por outro lado, a amostra A2-1 apresentou DP máxima de 3%, enquanto as demais amostras (A2-2, A4-1, A4-2 e A6) não ultrapassaram 1,2% nos pares de tensão mais severos.

Apesar do solo com menor deformação (A6) também apresentar maior MR médio, os solos arenosos (A3 e A1), que indicam afundamentos elevados, exibiram valores de MR dentro da média, semelhante às demais 7 amostras. Uma relação semelhante foi identificada por Puppala *et al.* (1999) e Venkatesh *et al.* (2020) para solos com teores elevados de finos e misturas de materiais geotécnicos. Por tanto, para o conjunto das amostras analisadas, a avaliação isolada do MR poderia levar à escolha de materiais inadequados para a composição de camadas granulares.

A avaliação do CBR dos materiais também sugere que esse ensaio pode não ser adequado em apontar empregabilidade das amostras, já que solos com maiores deformações (A3 e A1) implicaram em maiores CBR (maior capacidade de suporte). Isso pode acontecer pelo ensaio de CBR não indicar de forma efetiva o estado de tensões sob o qual a amostra estará sujeita, já que o tráfego implica em cargas dinâmicas (simuladas pelo equipamento triaxial no

ensaio de DP). A pressão causada durante o experimento, pode inclusive induzir à formação de deformações permanentes no corpo de prova, levando a certo grau de compactação (ERLINGSON, 2007).

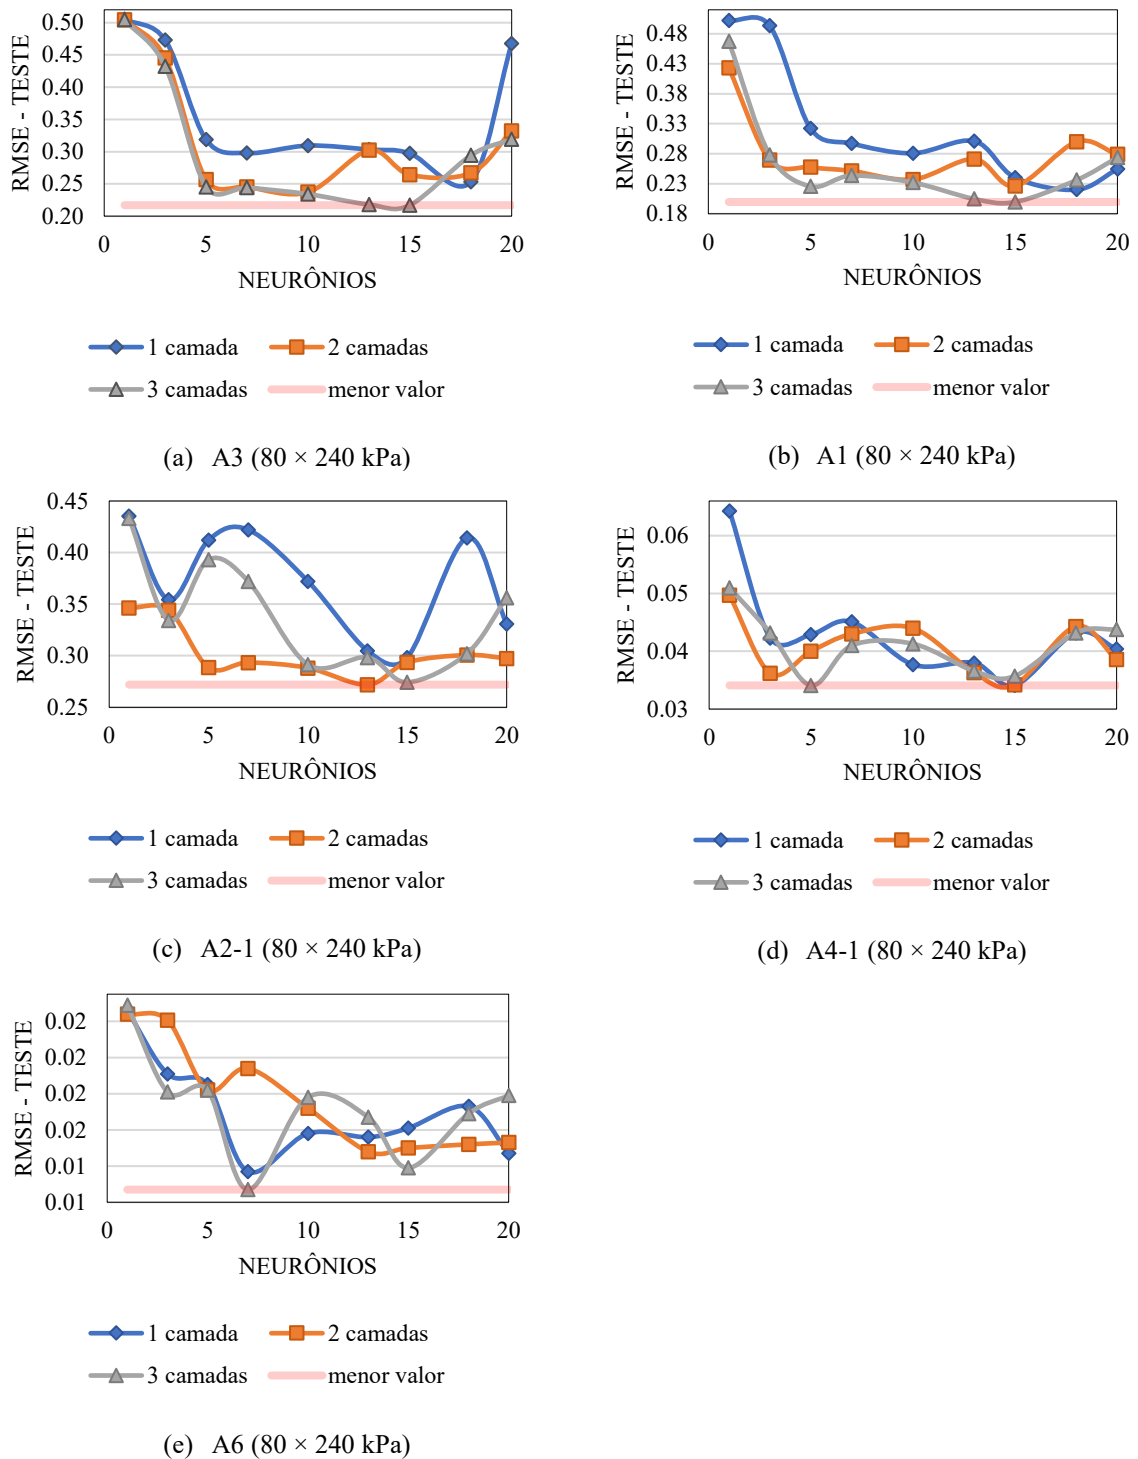
A análise dos ensaios indicou que os materiais tendem a apresentar menor taxa de variação no crescimento da DP acumulada no segundo estágio de seu comportamento plástico. De outro modo, a aplicação de estados de tensões mais elevadas resultou em maiores variações no incremento das deformações medidas. Testes preliminares confirmaram uma relação inversamente proporcional entre o RMSE obtido por modelos neurais e o aumento no estado de tensão aplicado.

Ainda é importante destacar que o desenvolvimento de modelos para todos os ensaios realizados, levando em consideração todos os pares de tensão e amostras, seria um procedimento excessivamente extenso e tornaria a interpretação dos resultados mais confusa. Nesse sentido, o ajuste de um modelo neural teve foco nas condições de carregamento mais severas possível para as amostras analisadas. Assim, para otimizar o ajuste do modelo final, os testes foram voltados aos ensaios referentes ao par de 80 kPa de tensão confinante e 240 kPa de tensão desvio, para cada uma das 5 amostras de solo. Salienta-se que a seleção de 5 entre os 42 ensaios de estágio único na avaliação de arquiteturas de modelos neurais permitiu otimizar os esforços na delimitação de um algoritmo adequado.

Nos gráficos mostrados na Figura 24 foi demonstrada a variação do RMSE quanto às arquiteturas propostas para as bases de teste (30% dos dados dos ensaios a 80 kPa \times 240 kPa) das 5 amostras de solo. Na tentativa de definir uma configuração que proporcionasse o melhor ajuste possível, foi construída uma linha horizontal, referente aos menores valores de erro obtidos. A avaliação da Figura 24 permitiu apontar que a adoção de 3 camadas ocultas promoveu menores valores de erro dentro do intervalo de análise, confirmando a necessidade da abordagem de *deep learning* na solução do problema proposto.

Apesar de nem sempre o valor mínimo dos erros corresponder a 15 neurônios, os resultados obtidos para esse ponto são próximos ao melhor desempenho alcançado, o que deve justificar a adoção dessa quantidade para priorizar a otimização das previsões de dados referentes às amostras arenosas (A3 e A1) que apresentam maiores deformações. A arquitetura sugerida para execução da metodologia de previsão da DP foi composta, então, por 3 camadas escondidas e 15 neurônios.

Figura 24 – Variação do RMSE pelo número de neurônios para as 5 amostras de solo, considerando 3 camadas escondidas

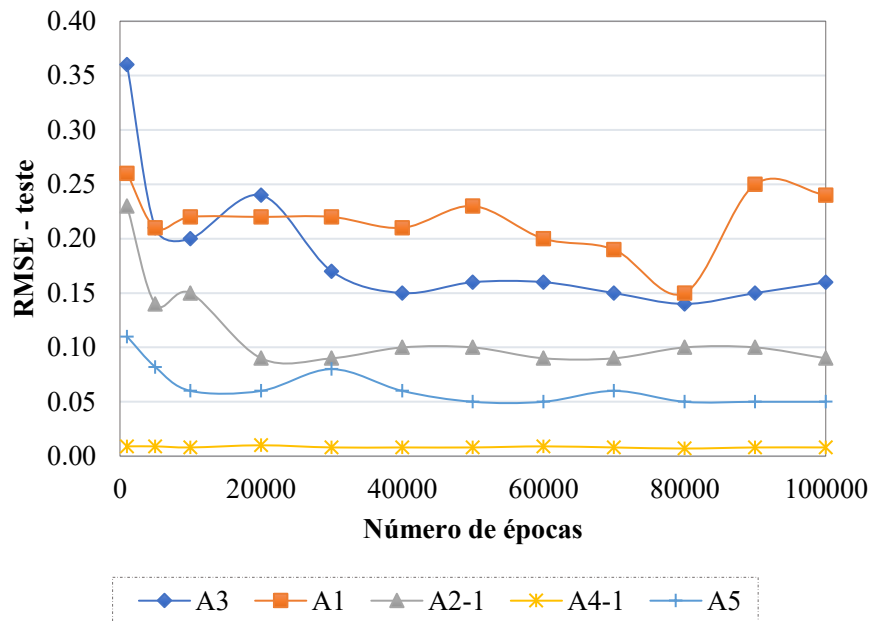


Fonte: elaborado pelo autor (2023)

Determinada a arquitetura com melhores resultados de forma generalizada, buscou-se definir um critério de parada das iterações quanto a um número fixo de épocas. Para isso, novos testes sequenciais foram executados para as 5 amostras no par de tensão 80 kPa × 240 kPa. Na Figura 25 podem ser identificados gráficos que mostram a variação do RMSE da base

de dados de treinamento pelo número de épocas para cada solo.

Figura 25 – Variação RMSE pela progressão do número de épocas para as 5 amostras de solo, considerando a melhor arquitetura identificada (15 neurônios em 3 camadas escondidas)




Fonte: elaborado pelo autor (2023)

As amostras de A3, A1 e A6 indicaram que o ponto de inflexão, com menor valor de erro, estaria em 80.000 épocas. Para além disso, a seleção desse número de iterações não afetaria o resultado das demais amostras, já que os valores foram próximos ou iguais aos menores erros obtidos. É notável que os erros observados para as amostras arenosas são superiores aos referentes aos demais materiais, especialmente em comparação ao solo A4-1. Dessa maneira, é importante destacar que a definição da arquitetura teve foco no melhor resultado obtido para as amostras A3 e A1.

Foi construído o gráfico ilustrado na Figura 26 para expor a relação entre os valores de DP observados e previstos para as bases de teste, referentes aos ensaios nos 5 solos analisados. De forma preliminar, os modelos demonstraram bom ajuste (coeficientes de correlação R^2 superiores a 0,80). Entretanto, tornou-se evidente que os modelos tem pior ajuste na previsão das deformações referentes aos ciclos iniciais. Para tanto, esses resultados fortalecem a hipótese de que a retirada de uma parte inicial desses dados pode impulsionar o desempenho alcançado.

Figura 26 – Valores observados pelos valores previstos nas bases de teste dos ensaios de estágio único a 80 kPa × 240 kPa



Fonte: elaborado pelo autor (2023)


4.4.2 Avaliação dos valores de ATR obtidos

Como descrito na seção anterior, foi proposta uma rede neural com 3 camadas ocultas e 15 neurônios na previsão do comportamento plástico para cada ensaio de estágio único, tomando como critério 80.000 épocas. O modelo neural foi implementado utilizando como base de treinamento as condições propostas na seção 4.3.4 (Controle, RNA1, RNA2 e RNA3). Entretanto, não foi abordada a retirada de 1000 ciclos iniciais para a base de 10.000 ciclos, já que isso restringiria o banco de dados de teste a uma amostra muito limitada de medições. Após cerca de 630 testes realizados, os coeficientes do modelo constitutivo da DP dos solos foram aplicados ao *software* de dimensionamento MeDiNa para obter os afundamentos nas condições de tráfego leve (5×10^5), moderado (5×10^6) e elevado (5×10^7).

As Figuras 27, 28, 29, 30 e 31 mostram em gráficos de barra verticais os resultados de ATR obtidos para os solos A3, A1, A2-1, A4-1 e A6, respectivamente, testados para camada de sub-base quanto à cada condição de teste descrita na seção 3.3: (1) utilizando a base de treinamento (10.000, 20.000, 30.000 e 40.000) na obtenção dos coeficientes dos modelos constitutivos (Controle); (2) utilização dos dados previstos por rede neural no complemento aos valores das bases de treinamento implementadas (RNA1); (3) ajuste da rede neural com a retirada de dos 500 ciclos iniciais (RNA2) e (4) ajuste da rede neural com a retirada dos 1000 ciclos iniciais (RNA3). Como critério de comparação para definir a acurácia dos resultados, as


linhas horizontais tracejadas demonstram os valores de ATR de referência, associada à aplicação convencional de 150.000 ciclos sugerida na norma brasileira.

Figura 27 – ATR obtido para cada condição de teste – solo A3




Fonte: elaborado pelo autor (2023)

Figura 28 – ATR obtido para cada condição de teste – solo A1




Fonte: elaborado pelo autor (2023)

Figura 29 – ATR obtido para cada condição de teste – solo A2-1




Fonte: elaborado pelo autor (2023)

Figura 30 – ATR obtido para cada condição de teste – solo A4-1



Fonte: elaborado pelo autor (2023)

Figura 31 – ATR obtido para cada condição de teste – solo A6



Fonte: elaborado pelo autor (2023)

A análise dos testes mostrou que os solos arenosos A3 e A1 apresentaram afundamentos superiores a 10 mm em condições de tráfego severo, ultrapassando o limite de ATR sugerido para a camada de sub-base em toda a estrutura. Portanto, foram conduzidos testes preliminares com 10.000, 20.000, 30.000 e 40.000 ciclos nessas duas amostras. Observou-se que a diferença entre o ATR de referência e os resultados dos testes diminuiu até 30.000 ciclos, sem melhorias significativas nas previsões em 40.000 ciclos. Com base nisso, concluiu-se que não havia necessidade de estender os testes além de 30.000 ciclos para as amostras de A2-1, A4-1 e A6, uma vez que foram observados erros muito menores nessas amostras. Para os solos de A4-1 e A6, obter os coeficientes apenas com a base de treinamento (1) de 30.000 ciclos resultaria em diferenças mínimas em relação aos valores de ATR de referência.

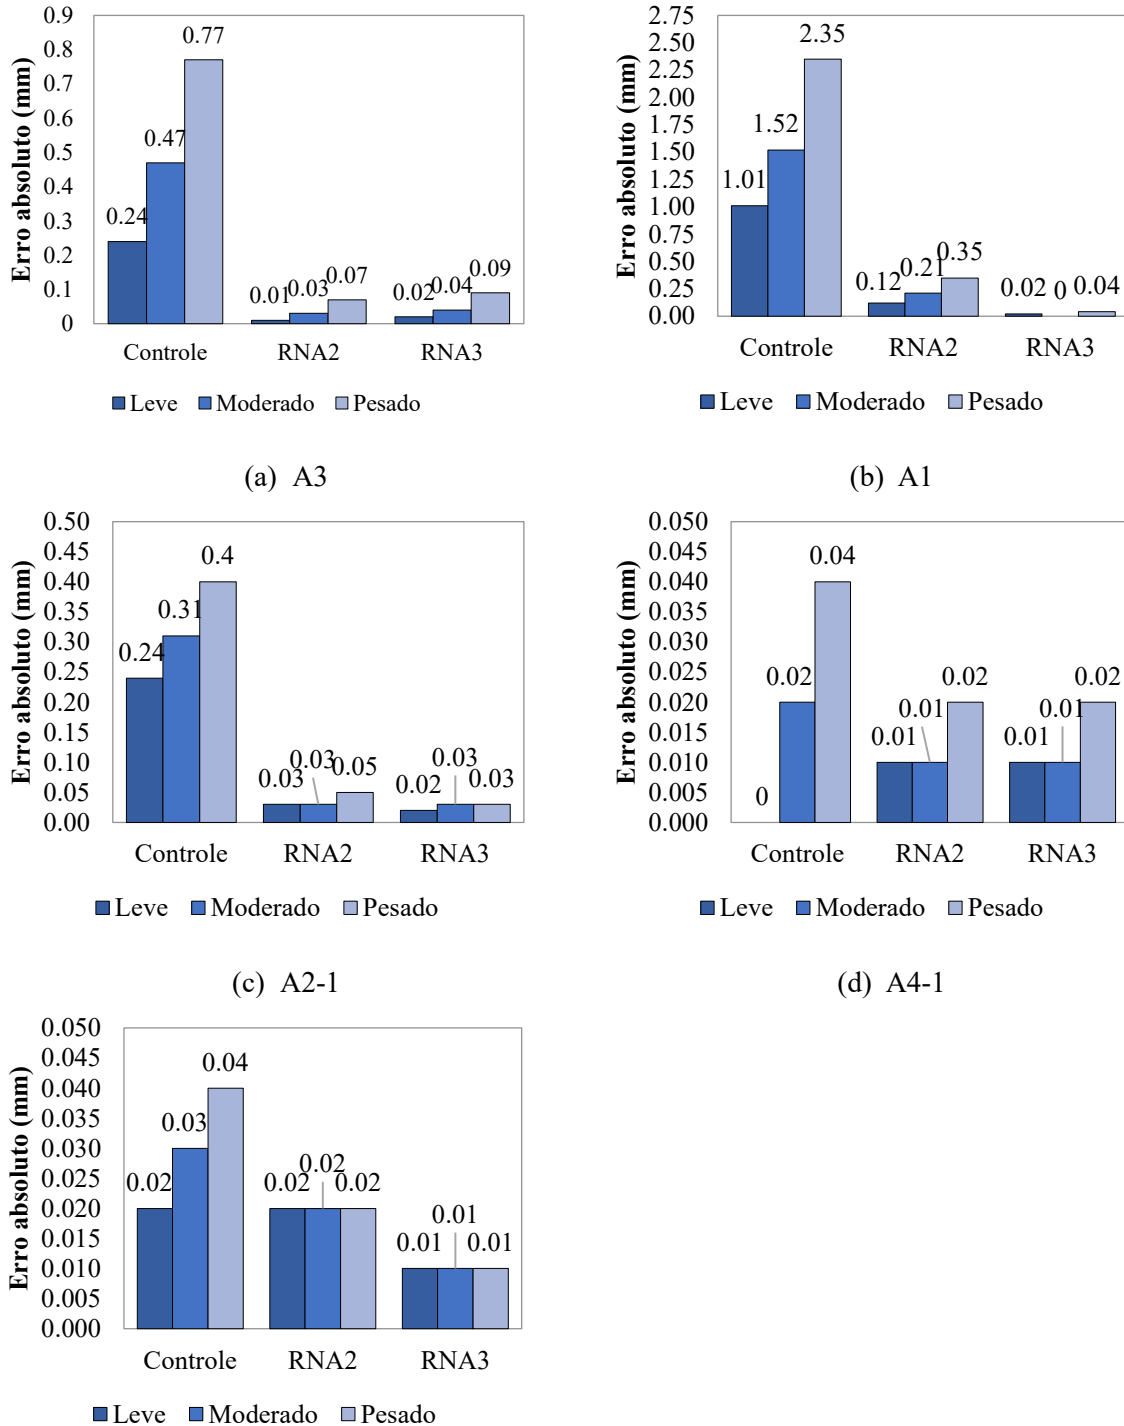
A utilização de redes neurais na estratégia RNA1 superestimou os valores de ATR na maior parte dos casos, não sendo viável mesmo em comparação ao ATR pela simples redução do número de ciclos (Controle). Entretanto, a retirada dos 500 (RNA2) e 1000 (RNA3) ciclos iniciais mostrou-se uma abordagem muito efetiva em otimizar a previsão dos afundamentos. Portanto, é justificada a hipótese de que houve maior capacidade da rede neural em se adequar a um conjunto de dados com taxas de crescimento de deformação com menor variação, especialmente quando se desconsidera a fase inicial do ensaio.

A partir de 20.000 ciclos como base de dados, a retirada de 500 e 1000 ciclos iniciais proporcionou uma boa aproximação aos afundamentos obtidos pelo ensaio completo para os solos areno-siltosos, siltosos e argilosos com menor deformação. No entanto, 30.000 ciclos proporcionaram o melhor nível de previsão para as 5 amostras analisadas em conjunto, incluindo os solos arenosos com maiores afundamentos nas condições de tráfego estabelecidas. Portanto, adotar a metodologia proposta com 30.000 ciclos permitiria economizar cerca de 5 vezes o tempo de ensaio para cada ensaio de estágio único por par de tensão, de 21 horas para 4,2 horas. Como resultado, a caracterização de cada amostra de solo poderia ser reduzida em pelo menos 50% em relação ao tempo de procedimento vigente, já que iria favorecer a execução de pelo menos dois ensaios por dia.

Para exibir os resultados de afundamento obtidos após a retirada de 500 (RNA2) e 1000 (RN3) ciclos de forma mais clara, tomando a base de treinamento de 30.000 ciclos, foram construídos os gráficos exibidos na Figura 32. Basicamente, as barras verticais representam o erro absoluto do ATR obtido em relação ao ATR de referência com 150.000 ciclos de ensaio pelo método convencional. Os gráficos também exibem o erro absoluto entre o afundamento obtido pelo cálculo dos coeficientes apenas pelos 30.000 ciclos iniciais (Controle), de modo a investigar a relevância da metodologia empregada frente à simples interrupção do ensaio nesse

ponto.

Figura 32 – Erro absoluto de ATR entre os testes realizados e os valores de ensaio a 150.000



(e) A6

Fonte: elaborado pelo autor (2023)

Ambas as abordagens (RNA2 e RNA3) sugerem ótima aproximação e efetividade da metodologia proposta. Entretanto, as amostras A1, A2-1 e A6 indicam maior aplicabilidade

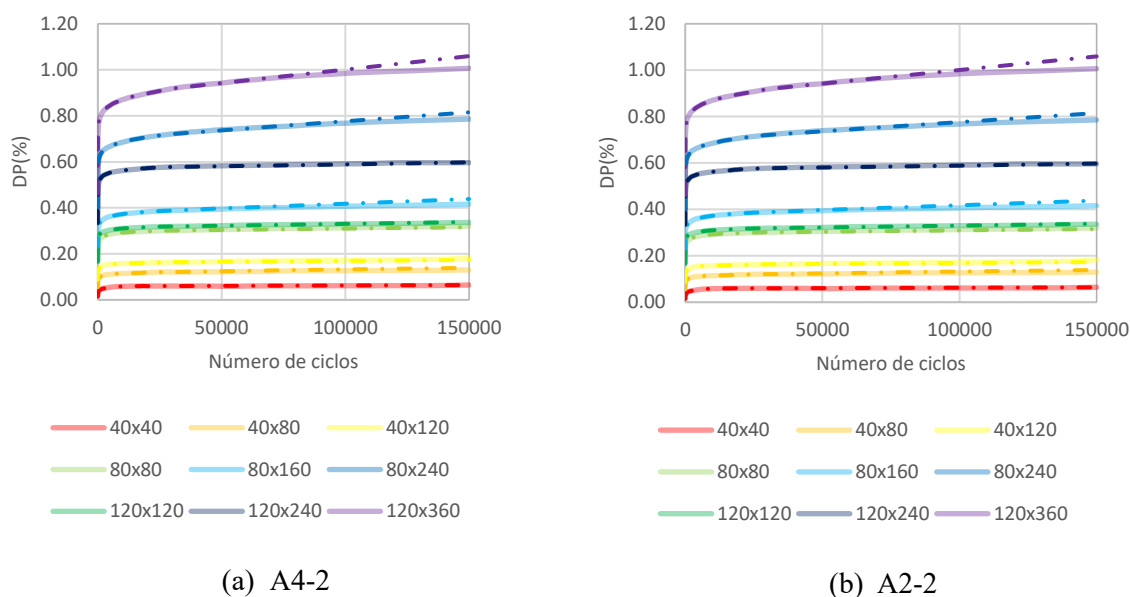
da retirada dos 1.000 ciclos iniciais, sobretudo para tráfego severo. Mesmo para o solo arenoso com maiores deformações (Camocim), a estratégia resultou em erros absolutos inferiores a 0,04 mm com tráfego pesado, o que representa cerca de 0,8% do ATR total obtido. Nos demais casos, foram observados valores inferiores a 0,09 mm de ATR, o que indica excelente aproximação frente à execução de ensaio a 150.000 ciclos no equipamento triaxial.

Para solos como A6 e A4-1 e A2-1, cujos menores afundamentos foram identificados, mesmo a utilização dos 30.000 ciclos iniciais na obtenção dos coeficientes do modelo de Guimarães (2009) resultou em erros iguais ou inferiores a 0,4 mm. Entretanto, de modo sugerir a melhor forma de abranger materiais com comportamentos distintos e obter valores de afundamento suficientemente próximos aos valores de referência, a análise dos erros absolutos denota que o modelo de rede neural após a retirada dos 1.000 ciclos iniciais representa a melhor alternativa frente às sugestões propostas.

Finalmente, a arquitetura de RNA definida por este estudo foi adaptada por meio do software Rstudio para um aplicativo online na plataforma Shiny. Dois novos solos foram utilizados para verificar a aplicabilidade do método em questão, sendo obtidas as deformações previstas e de ensaio, como verifica-se na Figura 33. Dessa forma, foram utilizados 30.000 ciclos de ensaios, retirando os 1000 ciclos iniciais, para estimar as deformações verticais acumuladas em cada ensaio de estágio único e tensões correspondentes. As previsões realizadas garantiram deformações finais a 150.000 (linhas tracejadas) muito próximas às obtidas pelo procedimento em laboratório (linhas contínuas), que demanda muito mais tempo. Além disso, é possível antecipar com exatidão o formato do comportamento dos ensaios de estágio único.

Entretanto, durante a execução das previsões em ensaios com deformações menores, foram observados pontos inconsistentes (nos quais a taxa de deformação é decrescente, comportamento contrário ao esperado) que podem prejudicar o desempenho do método. Nesses casos, o algoritmo pode retornar deformação que diminuem ao longo dos ciclos. Para tanto, recomenda-se o tratamento desses pontos, com o objetivo de garantir os melhores resultados.

Figura 33 – Comparação entre os valores previstos e ensaiados de DP para duas amostras de solo separadas para validação



4.4.3 Sugestão de aplicação da metodologia abordada na redução do tempo de procedimento nas parametrizações brasileiras 179/2018 - IE (DNIT, 2018a)

Tomando a precisão obtida em relação ao cálculo do ATR pela metodologia empregada, é possível delimitar de forma esquemática os principais passos para sua execução na caracterização de solos quanto à DP:

- 1 Execução de ensaios de estágio único no equipamento triaxial dinâmico, adotando uma frequência de 2 Hz e 30.000 ciclos de aplicação de carga para cada par de tensões programados;
- 2 Utilizar os dados obtidos (progressão da DP por número de ciclos) na previsão da deformação acumulada até 150.000 ciclos, seguindo os intervalos de medição adotados neste estudo (Tabela 13) e retirando os 1.000 ciclos iniciais. O modelo de RNAs adotado deve seguir a arquitetura delimitada (3 camadas escondidas, 15 neurônios em cada camada e 80.000 épocas).
- 3 Calcular os coeficientes do modelo constitutivo de Guimarães (2009) pelo conjunto de ensaios de estágio único executados. Os dados de cada ensaio devem agrupar os 30.000 ciclos de ensaios e os demais ciclos previstos.
- 4 Inserir os coeficientes no software MeDiNa para analisar o ATR nas condições esperadas de projeto (estrutura, tráfego e período estimado).

O processo descrito pode ser facilitado pelo uso de aplicações online também desenvolvidos neste trabalho, como a plataforma Shiny que permite automatizar o procedimento quando integrada ao Rstudio.

4.5 Conclusões

Este capítulo teve como objetivo propor uma metodologia para reduzir o tempo de ensaio referente ao procedimento de obtenção da DP de materiais granulares para uso em pavimentação, adotando as especificações brasileiras. Para isso, foram analisadas 5 amostras de solos de comportamentos distintos quanto à classificação AASHTO, cuja coleta embasou-se em dados pedológicos para maior representatividade dos solos do estado do Ceará. Sendo assim, podem-se tecer as seguintes considerações à luz dos testes realizados neste trabalho:

- a) inicialmente, buscou-se propor uma única arquitetura de RNA na previsão do comportamento plástico dos ensaios de estágio único em diferentes estados de tensão, aplicando a metodologia em amostras de solos com propriedades distintas. Foi possível otimizar a seleção da arquitetura ótima a partir da seleção de um ensaio de estágio único para cada tipo de solo, tomando um par de tensões mais severo 80×240 kPa entre os sugeridos nas parametrizações adotadas. Enfatiza-se que o emprego de *deep learning*, com arquitetura formada por três camadas escondidas e 15 neurônios, foi a mais adequada na previsão da DP de solos.
- b) a análise da deformação acumulada dos solos argilosos e siltosos-argilosos indica que a simples interrupção do ensaio com 30.000 ciclos já possibilitaria alcançar valores de ATR semelhantes aos valores dos ensaios convencionais. Entretanto, as amostras arenosas demonstraram maior suscetibilidade ao acúmulo de deformação frente à aplicação de cargas, apresentando DP superiores a 10 mm. Para esses solos, a interrupção prévia dos ensaios sem o uso da metodologia proposta pode gerar valores de ATR até 2 mm superiores aos calculados pelas parametrizações com 150.000 ciclos.
- c) a aplicação de redes neurais na previsão da deformação acumulada, e a posterior previsão dos coeficientes de modelos constitutivos, resultou em valores de ATR superiores aos valores de referência (ensaio convencional pelas normas adotadas). Entretanto, a retirada de ciclos iniciais no treinamento da rede possibilitou alcançar afundamentos próximos ao esperado, obtendo-se

melhores resultados pela retirada dos primeiros 1.000 ciclos nesse processo. Desse modo, pelos pequenos erros observados, destaca-se a efetividade do método sugerido na proposição de uma única arquitetura na obtenção da deformação plástica em ensaios de estágio único. Conseqüentemente, a utilização da metodologia abordada mostra-se aplicável na solução do problema proposto, especialmente por possibilitar métodos de implementação prática, em um software de código livre.

- d) por fim, as respostas dos modelos neurais desenvolvidos indicaram que é possível chegar a uma boa aproximação dos valores de ATR para todas os materiais geotécnicos aqui testados, a partir de 30.000 ciclos de aplicação de carga, mesmo em tráfego pesado. O maior erro alcançado, referente à amostra de A3, foi de 0,09 mm na situação de tráfego mais severa.

As implicações da utilização da metodologia aqui proposta resultariam em economia significativa na caracterização de amostras de solo quanto à DP. Estima-se que seriam poupados pelo menos 4 dias de trabalho contínuo no equipamento triaxial para 1 amostra de solo. Diante do exposto, este artigo demonstrou a viabilidade na redução do tempo total de ensaio da DP com relação aos parâmetros das normas brasileiras, aplicando modelos de *machine learning* na previsão do comportamento plástico em ensaios de estágio único. À medida que permite a realização de pelo menos duas amostras por dia, estima-se que possa ocorrer a redução de até 50% na caracterização de amostras.

Portanto, as contribuições dispostas neste estudo podem garantir maior praticidade e auxiliar a caracterização de solos quanto à sua DP, poupando o investimento de recursos humanos e financeiros, além de reduzir prazos em obras rodoviárias. Espera-se que essa abordagem favoreça a implementação do novo método de dimensionamento mecanístico-empírico no país, garantindo maior durabilidade e precisão no projeto e construção de pavimentos asfálticos e semirrígidos.

5 IDENTIFICAÇÃO DE NOVOS CRITÉRIOS DE PARADA PARA ENSAIOS DE DEFORMAÇÃO PERMANENTE DE MATERIAIS GRANULARES

Resumo

Na caracterização da deformação plástica de materiais granulares para uso em pavimentação, é possível identificar diferentes comportamentos ao longo da aplicação de cargas no equipamento triaxial. Alguns solos, em determinados pares de tensão, podem chegar a taxas de variação das deformações acumuladas tão pequenas que é possível determinar que ocorreu um acomodamento. Para esse tipo de situação, não se faz necessária a aplicação de milhares de ciclos de carga, como sugere a metodologia brasileira para análise da Deformação Permanente (DP). Nesse sentido, identificar tal comportamento de forma preliminar traria economia de tempo e recursos nas obras de pavimentação. No entanto, os critérios disponíveis na literatura são baseados em propriedades de um número limitado de amostras, o que pode não ser suficiente para uma generalização dos resultados de DP para uso em projetos rodoviários. Assim, o objetivo deste trabalho é analisar a aplicabilidade desses critérios em solos de uma região amostral e identificar o efeito da interrupção prévia em ensaios de estágio único de DP, caso verificado o acomodamento, avaliando o impacto dessa abordagem no dimensionamento de pavimentos sob a perspectiva brasileira. Para isso, foram analisados os resultados de DP para 7 solos distintos, aplicando 9 pares de tensão e 150.000 ciclos de carga a uma frequência de 2 Hz. Foram propostos alguns intervalos de ciclos, muito inferiores a 150.000, para os ensaios classificados como Tipo A (acomodamento plástico), verificando os valores de ATR por meio do software MeDiNa. Os critérios de classificação foram estabelecidos usando algoritmos de Árvores de Decisão para classificação, com base em valores da taxa de deformação vertical acumulada em diferentes intervalos anteriores a 10.000 ciclos. Os resultados demonstraram que o algoritmo foi capaz de prever com precisão os ensaios do Tipo A, não sendo observados falsos positivos das demais classes em relação ao acomodamento plástico, o que indica a aplicabilidade da metodologia proposta. Por fim, a análise do impacto da redução do número de ciclos mostrou que é possível interromper o procedimento após cerca de 30.000 ciclos para ensaios na faixa A, com erros de aproximadamente 0,1 mm de ATR em tráfego pesado, para solos com deformação total acumulada inferior a 2 mm. Portanto, a aplicação conjunta dos métodos aqui testados pode proporcionar economia significativa, bem como otimizar o dimensionamento e construção de pavimentos rodoviários.

Palavras chave: Teoria de Shakedown, Pavimentos asfálticos, Materiais Granulares, Árvores de Decisão

5.1 Introdução

Dentre os dois principais defeitos que afetam a vida útil de pavimentos asfálticos podem-se destacar os afundamentos nas camadas constituintes e o surgimento progressivo de trincas por fadiga. Para tanto, a estrutura deve ser dimensionada a partir da seleção criteriosa de materiais e dimensões específicas para prevenir a deterioração prematura por esses processos (WERKMEISTER, 2003). Em particular, afundamentos elevados podem limitar e prejudicar o desempenho funcional e estrutural de rodovias. Ressalta-se que a maior parte do afundamento

ocorre nas camadas granulares (sendo o subleito responsável por cerca de 40% do total), o que destaca a relevância da análise da deformação plástica acumulada ao longo da aplicação de cargas dinâmicas do tráfego (PUPPALA *et al.*, 1999).

Para compreender o comportamento plástico dos solos, são realizados testes laboratoriais extensivos, a fim de simular as condições de carga e ambientais encontradas no campo, como compactação e umidade. O equipamento mais utilizado para essa finalidade é o Triaxial de Cargas Repetidas (*Repeated Load Triaxial* - RLT) que registra a evolução da Deformação Permanente (DP) acumulada durante a progressão dos ciclos de aplicação de cargas em diferentes estados de tensão. A partir dos dados obtidos, é possível ajustar modelos estatísticos constitutivos que, em conjunto com softwares de dimensionamento, permitem determinar o afundamento esperado para um determinado nível de tráfego e características da estrutura (SALOUR e ERLINGSSON, 2017).

Wermeister (2003) propôs critérios para classificar preliminarmente o tipo de acomodamento atingido em cada ensaio com base na taxa de crescimento da DP. O uso de materiais com taxas de crescimento elevadas da deformação acumulada, classificados como Tipo C (WERKMEISTER *et al.*, 2001), deve ser evitado para a construção de pavimentos duráveis. Por outro lado, a taxa de deformação de alguns solos tende a decrescer significativamente, indicando que o material acomodou (Tipo A), quando a variação nas medidas se torna muito pequena. Nesses casos, a adoção de critérios preliminares permitiria a interrupção do procedimento em determinado ponto, resultando em economia na execução de procedimentos.

Essa abordagem é particularmente interessante para a redução de custos e tempo de procedimento, já que os ensaios de caracterização da DP de solos propostos na abordagem de dimensionamento de pavimentos asfálticos brasileira são bastante onerosos e demorados, envolvendo ensaios de estágio único com 150.000 ciclos de aplicação de carga, que podem durar cerca de 9 dias para uma frequência de 2 Hz. O custo elevado de aquisição e manutenção do equipamento triaxial do é outro fator que contribui para a necessidade de buscar alternativas mais econômicas para a determinação da DP de solos.

Entretanto, os critérios de classificação do tipo de acomodamento ou *shakedown* estabelecidos por Wermeister (2003) são limitados em abrangência e adequados apenas para um grupo específico de materiais, o que os torna possivelmente inadequados para outras regiões com características diferentes. Como resposta, Gu *et al.* (2017), Alnedawi *et al.* (2019) e Wang e Zhuang (2021) desenvolveram novos critérios de classificação para o *shakedown*, com o objetivo de ajustar a classificação para o grupo de amostras analisadas. Adicionalmente, sob as

parametrizações brasileiras, esses limites podem desconsiderar deformações iniciais significativas em alguns solos ou classificar ensaios de maneira excessivamente rigorosa, resultando em solos do tipo A sendo classificados como tipo B e como tipo C (LIMA, 2020).

Para estabelecer novos limites de classificação do shakedown, é necessário realizar uma análise criteriosa da distribuição de cada tipo de solo e como as classes se relacionam com faixas de variação da DP. Essa tarefa pode ser ainda mais complexa quando se considera a presença de solos de comportamento intermediário AB. Nesse contexto, ferramentas computacionais como as Árvores de Decisão (AD) podem trazer praticidade e efetividade no processo de classificação, permitindo o particionamento de um amplo conjunto de dados em grupos menores e mais homogêneos em relação à uma variável alvo. Além disso, as regras geradas por essas árvores são facilmente compreensíveis, o que tem contribuído para sua difusão na solução de diversos problemas de classificação e regressão (CHO *et al.*, 2010).

Com base nesses aspectos, o estudo aqui desenvolvido propõe a análise de estratégias de otimização do procedimento de determinação da DP, com destaque para a interrupção prévia daqueles ensaios que chegam ao acomodamento plástico. Além disso, serão realizadas análises referentes aos padrões brasileiros para identificar os limites da classificação de shakedown mais adequados às características dos solos coletados no Estado do Ceará. Espera-se que os resultados aqui obtidos possam contribuir para o aprimoramento da caracterização de materiais geotécnicos em relação à DP, possibilitando a redução de custos e de tempo necessários para a realização dos ensaios, tornando o processo de dimensionamento de rodovias mais eficiente e econômico.

5.2 Referencial teórico


5.2.1 Análise da deformação permanente

Diversos modelos matemáticos têm sido propostos para descrever a evolução da deformação permanente (DP) dos solos sob ação de carregamentos dinâmicos. Geralmente, esses modelos se baseiam em relações por logaritmos ou funções hiperbólicas (WERKMEISTER *et al.*, 2005). Em uma fase inicial, observa-se um crescimento rápido da deformação acumulada, que é conhecida como pós-compactação. Nesse ponto, a variação nas deformações observadas será apenas resiliente, ou seja, o material entrou em shakedown. Essa fase é seguida pelo acomodamento dos grãos, quando ocorrerá a redução no volume de poros, redução volumétrica e densificação. Em seguida, a deformação acumulada deve atingir um

valor assintótico em relação a um número crescente de ciclos de aplicação, cuja taxa de crescimento é aproximadamente constante, e o aumento na deformação plástica se dá apenas por variações volumétricas.

No entanto, em estados de tensões mais severas, as deformações plásticas podem crescer, levando à falha devido às deformações cisalhantes (EL-BASYOUNY *et al.*, 2005; WERKMEISTER *et al.*, 2005; RAHMAN e ERLINGSSON, 2015). Pela teoria do shakedown os solos podem ser classificados quanto à forma como a deformação plástica ocorre perante à aplicação de ciclos de carga no RLT, considerando um determinado estado de tensões atuantes. As classificações A, B e C foram propostas por Werkmeister *et al.* (2001), enquanto Guimarães (2009) sugere a adoção de uma nova faixa de comportamento (AB) para a caracterização de solos lateríticos brasileiros (Figura 34).

Figura 34 – Classificação do shakedown



- Faixa A - *shakedown* plástico: a deformação permanente cessa após um número finito de ciclos de aplicação de carga, verificando-se a pós compactação do material. Esse tipo de comportamento é permitido em solos utilizado em camadas de pavimentos asfálticos.
- Faixa B - resposta intermediária: ao se aplicar um estado de tensão elevado, o material apresenta uma taxa de crescimento expressiva da deformação plástica que tende a se tornar constante após os primeiros ciclos de aplicação. Após a progressão dos ciclos, as deformações seguem crescendo a uma taxa de crescimento pequena. Para utilizar um material que apresenta comportamento B em determinada camada do pavimento devem ser realizados testes mais abrangentes no equipamento triaxial, identificando os impactos ao final da vida útil da estrutura.


- c) Faixa C - colapso incremental: o decréscimo na taxa de variação da deformação é muito mais lento que as demais faixas. Assim, as deformações irão depender do carregamento atuante, levando o material à falha. Deve-se evitar o emprego de solos que apresentem comportamento tipo C em camadas granulares e no subleito de pavimentos.
- d) Faixa AB - elevada taxa de crescimento da deformação durante os primeiros ciclos, tendendo, no entanto, à acomodação do material após a aplicação de diversos ciclos de aplicação. Estudos como os de Zago *et al.* (2021) e Lima (2020) corroboram em apontar a presença dessa faixa para alguns solos brasileiros em determinados estados de tensão.

A norma brasileira (DNIT, 2018a) estabelece a realização de ensaios de estágio único com 150.000 ciclos de aplicação em diferentes estados de tensão para caracterização da deformação plástica (DP) em solos. Os critérios de shakedown devem ser definidos por classificação visual, utilizando gráficos que representam a variação da taxa de crescimento da DP ($e'p$) em relação ao aumento da deformação acumulada (ep). O acomodamento é considerado quando as taxas de crescimento da DP são iguais ou inferiores a 10^{-7} mm por ciclo de carga.

Werkmeister *et al.* (2001), em seu estudo, buscou delimitar faixas que representassem a zona de transição entre um tipo de acomodamento e outro, verificando a taxa de variação da deformação acumulada em diferentes estados de tensão. O autor sugeriu que, para o conjunto de solos testados, os primeiros 5.000 ciclos de aplicação de carga foram mais expressivos em determinar limites para a classificação do tipo de acomodamento. Na Figura 35 ilustra-se a transição entre os comportamentos do tipo B e C, a partir de um limite determinado pela taxa de variação da DP (eixo vertical) para os solos analisados por Werkmeister (2003). Pode-se verificar que existe um valor (taxa de deformação por ciclos) que acima do qual os ensaios em determinados pares de tensão serão atribuídos como tipo C.

É importante ressaltar que, para a caracterização de solos brasileiros conforme comentado anteriormente, Guimarães (2009) propôs a adoção de uma nova faixa de comportamento (AB) baseada nas características dos solos do país.

Figura 35 – Definição de critérios de classificação entre as faixas B e C



Fonte: Adaptado de Werkmeister (2003)

Na busca de adaptar a abordagem do shakedown a diferentes grupos de solos com propriedades distintas, alguns autores, como Gu *et al.* (2017) e Wang e Zhuang (2021), estabeleceram novos limites de shakedown. Para a classificação do comportamento dos materiais, esses autores consideraram a diferença entre as deformações acumuladas obtidas a 5000 e 3000 ciclos. Por outro lado, Alnedawi *et al.* (2019) relacionaram as classificações do shakedown à inclinação da curva formada entre a deformação acumulada e os ciclos de aplicação de carga. Esses estudos resultaram em novas relações entre as faixas de comportamento e a deformação percentual final atingida em ensaios de estágio múltiplo.

De forma semelhante, Lima (2020) observou as propriedades de solos brasileiros, também relacionando a deformação percentual acumulada à determinação do tipo de acomodamento plástico. A autora evidenciou a necessidade da utilização da classificação visual dos ensaios sob as normas brasileiras, já que a classificação de solos por ciclos iniciais muitas vezes levaria a previsões equivocadas. Basicamente, ao se executar ensaios em longos intervalos de aplicação de carga (150.000), identificou-se que, entre 3000 e 5000 ciclos, alguns solos podem apresentar baixas deformações, embora posteriormente cheguem a elevados valores de DP acumulada. Outros solos, comumente atrelados à classificação AB, podem demonstrar elevadas deformações acumuladas iniciais, mas tendem à estabilização. Na Tabela 16 são expostos os critérios adotados em cada pesquisa para as faixas A, B e C.

Tabela 16 – Critérios de shakedown propostos na literatura

Faixas	A	B	C
Werkmeister (2003)	$\varepsilon_p^{5000} - \varepsilon_p^{3000}$ $< 0,045 \times 10^{-3}$	$0,045 \times 10^{-3}$ $< \varepsilon_p^{5000} - \varepsilon_p^{3000} < 0,4 \times 10^{-3}$	ε_p^{5000} $\varepsilon_p^{3000} > 0,4 \times 10^{-3}$
Gu <i>et al.</i> (2017)	$\varepsilon_p^{5000} - \varepsilon_p^{3000}$ $< 0,06 \times 10^{-5}$	$0,06 \times 10^{-3}$ $< \varepsilon_p^{5000} - \varepsilon_p^{3000} < 0,6 \times 10^{-4}$	ε_p^{5000} $\varepsilon_p^{3000} > 0,6 \times 10^{-3}$
Wang e Zhuang (2021)	$\varepsilon_p^{5000} - \varepsilon_p^{3000}$ $< 1 \times 10^{-5}$	1×10^{-5} $< \varepsilon_p^{5000} - \varepsilon_p^{3000} < 8 \times 10^{-5}$	$\varepsilon_p^{5000} - \varepsilon_p^{3000} > 8 \times 10^{-5}$
Alnedawi <i>et al.</i> (2019)	$\varepsilon_p < 1\%$	$1\% < \varepsilon_p < 3\%$	$\varepsilon_p > 3\%$
Lima (2020)	$\varepsilon_p < [1\%, 2\%]^*$	$[1\%, 3\%]^* < \varepsilon_p < [2\%, 4\%]$	$\varepsilon_p > [3\%, 4\%]^*$

Fonte: elaborada pelo autor (2023)

5.2.2 A Abordagem Empírica-Mecanicista

O Método de Dimensionamento Nacional (MeDiNa) foi desenvolvido para otimizar o dimensionamento de pavimentos asfálticos no Brasil, permitindo a análise do emprego de materiais em camadas de pavimentos. Para avaliar o desempenho desses materiais, o método sugere a análise de suas características elásticas, por meio de modelos de previsão da vida útil. Essa abordagem foi desenvolvida por Franco (2007) em parceria com a Universidade Federal do Rio de Janeiro e outros centros de pesquisa. O MeDiNa utiliza análises elástico-linear e elástico não linear para prever o comportamento do pavimento ao longo do tempo (SILVA e SANTOS, 2021).

O software adotado pelo método, também chamado de MeDiNa, foi desenvolvido para a análise e dimensionamento de pavimentos asfálticos e semirrígidos. Utilizando a rotina AEMC, o programa é capaz de calcular o impacto da incidência de tráfego em diferentes níveis para cada camada da estrutura e subleito. Para a realização dessas tarefas, é necessário inserir uma série de dados sobre a composição dos materiais utilizados na construção da estrutura, além de realizar ensaios padronizados para garantir a confiabilidade no projeto e construção de estradas (DNIT, 2019; KNABEN e CARPIO, 2020 e LIMA, 2020).

Para avaliar a condição do pavimento, dois critérios principais são utilizados: o trincamento por fadiga e o afundamento de trilhas de toda (ATR). No caso de camadas granulares, é necessário realizar ensaios no equipamento triaxial de cargas repetidas para ajustar modelos constitutivos que representem o módulo de resiliência e a deformação permanente. O modelo elástico não linear proposto no cálculo da DP foi o de Guimarães (2009) (Equação 18), que permite a observação da evolução das deformações plásticas sob os carregamentos incidentes. O valor máximo permitido para o afundamento do pavimento varia de acordo com o tipo de via dimensionada, sendo em torno de 10 mm para vias arteriais principais ou coletoras

primárias e 20 mm para vias arteriais coletoras secundárias e locais.

$$\varepsilon_p = \varphi_1 \left(\frac{\sigma_c}{P_a} \right)^{\varphi_2} \left(\frac{\sigma_d}{P_a} \right)^{\varphi_3} N^{\varphi_4} \quad (18)$$

Onde: ε_p é a deformação permanente específica (%), σ_c é a tensão confinante, σ_d é a tensão desvio, N é o número de ciclos, P_a é a pressão atmosférica e φ_1 , φ_2 , φ_3 e φ_4 são os coeficientes do modelo.

O trabalho desenvolvido por Guimarães (2009) em amostras de solo de diferentes regiões do país determinou que os materiais ainda sofriam deformações significativas a um número considerável de ciclos de aplicação de carga. Dessa forma, a norma brasileira indica a realização de até 9 pares de tensão em ensaios de estágio único, aplicando 150.000 ciclos de carga repetida. Tomando uma frequência recomendada de 2Hz no equipamento triaxial, são necessárias 21 horas em cada estado de tensão, e cerca de duas semanas para a caracterização completa de um solo.

5.3 Materiais e métodos

5.3.1 Materiais

Foram coletadas 7 amostras de solo representativas do Estado do Ceará, localizado na região Nordeste brasileira, com intuito de abranger o efeito da variabilidade espacial nas propriedades desses materiais. A seleção das amostras foi orientada por características pedológicas e pela proximidade a rodovias existentes.

5.3.2 Experimentos

Para caracterizar os materiais granulares utilizados no estudo, foram realizados testes de granulometria, limites de plasticidade, compactação, CBR e expansão. A caracterização do MR foi realizada de acordo com a norma 134/2018-ME (DNIT, 2018b), utilizando a sequência de pares de tensão sugerida para o subleito após a aplicação de três pares de tensão para condicionamento a 1 Hz de frequência. Os corpos de prova foram preparados na umidade ótima e compactados na energia intermediária, utilizando um soquete para 10 camadas de solo em um cilindro tripartido. Essa etapa foi importante para garantir maior precisão na

descrição do comportamento resiliente no dimensionamento.

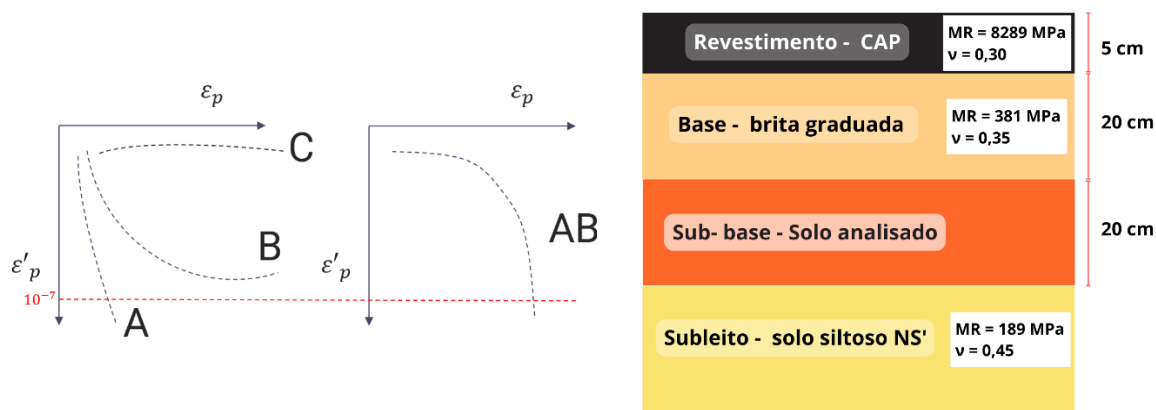
Os ensaios de DP foram executados conforme especificado na norma DNIT 179/2018 – IE (DNIT, 2018a) e condições dos corpos de prova semelhantes ao descrito para o MR. A caracterização da DP das sete amostras foi realizada aplicando 150.000 ciclos de carga em ensaios de estágio único, a uma frequência recomendada de 2 Hz (120 ciclos por minuto). Na etapa de pré-condicionamento, a norma brasileira sugere a aplicação de 50 ciclos de carga a 30 KPa de tensão confinante e 30 KPa de tensão desvio.

5.3.3 *Análise do impacto da redução do número de ciclos*

Inicialmente, os ensaios realizados em diferentes pares de tensão foram classificados quanto à ocorrência de *shakedown* de acordo com as premissas indicadas pela norma brasileira. A classificação visual demandou a construção de gráficos da taxa de variação da deformação permanente em escala logarítmica no eixo das ordenadas e deformação acumulada no eixo das abscissas para cada solo. A partir disso, foi realizado o ajuste do modelo constitutivo de Guimarães para diferentes situações, limitando os dados referentes aos ensaios classificados como Tipo A à 10.000, 20.000, 30.000, 40.000, 50.000 e 60.000 ciclos de aplicação. Para os demais ensaios, classificados como B ou AB, foram considerados sempre os dados nos 150.000 ciclos, referente ao procedimento padrão. Intervalos superiores a 60.000 ciclos ocasionariam redução no tempo de funcionamento do equipamento, mas não no tempo efetivo de caracterização de amostras, já que o período necessário ainda seria superior ao horário de funcionamento em laboratórios.

Os coeficientes dos modelos gerados em cada caso de testes foram inseridos como entrada para o software MeDiNa, versão v.1.1.5.0, adotando a construção de uma camada de sub-base em estrutura hipotética de pavimento flexível para 10 anos de vida útil. Foram ainda definidas as espessuras adotadas para revestimento, base e subleito, assim como os materiais disponíveis no programa com as suas principais propriedades. Por fim, os valores de ATR foram comparados para vislumbrar o impacto na redução do número de ciclos para ensaios Tipo A no dimensionamento de pavimentos pelo software brasileiro. Na Figura 36a são mostradas as classificações do comportamento plástico de materiais quanto ao *shakedown*, enquanto a na Figura 36b é exposta a seção de pavimento sugerida neste estudo.

Figura 36 – Premissas de metodológicas quanto à classificação dos solos e implementação no MeDiNa



(a) Classificação shakedown DNIT (2018-a)

(b) Seção do pavimento proposta

Fonte: elaborado pelo autor (2023)

5.3.4 Seleção de critérios de classificação shakedown por Árvore de Decisão

As Árvores de Decisão (AD) são algoritmos amplamente utilizados na construção de modelos estatísticos para previsão de variáveis dependentes, tanto em classificação quanto em regressão. Essa metodologia tem sido empregada de forma multidisciplinar na solução de diversos problemas em diversas áreas da ciência (DE VILLE, 2013). As AD permitem a criação de regras de classificação de maneira prática e clara, por meio de gráficos em formato de árvores ou modelos preditivos, o que possibilita a identificação das possíveis implicações em relação à chance de ocorrência de um evento, custos e utilidade (LAVANYA e PREETHI, 2017).

Esses modelos são construídos por sucessivas regras de "se-então", que ajustam uma curva senoidal, cuja complexidade da estrutura construída é diretamente proporcional ao ajuste do modelo gerado (NOORMANSHAH *et al.*, 2018). Ao contrário de outros modelos de *machine learning*, como Redes Neurais Artificiais, as AD apresentam a relação entre a variável resposta e os atributos de entrada de forma clara ao usuário, sem a necessidade de entender a interação complexa entre pesos e neurônios (KINGSFORD e SALZBERG, 2008).

Kotsiantis (2013) sugere que o desenvolvimento de AD acontece nas fases de crescimento e poda. Na fase de crescimento o conjunto de dados de treinamento será particionado em ramificações, em que cada nó irá sofrer sucessivas divisões até certo limite, ou será associado a uma classe. Existem 3 tipos de nós nas AD, sendo esses o nó raiz, nó interno e as folhas. As divisões formadas irão construir uma árvore nas quais a base de dados é segmentada em conjuntos cada vez menores. O nó raiz é representado pela partição inicial,

gerenciada pelo atributo com maior influência na classificação dos dados, ou melhor preditor. Os nós subjacentes serão chamados de nós intermediários, sempre constituídos de outros ramos de entrada e de saída, enquanto as folhas representam a classificação dos atributos (NOORMAHSHAH *et al.*, 2018).

Dessa maneira, o nó inicial ou raiz irá se desdobrar em ramos que irão agrupar a base de dados de acordo com critérios definidos nos nós intermediários para cada nível da estrutura da árvore. Como critério de partição, serão avaliadas as saídas de uma função discreta em cada nó, relacionadas aos parâmetros de entrada que irão permitir melhor expressar a variabilidade observada na variável alvo (KOTSIANTIS, 2013; DE VILLE, 2013). A divisão irá seguir até que cada ramo termine em um nó final (folha), no processo chamado particionamento recursivo. A ideia principal nesse processo é encontrar a forma mais eficiente de estabelecer as divisões, alcançando os nós mais homogêneos possíveis.

Neste capítulo foi utilizado o algoritmo CART (*Classification and Regression Trees*), por meio do pacote *rpart* (THERNEAU e ATKINSON, 2019) do software Rstudio, versão 4.1-15. A partir de divisões binárias, o algoritmo CART permite a classificação de variáveis categóricas e numéricas, apresentando certa robustez quanto a *outliers* (PATEL e PRAJAPATI, 2018). O critério de partição empregado, índice Gini (Equação 19), mede a pureza das variáveis aleatórias conforme a base de treinamento é particionada sucessivamente. Quanto mais baixo o valor do índice, maior a preferência do atributo na classificação da variável alvo (YADAV e THAREJA, 2019). Caso uma base de dados D seja dividida em A em dois grupos, $D1$ e $D2$, de acordo com Kotsiantis (2013), o índice de Gini será então definido pela Equação 20.

$$Gini(D) = 1 - n \sum_{k=1} p_k^2 \quad (19)$$

Para uma base de dados D , o número de classes “ k ” irá variar de 1 até n e P representa a proporção dos valores observados referentes a determinada classe.

$$Gini A(D) = \frac{|D1|}{(|D|Gini(D1))} + \frac{|D2|}{(|D|Gini(D2))} \quad (20)$$

Para otimizar os resultados e limitar o desenvolvimento da árvore, impedindo que o algoritmo gere um ajuste excessivo aos dados, realiza-se a poda. Essa etapa tem como principal objetivo garantir a criação de um modelo com maior poder de generalização,

reduzindo a probabilidade de *overfitting* na base de dados de treinamento. A fase de poda também é referenciada como pós-poda, diferenciando-a da etapa de pré-poda durante o crescimento da árvore, quando alguns *splits* são descartados ao não atingirem determinados critérios. Basicamente, determina-se o ponto de poda nas folhas de menor importância a partir de um parâmetro de complexidade (CP) da menor árvore possível (YADAV e THAREJA, 2019; KOTSIANTIS, 2013). Em adição a essa estratégia, a base de dados foi dividida entre treinamento (80%) e teste (20%).

Nesse sentido, também se faz necessária a delimitação de parâmetros como *minbucket*, referente ao menor número de observações permitidas em uma folha, *minsplit*, que diz respeito ao menor número de observações em que um nó pode ser dividido, e *maxdepth*, que permite impedir que a árvore cresça além de uma certa profundidade. O parâmetro crescimento de desempenho nas divisões “cp” foi adotado como 0,01.

5.3.5 Parâmetros de entrada

Apesar da literatura considerar apenas a taxa de deformação entre 5.000 e 3.000 ciclos iniciais, autores como Cabral *et al.* (2020) e Lima (2020) indicam que alguns solos brasileiros podem demonstrar comportamento divergente ao descrito em estudos como os de Werkmeister (2003). Para tanto, identificando a influência dos primeiros 10.000 ciclos iniciais no comportamento da DP total com 150.000 ciclos, foram propostas faixas adicionais da taxa de deformação como variáveis de entrada para os modelos de AD, sendo relacionadas aos limites propostos na literatura (Equação 21). Ainda, a deformação inicial (mm) foi também inserida como variável, potencialmente explicando a dimensão da taxa de crescimento da DP de solos em estágios como AB. Cada taxa foi obtida pela diferença entre a deformação observada (mm) referentes aos limites superiores e inferiores (Tabela 17).

$$\frac{\varepsilon_p Y - \varepsilon_p X}{Y - X} \quad (21)$$

Onde $\varepsilon_p X$ será o deslocamento vertical (mm) medido no ciclo X.

Tabela 17 – Intervalos de variação da DP propostos como parâmetros de entrada

Variável	Intervalo
e01	$\varepsilon_p 1$
e5030	$\varepsilon_p 5000 - \varepsilon_p 3000$
e8030	$\varepsilon_p 8000 - \varepsilon_p 3000$
e8050	$\varepsilon_p 8000 - \varepsilon_p 5000$
e10030	$\varepsilon_p 10000 - \varepsilon_p 3000$
e10050	$\varepsilon_p 10000 - \varepsilon_p 5000$

Fonte: elaborada pelo autor (2023)

5.3.6 Critérios de avaliação dos modelos de Árvore de Decisão

Um dos principais critérios para avaliar algoritmos de classificação é a acurácia, que relaciona a soma dos verdadeiros (TP) e falsos positivos (FP) e a junção dessa parcela aos verdadeiros (FP) e falsos negativos (FN), como descrito na Equação 22.

$$\frac{VP + VN}{VP + FP + VN + FN} \quad (22)$$

Também foram considerados a sensibilidade (Equação 23) e especificidade (Equação 24) para avaliação do modelo de árvores de decisão. Enquanto a sensibilidade busca avaliar a porcentagem de positivos verdadeiros frente a observações de condições positivas, a especificidade ignora falsos positivos, entendendo a que grau o modelo prevê um caso negativo.

$$\frac{VP}{VP + FN} \quad (23)$$

$$\frac{VN}{VN + FP} \quad (24)$$

5.4 Resultados e discussões

5.4.1 Classificação dos solos

Algumas amostras apresentaram deformação inicial superior à permitida pelo equipamento (5%) nos últimos pares de tensão, como A3 nos pares 120×240 e 120×360 kPa, bem como A1 no par 120×360 kPa. Já a amostra A2-2 apresentou resultados inconsistentes

quanto à variação da DP ao longo do número de ciclos nos pares 40×40 e 40×120 , de modo que esses ensaios também foram desconsiderados. Admite-se que as amostras arenosas resultaram em maior deformação quanto à sollicitação de cargas e maior sensibilidade sobretudo à variação da tensão desvio, culminando em valores excessivamente elevados nos pares de tensão mais severos. Por outro lado, diferente dos demais materiais, a amostra A2-2 apresentou expansão muito elevada, o que pode ter influenciado nas medidas de deformação em pares de tensão menos severos.

Nesse cenário, foram considerados 58 ensaios na composição do banco de dados. As principais características referentes aos ensaios de caracterização realizados, bem como os coeficientes do modelo composto de Pezo (1993), Equação 25, são expressos na Tabela 18.

$$MR = k_1(\sigma_3)^{k_2}(\sigma_d)^{k_3} \quad (25)$$

Onde: MR é o Módulo de Resiliência, σ_3 é a tensão confinante, σ_d é a tensão desvio, e k_1, k_2 e k_3 são os coeficientes do modelo.

Tabela 18 – Principais resultados dos ensaios de caracterização básica e MR

ID	Clas. AASHTO	Umid. ótima (%)	Dens. máxima (g/cm ³)	Expansão (%)	MR			
					k1	k2	k3	R ²
A3	A-3	10	1,79	0,00	$0,187 \times 10^4$	0,782	0,011	0,98
A1	A-1-b	9,5	1,89	0,00	$0,218 \times 10^4$	0,926	0,081	0,98
A2-1	A-2-4	8,8	2,11	0,17	$0,115 \times 10^4$	0,685	-0,071	0,97
A2-2	A-2-7	10	1,99	3,30	$0,027 \times 10^4$	0,116	-0,307	0,93
A4-1	A-4	13,5	1,91	0,00	$0,157 \times 10^4$	0,142	-0,306	0,89
A4-2	A-4	9,6	2,09	0,13	$0,019 \times 10^4$	0,168	-0,289	0,90
A6	A-6	11	1,97	0,30	$0,054 \times 10^4$	0,348	-0,473	0,86

Fonte: elaborada pelo autor (2023)

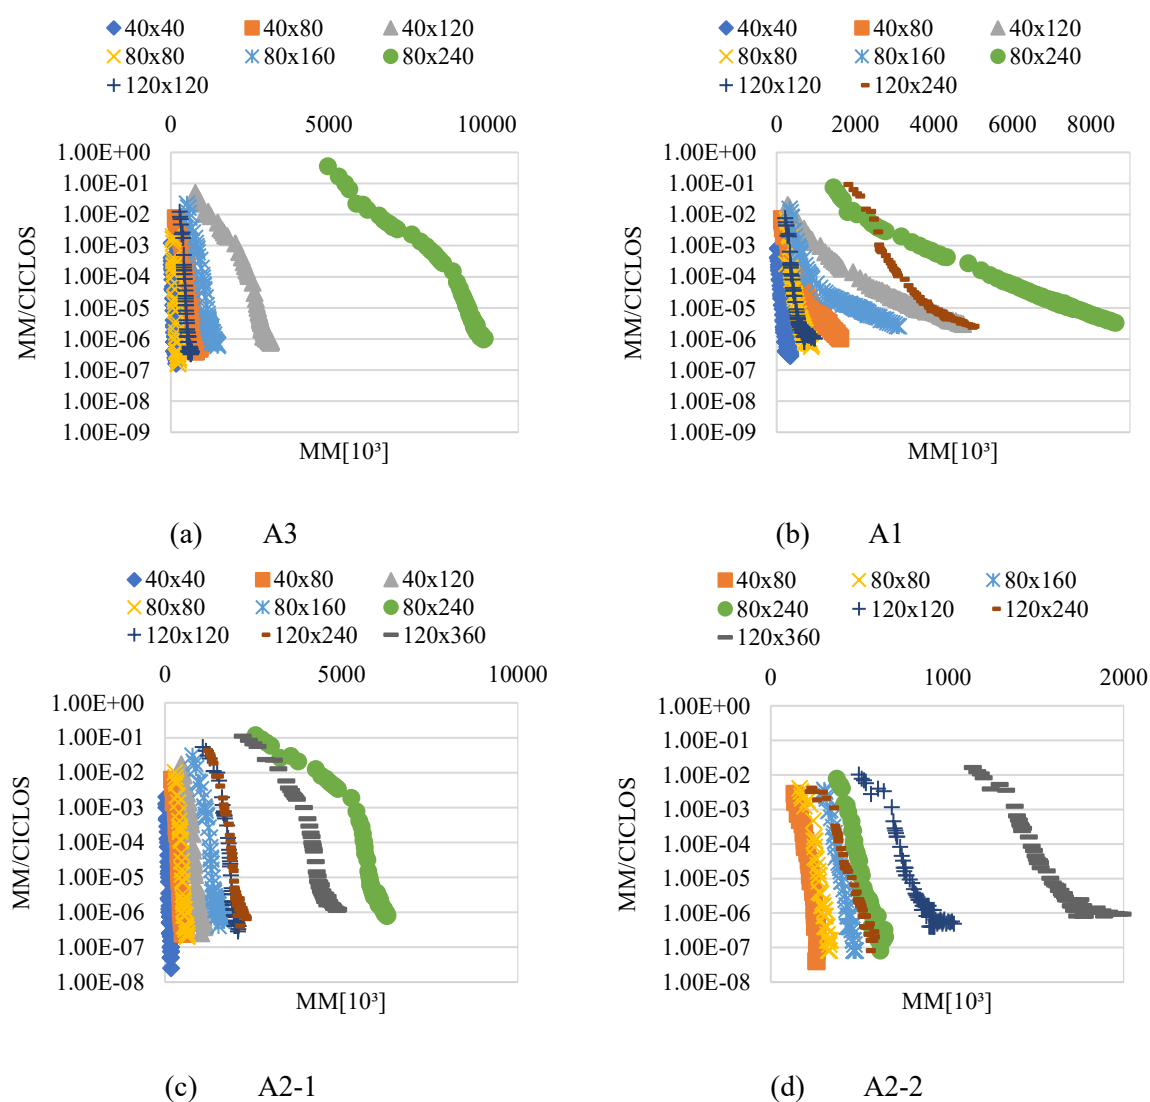
Uma das limitações observadas por estabelecer limites entre as classes por intervalos de deformação vertical é o próprio comportamento dos dados. Em alguns ensaios as taxas de deformação se mantiveram paralelas ao eixo das ordenadas sem modificação aparente até o fim do ensaio. Apesar da classificação visual atrelar esse comportamento ao tipo A, muitas vezes não foi atingido o limite de 10^{-7} m/ciclos, apesar de ser razoável concluir que a evolução do ensaio iria tender ao acomodamento. Sendo assim, tais amostras possuem variação da deformação acumulada entre os intervalos propostos na literatura muito mais próximas ao acomodamento plástico, e mais distantes do comportamento B, portanto sendo classificadas aqui como de comportamento A

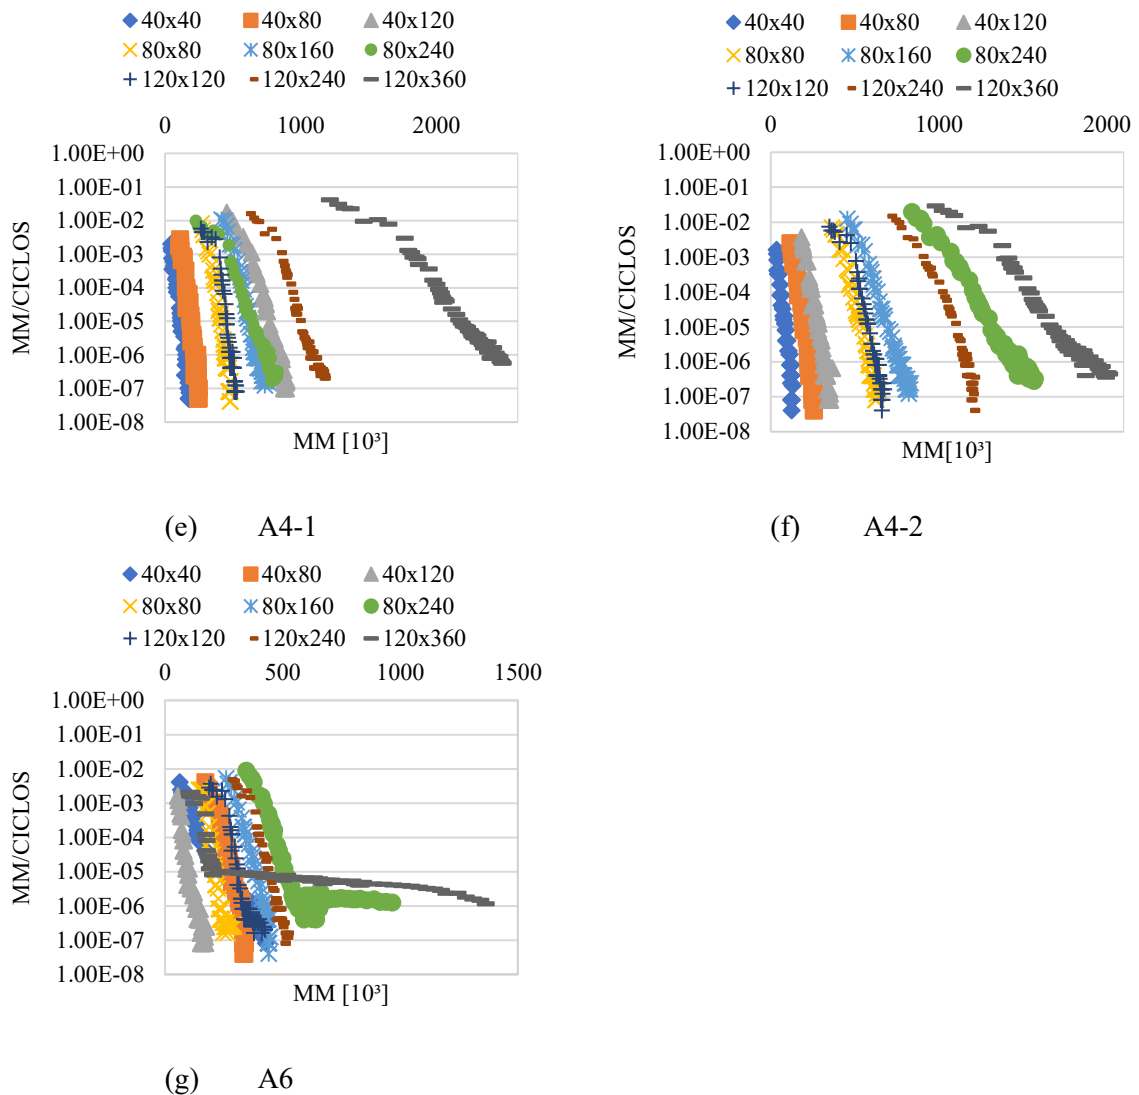
Nesse sentido, para a classificação das faixas de *shakedown*, ensaios cuja taxa de

deformação seguiu paralela ao eixo ‘y’, alcançando ou demonstrando tendência clara a atingir 10^{-7} m/ciclos receberam a denominação de classe A. Os ensaios cujo comportamento progride paralelo ao eixo “y”, mas inclinam-se paralelamente ao eixo ‘x’ são determinados como tipo B, sendo observadas na maior parte dos casos, taxas acumuladas finais de 10^{-6} m/ciclos. Já para um comportamento intermediário, no qual se verifica crescimento considerável da deformação, mas tendência posterior a atingir 10^{-7} m/ciclos, foi atribuído o comportamento Tipo AB.

Por fim, quando a variação da deformação plástica se dá por uma curva aparentemente paralela ao eixo ‘x’ indica-se a ocorrência do Tipo C. Entretanto, nenhum desses casos foi verificado no banco de dados. Os ensaios em diferentes pares de tensão para cada solo foram classificados quanto ao formato da curva da variação da taxa de deformação acumulada em m/ciclos [10^{-3}] (eixo “y”) pela deformação acumulada em mm [10^3] (eixo “x”), como demonstra a Figura 37.

Figura 37 – Variação da taxa de crescimento da DP pela deformação vertical acumulada





Fonte: elaborado pelo autor (2023)

Na Tabela 19 são mostradas as classificações quanto à ocorrência de *shakedown*, comparando o método de classificação visual pertinente à norma brasileira e os limites delimitados por Wermeister (2009) e Gu *et al.* (2017). Não houve diferenças entre a classificação proposta por Werkmeister (2003) e por Gu *et al.* (2017). Entretanto, esses resultados divergiram da abordagem brasileira, o que ressalta a especificidade de cada conjunto de critérios para amostras de solos com características específicas. Os critérios dos autores mencionados determinaram o comportamento na faixa A para os solos analisados em quase todos os pares de tensões. Entretanto, a classificação visual sugere a ocorrência das faixas AB e B em muitos outros ensaios. Nessa situação, é possível afirmar que os principais critérios disponíveis na literatura falham em identificar um acúmulo significativo de deformações em alguns estados de tensões, que devem ser analisados com maior cautela segundo as normas

brasileiras.

Tabela 19 – Classificação dos solos quanto ao shakedown

Amostra	Critério	1	2	3	4	5	6	7	8	9
A3	DNIT (2019)	A	B	B	A	B	B	A	-	-
	Werkeister (2003)	A	A	A	A	A	B	A	-	-
	Gu <i>et al.</i> (2017)	A	A	A	A	A	B	A	-	-
A1	DNIT (2019)	B	B	B	B	B	B	B	B	-
	Werkeister (2003)	A	A	B	A	B	B	A	B	-
	Gu <i>et al.</i> (2017)	A	A	B	A	B	B	A	B	-
A2-1	DNIT (2019)	A	B	AB	A	AB	B	AB	AB	AB
	Werkeister (2003)	A	A	A	A	A	A	A	A	A
	Gu <i>et al.</i> (2017)	A	A	A	A	A	A	A	A	A
A2-2	DNIT (2019)	-	A	-	A	A	A	AB	AB	AB
	Werkeister (2003)	-	A	-	A	A	A	A	A	A
	Gu <i>et al.</i> (2017)	-	A	-	A	A	A	A	A	A
A4	DNIT (2019)	A	A	AB	A	A	AB	AB	AB	AB
	Werkeister (2003)	A	A	A	A	A	A	A	A	A
	Gu <i>et al.</i> (2017)	A	A	A	A	A	A	A	A	A
A4-2	DNIT (2019)	A	A	A	A	AB	AB	A	AB	B
	Werkeister (2003)	A	A	A	A	A	A	A	A	A
	Gu <i>et al.</i> (2017)	A	A	A	A	A	A	A	A	A
A6	DNIT (2019)	AB	A	A	A	A	AB	A	A	AB
	Werkeister (2003)	A	A	A	A	A	A	A	A	A
	Gu <i>et al.</i> (2017)	A	A	A	A	A	A	A	A	A

Fonte: elaborada pelo autor (2023).

*- Ensaios desconsiderados por rompimento das amostras ou comportamento inesperado

5.4.2 Impacto da interrupção dos ensaios Tipo A na obtenção do ATR pelo software MeDiNa

Foi proposta a redução no número de ciclos em ensaios classificados na Faixa A, com o objetivo de identificar o impacto dessa abordagem no valor de ATR calculado pelo software MeDiNa em cada caso de teste. Para isso, os intervalos de testes foram determinados entre 10.000 e 60.000 ciclos, com variação de 10.000 ciclos. As observações de DP medidas pelo equipamento triaxial foram restringidas ao limite estipulado. Além disso, no dimensionamento da estrutura, foi determinada uma vida útil de 10 anos, sendo cada situação avaliada em três níveis de tráfego (5×10^5 , 5×10^6 e 5×10^7).

A amostra de solo A1 não foi considerada no processo, pois todos os ensaios foram classificados como B. No entanto, a amostra A3, também de caráter arenoso e com deformações elevadas, apresentou três estados de tensão nos quais o comportamento plástico foi determinado como Tipo A. No final do período de projeto, o ATR observado para os dados de controle (150.000 ciclos) variou entre 6 e 11 mm, dependendo das diferentes situações de tráfego

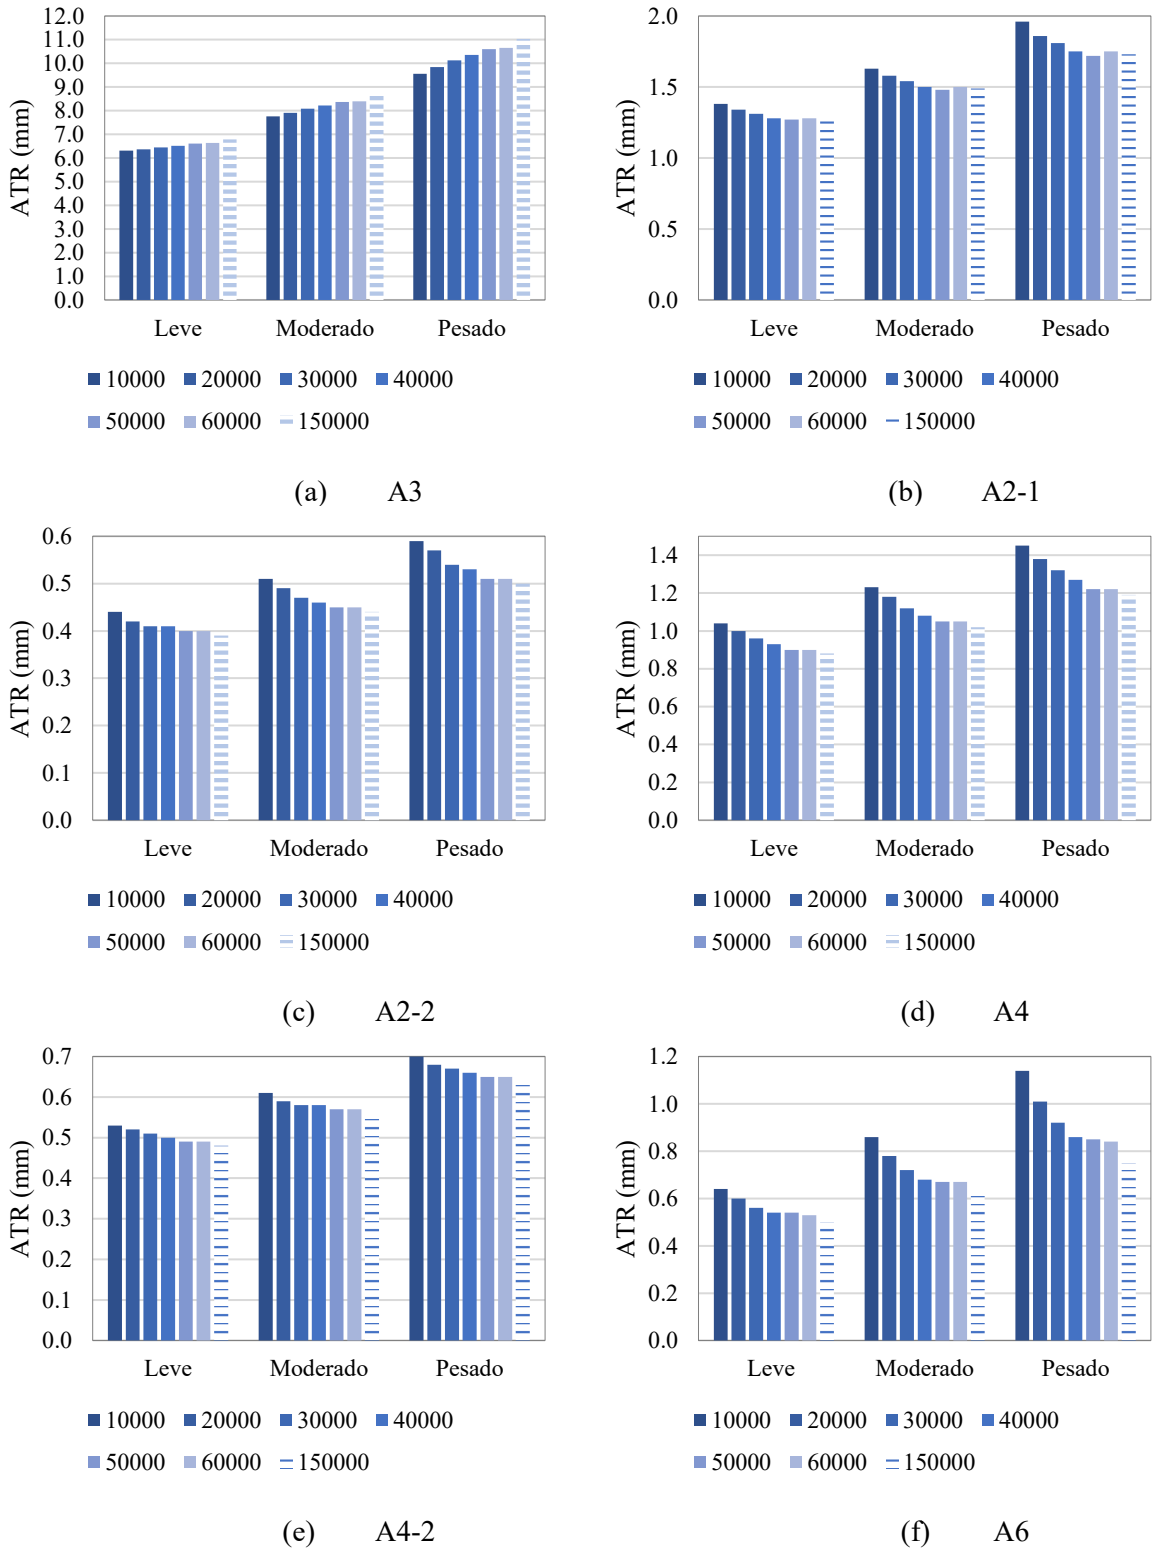
incidente. Esse valor pode exceder as deformações permitidas para toda a estrutura sob as perspectivas de dimensionamento brasileiras, denotando um solo cuja implementação em camadas de pavimentos seria evitada.

Já quanto à execução da metodologia proposta, percebeu-se que o aumento no número de ciclos nos ensaios A reduziu os erros em relação ao valor de referência do ATR. A menor variação nos erros obtidos entre os intervalos de testes ocorreu de 50.000 a 60.000 ciclos. Os valores calculados a 60.000 ciclos variaram entre 0,15 mm para tráfego leve e 0,38 mm para tráfego pesado, abaixo do ATR de controle. Conseqüentemente, é possível concluir que essa abordagem pode ser efetiva mesmo para solos altamente deformáveis, uma vez que os erros esperados foram inferiores a 4% dos afundamentos em situações de tráfego pesado na estrutura.

De outra forma, observou-se que o comportamento das demais amostras foi distinto do solo arenoso A3, evidenciado pelos afundamentos inversamente proporcionais ao número de ciclos de teste considerados. Além disso, esses materiais apresentaram uma baixa deformabilidade, com valores de ATR inferiores a 2 mm, o que indica um comportamento plástico potencialmente favorável para uso em obras de pavimentação, cuja contribuição para a deformação total na estrutura não seria tão significativa em relação ao ATR total permitido de 10 mm.

Para além disso, a metodologia proposta mostrou-se eficiente no dimensionamento da seção de pavimento, mesmo após 30.000 ciclos. Foram obtidos erros máximos em torno de 0,1 mm para todas as demais amostras de materiais ensaiadas, inclusive em situações de tráfego pesado. Assim, a interrupção do procedimento nesse intervalo em ensaios classificados como Tipo A não afetou significativamente a precisão no dimensionamento da estrutura. Na Figura 38 são ilustrados gráficos de barra que descrevem o ATR obtido em cada situação de teste em comparação ao afundamento com 150.000 ciclos pelo software MeDiNa nas 7 amostras de solos analisadas.

Figura 38 – Impacto da redução de ciclos no ATR obtido em ensaios na faixa A



Fonte: elaborado pelo autor (2023)


5.4.3 Critério preliminar de classificação para o conjunto de amostras

Com o objetivo de estabelecer um critério para interrupção dos ensaios de cargas

repetidas no equipamento triaxial, foram desenvolvidos modelos de classificação baseados em árvores de decisão. Esses modelos foram construídos considerando apenas três classes (A, B e AB), uma vez que o comportamento tipo C não foi observado nas amostras avaliadas. As variáveis de entrada utilizadas nos modelos foram os intervalos entre ciclos propostos na seção 5.3.5, enquanto a variável alvo multi-classe foi o tipo de *shakedown* de acordo com os parâmetros brasileiros.

Com o objetivo de evitar o *overfitting* na árvore de decisão, foi realizada uma poda do modelo com base na variação do erro relativo em função do número de complexidade (CP) para cada divisão da árvore (conforme apresentado na Figura 39a). É evidente que, após o terceiro nó de divisão, não há ganhos na eficiência do modelo, uma vez que o erro relativo permanece constante. Portanto, a árvore foi podada com base no menor valor de CP para o menor *split* e menor erro relativo (indicado por X). Isso garantiu que o modelo final fosse potencialmente mais generalizável para novos dados. Já a estrutura da árvore após a “poda” pode ser visualizada na Figura 39b, sendo possível visualizar a estrutura condicional de classificação *shakedown* proposta, com base na taxa de variação entre 10.000 e 3.000 ciclos (e10030) e 5.000 e 3.000 ciclos (e5030).

Figura 39 – Avaliação de desempenho para otimização e estrutura pós-poda da AD proposta



(a) Análise do desempenho do modelo pelo crescimento da AD

(b) Fluxograma de classificação das faixas de shakedown

Fonte: elaborado pelo autor (2023)

É importante ressaltar que as árvores de decisão são capazes de selecionar as variáveis que permitem a maior eficiência na partição dos dados, garantindo assim uma maior pureza na previsão da variável alvo. Nesse sentido, o modelo criado para classificação de ensaios quanto ao shakedown identificou o intervalo entre os primeiros 10.000 e 3.000 ciclos

iniciais como o mais relevante para seleção do limite de classificação entre as classes A e B, e o intervalo entre 5.000 e 3.000 para a distinção entre B e AB.

A matriz de confusão (Tabela 20) e a acurácia obtida para as bases de treinamento e teste, considerando as três classes de shakedown, demonstraram efetividade na previsão, sobretudo para o Tipo A. É notável que não foram identificados falsos negativos para a classe A, o que se reflete no valor atribuído de 1 para a sensibilidade em ambas as bases de dados (teste e treinamento). Entretanto, um ensaio Tipo A foi classificado como AB na base de treinamento, justificando o menor valor de sensibilidade para esse conjunto de dados.

Tabela 20 – Matriz de confusão da AD gerada

		A	B	AB
Base de treinamento	A	20	0	1
	B	0	6	5
	AB	0	1	14
Base de teste	A	5	0	0
	B	0	1	2
	AB	0	0	4

Fonte: elaborada pelo autor (2023)

Por outro lado, o desempenho do modelo na identificação do comportamento B e AB apresentou menor precisão. Tal fato decorre da natureza do comportamento Tipo AB, que se apresenta com uma tendência intermediária, possuindo uma taxa de crescimento inicial alta, semelhante ao Tipo B, mas alcançando o acomodamento, como o Tipo A. Ademais, as principais diferenças entre as classes AB e B ocorrem após um grande número de ciclos de aplicação de carga, dificultando a classificação com base nas taxas iniciais de deformação plástica e resultando em uma maior proporção de falsos positivos e negativos, devido à menor distribuição de dados quanto à classe. Assim, a determinação de critérios que permitam definir com maior precisão os limites entre essas classes tornou-se uma tarefa mais complexa.

Por outro lado, os ensaios que não tendem ao acomodamento, cujo comportamento plástico deve ser analisado com maior confiabilidade e maior número de ciclos de carga, não serão interrompidos prematuramente, o que sugere maior segurança na utilização do método proposto. Os parâmetros de medida de desempenho adotados para a avaliação da AD em cada classe podem ser verificados na Tabela 21.

Tabela 21 – Medidas de avaliação do desempenho da AD

		A	B	AB
Base de treinamento	Acurácia	0,981	0,940	0,850
	Sensitividade	1,000	1,000	0,700
	Especificidade	0,961	0,870	1,000
Base de teste	Acurácia	1,000	0,900	0,830
	Sensitividade	1,000	1,000	0,670
	Especificidade	1,000	0,810	1,000

Fonte: elaborado pelo autor (2022)

É importante ressaltar que testes preliminares com o desenvolvimento de modelos baseados apenas no intervalo entre 5.000 e 3.000 ciclos iniciais demonstraram menor acurácia e um número maior de falsos negativos para o Tipo A. Nesse caso, a probabilidade de um ensaio Tipo B ou AB ser classificado como A seria maior, o que poderia levar à interrupção prematura de ensaios com alta taxa de crescimento da deformação plástica. Portanto, o intervalo proposto por Werkmeister (2003) pode não ser o mais adequado para definir o tipo de acomodamento plástico em solos do Estado do Ceará.

5.5 Conclusões

A partir desta pesquisa, foi possível verificar que é possível reduzir o número de ciclos em ensaios que atingem o acomodamento plástico (Tipo A) sem prejudicar de forma significativa o desempenho da previsão de ATR em camadas granulares no dimensionamento de pavimentos asfálticos. Além disso, também foram estabelecidos critérios de identificação prévia da classificação *shakedown* de procedimentos laboratoriais de estágio único para o grupo de amostras analisadas. As principais conclusões em relação ao trabalho desenvolvido foram:

- a) Para o tráfego pesado (5×10^7), interromper o ensaio após 30.000 ciclos resultou em variações no ATR calculado na dimensão de 0,10 mm para amostras cujos afundamentos foram inferiores a 2 mm. Dessa maneira, essa metodologia poderia trazer uma economia de tempo no procedimento laboratorial em cerca de 16,8 horas em cada ensaio de estágio único.
- b) Os resultados dos ensaios para a amostra de solo A3 mostraram que, para solos altamente deformáveis (com afundamentos superiores a 11 mm), é necessário aplicar um número maior de ciclos de carga para evitar superestimar as deformações. Embora a precisão na medição do ATR para essa amostra seja menor (cerca de 0,30 mm), o erro gerado representa menos de 4% do

afundamento plástico ao final dos testes com apenas 60.000 ciclos. É justificável, portanto, interromper os ensaios Tipo A, obtendo uma boa aproximação e reduzindo o tempo total de ensaio em cerca de 30%.

- c) A avaliação da taxa de deformações indicou que os critérios de classificação prévia de ensaios descritos na literatura não são adequados para os solos analisados, muitas vezes apontando ensaios B ou AB como A. Portanto, é justificada a necessidade de desenvolver e testar critérios que permitam uma previsão precisa do tipo de comportamento em ensaios de estágio único, levando em consideração os parâmetros brasileiros e as características particulares dos solos da região analisada.
- d) Os resultados indicam que, dentre as diferentes faixas de variação da taxa de crescimento da DP, a relação entre 10.000 e 3.000 ciclos iniciais foi mais relevante identificar os limites entre as classificações A e B, enquanto a faixa entre 5.000 e 3.000, geralmente abordada na literatura, foi mais efetiva na classificação entre B e AB. Dessa maneira, indica-se a importância de considerar outras faixas de variação da taxa de crescimento da DP para se obter uma boa previsão do comportamento dos materiais em ensaios de estágio único. São necessários novos estudos para validar a metodologia proposta aqui em diferentes condições.
- e) A partir do desenvolvimento de modelos de classificação baseados em árvores de decisão, foram estabelecidos critérios para a identificação dos tipos de acomodamento A, B e AB em ensaios de estágio único. O modelo apresentou boa acurácia na previsão da ocorrência do Tipo A, o que sugere sua utilidade na identificação prévia de ensaios que tendem ao acomodamento plástico. Além disso, não se percebeu a falsa identificação de ensaios AB e B como A, o que poderia influenciar negativamente a previsão do comportamento plástico de solo. Com isso, seria possível reduzir o número de ciclos em condições de acomodamento (faixa A), diminuindo o desgaste do equipamento e otimizando os recursos financeiros e o tempo necessário para a caracterização dos solos. Entretanto, a limitação no número de amostras e ensaios demanda uma análise mais aprofundada com um banco de dados mais amplo, permitindo a generalização dos resultados para a região de estado brasileiro estudado.

Assim, esse método pode trazer benefícios na caracterização de solos em relação à DP sob parâmetros brasileiros, à medida que reduz prazos, esforço do equipamento e custos

associados. Portanto, a utilização desses critérios pode ser uma ferramenta útil para melhorar a eficiência e a agilidade na realização de ensaios geotécnicos.


6 PRINCIPAIS CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

6.1 Principal contribuição do trabalho

A partir da análise dos 7 materiais ensaiados, foi investigado o uso de ferramentas de machine learning na previsão das deformações plásticas dos solos submetidos a carregamentos dinâmicos no equipamento triaxial. Foram implementadas 3 principais abordagens: a previsão da DP com base em índices físicos e outras propriedades; a previsão das deformações com base na evolução do número de ciclos em cada ensaio de estágio único e a classificação *shakedown* com base na taxa de variação das deformações nos 10.000 primeiros ciclos de carga.

De modo geral, foi possível apontar a adequação de modelos de RNA e RF na previsão da DP para identificação preliminar do potencial de uso de solos em pavimentos, a programação de interrupção prévia de ensaios na faixa A (acomodamento plástico) e a possível redução no número de ciclos de ensaios sob os parâmetros brasileiros para 30.000 com auxílio de uma ferramenta *online*. A Figura 40 ilustra a interface (a) e o *QR-code* (b) pelo qual se pode acessar o aplicativo online. Essa ferramenta permite a obtenção dos valores previstos pelo *upload* de uma planilha com os dados de ensaio a 30.000 ciclos (número de ciclos e deformação plástica acumulada em porcentagem), retirando os 1.000 ciclos iniciais.

Figura 40 – Interface e código de acesso ao aplicativo online desenvolvido para demonstração do método proposto.



(a) Interface do software



(b) *QR code* para acesso do aplicativo

Fonte: elaborado pelo autor (2023)

6.2 Principais limitações do trabalho

A análise dos dados e o desenvolvimento dos modelos foi realizada a partir de um conjunto limitado de amostras ensaiadas. Apesar da configuração do ensaio de DP resultar em um banco de dados expressivo da evolução de deformações acumuladas por um amplo intervalo de ciclos de carga e estado de tensões, foram considerados ao todo 7 solos. Essa restrição se deu sobretudo pela duração dos procedimentos e disponibilidade de dados referentes a essa propriedade.

Nesse sentido, apesar dos modelos de previsão desenvolvidos indicarem a viabilidade e potencial dos métodos de estimação da DP, é importante destacar que um grupo maior de amostras é necessário para trazer maior poder de generalização. Assim, o ajuste dos modelos com dados provenientes de novos materiais é desejável para criar ferramentas com melhor desempenho em relação à previsão do comportamento de solos com propriedades mais heterogêneas em relação ao banco de dados.

6.3 Principais conclusões com relação à revisão da literatura

A partir de uma revisão bibliográfica, foi identificado um pequeno grupo de estudos relacionados à estimação das deformações plásticas de solos, submetidos à carregamentos dinâmicos no equipamento triaxial. Os modelos foram desenvolvidos a partir de ensaios em estágio múltiplo, dentro de um intervalo de 10.000 ciclos de aplicação de carga para cada estado de tensão. Os autores empregaram modelos estatísticos de regressão e algoritmos de RNA, inclusive sendo apontada maior aplicabilidade das ferramentas de *machine learning*. Paralelamente, foram observadas as principais variáveis de entrada determinadas pelos autores, principalmente referentes aos ensaios de granulometria, compactação, limites de consistência e CBR. Por fim, o conjunto limitado de artigos selecionados indica que ainda existem diversas abordagens a serem consideradas na criação de modelos de previsão da DP, tal como o uso de diferentes ferramentas e métodos cada vez mais eficientes.

6.4 Principais conclusões do artigo 1

Os algoritmos de *machine learning* (Redes Neurais Artificiais e *Random Forest*) foram efetivos na criação de modelos de previsão da DP, com base em propriedades e índices

físicos, a partir da avaliação do ajuste e os erros gerados (com coeficientes de determinação superiores a 0,99). Para tanto, essas ferramentas demonstraram bom potencial na previsão desse parâmetro por variáveis que exigem menos recursos econômicos e de tempo, considerando o intervalo de ciclos e estados de tensão propostos nas parametrizações brasileiras. Além disso, a avaliação da influência das variáveis de entrada levou à identificação de propriedades essenciais ao desempenho dos modelos, identificando a porcentagem passante na peneira N° 200 como principal variável explicativa do comportamento plástico do conjunto analisado. Nesse sentido, essa estratégia possibilitou otimização dos algoritmos, estimando a DP por um número menor de atributos sem prejuízos aos erros e ajuste gerados.

6.5 Principais conclusões do artigo 2

Foi possível delimitar uma única arquitetura de RNA capaz de prever o comportamento da DP de solos em ensaios de estágio único. A partir de 30.000 ciclos, o modelo foi capaz de estimar a evolução das deformações até 150.000. Ainda, a retirada de ciclos iniciais aprimorou o desempenho dos algoritmos, sendo apontada a exclusão dos primeiros 1.000 ciclos com o valor mais adequado para o treinamento. Após o ajuste de modelos constitutivos (Guimarães, 2009), verificou-se boa precisão na previsão do ATR de uma estrutura de pavimento proposta, avaliando o uso de solos com comportamentos arenosos e siltosos na composição da sub-base da estrutura. Estima-se que a economia de tempo gerada por esse método possa chegar a 4 dias na caracterização de uma amostra.

6.6 Principais conclusões do artigo 3

Considerando uma estrutura de pavimento e o uso dos solos ensaiados para compor sua sub-base, a interrupção de ensaios classificados como A (*shakedown plástico*) no equipamento triaxial após 30.000 ciclos resultou em erros de ATR em torno de 0,1 mm, para amostras cuja deformação total foi inferior a 2 mm. Além disso, a utilização de árvores de decisão permitiu a criação de uma estrutura de classificação do tipo de *shakedown* de ensaios de estágio único dentro dos primeiros 10.000 ciclos de aplicação de carga. A partir dos resultados observados na matriz de confusão e parâmetros de avaliação (sensibilidade e especificidade) o modelo foi efetivo em identificar a classificação A com precisão, possibilitando a potencial programação da interrupção de ensaios dentro do *shakedown* plástico no equipamento triaxial.

6.7 Sugestão para futuros trabalhos

Diante do exposto tem-se as seguintes sugestões para trabalhos futuros:

- a) ajustar os algoritmos de RF e RNA no desenvolvimento de modelos com um número maior de amostras de solo, buscando ampliar o poder de generalização obtido e minimizar a sensibilidade a materiais com diferentes características;
- b) verificar a aplicabilidade de novos algoritmos de machine learning na previsão da DP a partir das propriedades e índices físicos apontados. Assim como na previsão do MR em muitos estudos, novas abordagens podem trazer diferentes benefícios e aprimoramento da estimação do comportamento plástico de materiais geotécnicos;
- c) testar a redução de ciclos em novas amostras de solo. A expansão dos testes servirá para posterior validação dos resultados em outras regiões e outros tipos de materiais, verificando a aplicabilidade da metodologia diante de maior variabilidade espacial de características geotécnicas;
- d) apontar critérios de diferenciação entre solos com maiores e menores deformações, otimizando ainda mais a redução do tempo de ensaio necessário. Como alguns solos demonstraram ATRs muito próximos aos de referência já com 20.000 ciclos, seria interessante definir aspectos que indiquem preliminarmente a possibilidade de interromper os ensaios antes mesmo de atingir 30.000 ciclos;
- e) ajustar os modelos de árvore de decisão com um número maior de amostras de solo e pares de tensão, em busca de avaliar o poder de generalização obtido.

REFERÊNCIAS

- ABIODUM, O. I.; JANTAN, A.; OMOLARA, A. E.; DADA, K. V.; MOHAMED, N. A.; ARSHAD, H. State-of-the-art in artificial neural network applications: A survey. **Heliyon**, v. 4, n. 11, p. e00938, 2018.
- ABRAHAM, A. Artificial neural networks. **Handbook of measuring system design**, 2005
- AGATONOVIC-KUSTRIN, S.; BERESFORD, R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. **Journal of pharmaceutical and biomedical analysis**, v. 22, n. 5, p. 717-727, 2000.
- AHMAD, M. W.; MOURSHED, M.; REZGUI, Y. Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. **Energy and buildings**, v. 147, p. 77-89, 2017.
- AIELLO, S.; ECKSTRAND, E.; FU, A.; LANDRY, M.; ABOYOUN, P. **Machine Learning with R and H2O**. Leghorn: H2O.ai, Inc, 2018.
- AKOGLU, H. User's guide to correlation coefficients. **Turkish Journal of emergency medicine**, v. 18, n. 3, p. 91-93, 2018.
- ALNAHIT, A. O.; MISHRA, A. K.; KHAN, A. A. Stream water quality prediction using boosted regression tree and random forest models. **Stochastic Environmental Research and Risk Assessment**, v. 36, n. 9, p. 2661-2680, 2022.
- ALNEDAWI, A.; NEPAL, K. P.; AL-AMERI, R. New shakedown criterion and permanent deformation properties of unbound granular materials. **Journal of Modern Transportation**, v. 27, n. 2, p. 108-119, 2019.
- ALNEDAWI, A.; AL-AMERI, R.; NEPAL, K. P. Neural network-based model for prediction of permanent deformation of unbound granular materials. **Journal of Rock Mechanics and Geotechnical Engineering**, v. 11, p. 1231-1242, 2019.
- ALNEDAWI, A.; NEPAL, K. P.; AL-AMERI, R. Effect of loading frequencies on permanent deformation of unbound granular materials. **International Journal of Pavement Engineering**, v. 22, n. 8, p. 1008-1016, 2021.
- ARNDT, S.; TURVEY, C.; ANDREASEN, N. C. Correlating and predicting psychiatric symptom ratings: Spearman's r versus Kendall's tau correlation. **Journal of psychiatric research**, v. 33, n. 2, p. 97-104, 1999.
- ATHEY, S.; TIBSHIRANI, J.; WAGER, S. Generalized random forests. **The Annals of Statistics**, v. 47, n. 2, p. 1148-1178, 2019.
- AUSTROADS. Determination of Permanent Deformation and Resilient Modulus Characteristics of Unbound Granular Materials under Drained Conditions – Commentary to AG:PT/T053. **Austrroads**, Sydney, Australia, 2007.
- BA, M.; TINIUUM, J. M.; FALL, M. Prediction of permanent deformation model parameters of unbound base course aggregates under repeated loading. **Road Materials and Pavement**

Design, v. 16, n. 4, p. 854-869, 2015.

BAGHERZADEH-KHIABANI, F.; RAMEZANKHANI, A.; AZIZI, F.; HADAEGH, F.; STEYERBERG, E. W.; KHALILI, D. A tutorial on variable selection for clinical prediction models: feature selection methods in data mining could improve the results. **Journal of clinical epidemiology**, v. 71, p. 76-85, 2016.

BARKSDALE, R. D. Laboratory Evaluation of Rutting in Base Course Materials. **Proceedings of the Third International Conference on Structural Design of Asphalt Pavements**, London, pp. 161-174, 1972.

BAUS, R. L.; STIRES, N. R. **Mechanistic-empirical pavement design guide implementation**. University of South Carolina. Dept. of Civil & Environmental Engineering, 2010.

BEHRANG, M. A.; ASSAREH, E.; GHANBARAZEDEH, A.; NOGHREHALBADI, A. R. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. **Solar Energy**, v. 84, n. 8, p. 1468-1480, 2010.

BENARDOS, P. G.; VOSNIAKIS, G. C. Optimizing feed forward artificial neural network architecture. **Engineering applications of artificial intelligence**, v. 20, n. 3, p. 365-382, 2007.

BERNUCCI, L. B.; MOTTA, L. D.; CERATTI, J. A. P.; SOARES, J. B. **Pavimentação asfáltica: formação básica para engenheiros**. Rio de Janeiro: Petrobrás, 2008.

BOTTOU, L. Stochastic gradient learning in neural networks. **Proceedings of Neuro-Nimes**, v. 91, n. 8, 1991.

BREIMAN, L. **Random Forest**. Statistics Department University of California Berkeley, 1999.

CABRAL, W. S. **Exploração, análise comparativa e modelagem da deformação permanente de materiais granulares da microregião de Mossoró/RN**. Tese (Doutorado em Engenharia de Transportes). Universidade Federal do Ceará, Fortaleza, 2021.

CABRAL, W. S.; BARROSO, S. H. de A.; TORQUATO, S. A. Study of the Permanent Deformation of Soil Used in Flexible Pavement Design. **Advances in Civil Engineering**, v. 2020, 2020.

CAI, Y.; CHEN, J.; CAO, Z.; GU, C.; WANG, J. Influence of grain gradation on permanent strain of unbound granular materials under low confining pressure and high-cycle loading. **International Journal of Geomechanics**, v. 18, n. 3, p. 04017156, 2018.

CAO, Z.; CHEN, J.; CAI, Y.; ZHAO, L.; GU, C.; WANG, J. Long-term behavior of clay-fouled unbound granular materials subjected to cyclic loadings with different frequencies. **Engineering geology**, v. 243, p. 118-127, 2018.

CEN (European Committee for Standardization). **EN. 13286–13287: Cyclic Load Triaxial**

Test for Unbound Mixtures. Brussels: European Standard, 2004.

CHA, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE) – Arguments against avoiding RMSE in the literature. **Geoscientific model development**, v. 7, n. 3, p. 1247-1250, 2014.

CHAI, J. C; MIURA, N. Traffic-load-induced permanent deformation of road on soft subsoil. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 128, n. 11, p. 907-916, 2002.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)?–Arguments against avoiding RMSE in the literature. **Geoscientific model development**, v. 7, n. 3, p. 1247-1250, 2014.

CHAN, J. Y. L.; LEOW, S. M. H.; BEA, K. T.; CHENG, W. K.; PHOONG, S. W.; HONG, Z. W.; CHEN, Y. L. Mitigating the Multicollinearity Problem and Its Machine Learning Approach: A Review. **Mathematics**, v. 10, n. 8, p. 1283, 2022.

CHEN, X.; ISHWARAN, H. Random forests for genomic data analysis. **Genomics**, v. 99, n. 6, p. 323-329, 2012.

CHO, S., HONG, H., & HA, B. C. A hybrid approach based on the combination of variable selection using decision trees and case-based reasoning using the Mahalanobis distance: For bankruptcy prediction. **Expert Systems with Applications**, v. 37, n. 4, p. 3482-3488, 2010.

CHOWDHURY, R. M; KASSEM, E; ALKUIME, H; MISHRA, D; BAYOMY, F, M, S. Summary Resilient Modulus Prediction Model for Unbound Coarse Materials. **Journal of Transportation Engineering, Part B: Pavements**, v. 147, n. 3, p. 04021035, 2021.

CIABURRO, G.; VENKATESWARAN, B. **Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles.** Packt Publishing Ltd, 2017.

COLLINS, I. F.; BOULBIBANE, M. Geomechanical analysis of unbound pavements based on shakedown theory. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 126, n. 1, p. 50-59, 2000.

CUTLER, A.; CUTLER, D.R., STEVENS, J.R. Random forests. *In: Ensemble machine learning.* Springer, Boston, MA., 2012.

DA SILVA, L. M.; SANTOS, R. O. G. Estudo comparativo: método empírico do DNIT e mecanístico-empírico (Medina) no dimensionamento de pavimentos asfálticos. **Engineering Sciences**, v. 9, n. 1, p. 114-124, 2021.

DE VILLE, B. Decision trees. **Wiley Interdisciplinary Reviews: Computational Statistics**, v. 5, n. 6, p. 448-455, 2013.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTE – DNIT. **ME 179: Pavimentação: Solos: Determinação da deformação permanente: Método de Ensaio.** Rio de Janeiro: Departamento Nacional de Infraestrutura de Transportes, 2018a.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTE – DNIT. **ME 134: Pavimentação: Solos: Determinação do módulo de resiliência: Método de Ensaio.** Rio de Janeiro: Departamento Nacional de Infraestrutura de Transportes, 2018b.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTE – DNIT. **Manual de utilização do programa MeDiNa.** Departamento Nacional de Infraestrutura de transporte, Diretoria de Planejamento e Pesquisa. Instituto de Pesquisas Rodoviárias, 2019.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTE – DNIT. **Instrução de Serviço – IS-247: Estudos para Elaboração de Projetos de Implantação usando o Método de Dimensionamento Nacional – MeDiNa.** Nota Informativa. Departamento Nacional de Infraestrutura de Transportes, 2021.

DIETTERICH, T. G. Ensemble methods in machine learning. *In: International workshop on multiple classifier systems* (pp. 1-15). **Proceedings [...]**, Springer, Berlin, Heidelberg, 2000.

DJONKAMLA, Y.; DORE, G; BILODEAU, J. P. Development of a prediction model of permanent deformation considering the physical properties of subgrade soil. **Canadian Journal of Civil Engineering**, v. 43, n. 11, p. 958-967, 2016.

DONG, W. Z.; ZHU, F. Research on influencing factors for permanent deformation of soil base of low embankment highway. *In: Transportation Research Congress 2016: Innovations in Transportation Research Infrastructure* (pp. 364-373). **Proceedings [...]**, 2016.

DONGARE, A. D.; KHARDE, R. R.; KACHARE, A. D. Introduction to artificial neural network. **International Journal of Engineering and Innovative Technology (IJEIT)**, v. 2, n. 1, p. 189-194, 2012.

DUBEY, A. K.; JAIN, V. Comparative study of convolution neural network's relu and leaky-relu activation functions. *In: Applications of Computing, Automation and Wireless Systems in Electrical Engineering* (pp. 873-880). **Proceedings [...]**, Springer, Singapore, 2019.

DUONG, T. V.; CUI, Y. J.; TANG, A. M., DUPLA, J. C., CANOU, J., CALON, N., ROBINET, A. Effects of water and fines content on the resilient modulus of the interlayer soil of railway substructure. **Acta Geotechnica**, v. 11, n. 1, p. 51-59, 2016.

EL-BASYOUNY, M. M.; WITCZAK, M.; EL-BADAWY, S. Verification for the calibrated permanent deformation models for the 2002 design guide (with discussion). **Journal of the Association of Asphalt Paving Technologists**, v. 74, 2005

ERLINGSSON, S. On forecasting the resilient modulus from the CBR value of granular bases. **Road materials and pavement design**, v. 8, n. 4, p. 783-797, 2007.

ERLINGSSON, S.; RAHMAN, S., SALOUR, F. Characteristic of unbound granular materials and subgrade S based on multistage RLT testing. **Transportation Geotechnics**, v. 13, p. 28-42, 2017.

GALIANO, V. R.; CASTILLO, M. S.; OLMO, M. C.; RIVAS, M. J. O. G. R. C. Machine learning predictive models for mineral prospectivity: an evaluation of neural networks,

random forest, regression trees and support vector machines. **Ore Geology Reviews**, v. 71, p. 804-818, 2015.

GARDNER, M. W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. **Atmospheric environment**, v. 32, n. 14-15, p. 2627-2636, 1998.

GATAHUN, M. A., SHITOTE, S. M.; GARIV, Z. C. A. Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes. **Construction and Building Materials**, v. 190, p. 517-525, 2018.

GENUER, R., POGGI, J. M., & TULEAU-MALOT, C. Variable selection using random forests. **Pattern recognition letters**, v. 31, n. 14, p. 2225-2236, 2010.

GENUER, R., POGGI, J. M., & TULEAU-MALOT, C. VSURF: an R package for variable selection using random forests. **The R Journal**, v. 7, n. 2, p. 19-33, 2015.

GETAHUN, M. A., SHITOTE, S. M., & GARIY, Z. C. A. Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes. **Construction and Building Materials**, v. 190, p. 517-525, 2018.

GHORBANI, B; ARULRAJAH, A; NARSILIO, G; HORPIBULSUK, S; BO, M. V. Development of genetic-based models for predicting the resilient modulus of cohesive pavement subgrade soils. **Soils and Foundations**, v. 60, p. 398-410, 2020.

GLUCHOWSKI, A.; SAS, W. Impact of cyclic loading on shakedown in cohesive soils—Simple Hysteresis Loop Model. **Applied Sciences**, v. 10, n. 6, p. 20-29, 2020.

GÖKHAN, A. K. S. U.; GÜZELLER, C. O.; ESER, M. T. The effect of the normalization method used in different sample sizes on the success of artificial neural network model. **International Journal of Assessment Tools in Education**, v. 6, n. 2, p. 170-192, 2019.

GONG, H.; SUN, Y.; SHU, X.; HUANG, B. Use of random forests regression for predicting IRI of asphalt pavements. **Construction and Building Materials**, v. 189, p. 890-897, 2018.

GRÖMPING, U. Variable importance assessment in regression: linear regression versus random forest. **The American Statistician**, v. 63, n. 4, p. 308-319, 2009.

GU, F.; LUO, X.; ZHANG, Y.; CHEN, Y.; LUO, R.; LYTTON, R. L. Prediction of geogrid-reinforced flexible pavement performance using artificial neural network approach. **Road Materials and Pavement Design**, v. 19, n. 5, p. 1147-1163, 2021

GU, F.; ZHANG, Y.; LUO, X., SAHIN, H.; LYTTON, R. L. Characterization and prediction of permanent deformation properties of unbound granular materials for pavement ME design. **Construction and Building Materials**, v. 155, p. 584-592, 2017

GUIMARÃES, A. C. **Um método mecânico-empírico para a previsão da deformação permanente em solos tropicais constituintes de pavimentos**. Tese (doutorado). Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2009.

- HAN, H.; GUO, X.; Yu, H. Variable selection using mean decrease accuracy and mean decrease gini based on random forest. *In: 2016 7th IEEE international conference on software engineering and services science (ICSESS) (pp. 219-224). Proceedings [...], IEEE, 2016.*
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. Random Forests. *In: The Elements of Statistical Learning. Springer Series in Statistics. Proceedings [...], Springer, New York, NY, 2009.*
- HEIDARABADIZADEH, N; GHANIZADEH, A. R; BEHNOOF, A. Prediction of the resilient modulus of non-cohesive subgrade soils and unbound sub-base materials using a hybrid support vector machine method and colliding bodies optimization algorithm. **Construction and Building Materials**, v. 275, p. 122140, 2021.
- HELSEL, D. R. Advantages of nonparametric procedures for analysis of waterquality data. **Hydrological Sciences Journal**, v. 32, n. 2, p. 179-190, 1987.
- HOSSAIN, M. S. Estimation of subgrade resilient modulus for Virginia soil. **Transportation Research Record**, v. 2101, n. 1, p. 98-109, 2009.
- IKEAGWUANI, C. C; D. C. NWONU; C. C. NWEKE. Resilient modulus descriptive analysis and estimation for fine-grained soils using multivariate and machine learning methods. **International Journal of Pavement Engineering**, v. 2021, p. 1-16, 2021.
- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial Neural Networks: A tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.
- JAYALAKSHMI, T.; SANTHAKUMARAN, A. Statistical normalization and backpropagation for classification. **International Journal of Computer Theory and Engineering**, v. 3, n. 1, p. 1793-8201, 2021.
- JING, P.; NOWAMOOZ, H.; CHAZALLON, C. Permanent deformation behaviour of a granular material used in low-traffic pavements. **Road Material and Pavement Design**, v. 19, n. 2, p. 289-314, 2016.
- KARSOLIVA, S. Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture. **International Journal of Engineering Trends and Technology**, v. 3, n. 6, p. 714-717, 2012.
- KHAN, Z. H., ALIN, T. S., HUSSAIN, M. A. Price prediction of sharemarket using artificial neural network (ANN). **International Journal of Computer Applications**, v. 22, n. 2, p. 42-47, 2011.
- KHASAWNEH, M. A. Permanent deformation behavior of cohesive subgrade soils classified as A-4a and A-6a. **Materials Today: Proceedings**, v. 33, p. 1762-1768, 2020.
- KHASAWNEH, M. A; N. F. AL-JAMAL. Modeling resilient modulus of fine-grained materials using different statistical techniques. **Transportation Geotechnics**, v. 21, p. 100263, 2019.
- KIM, S.; J. YANG; J. JEONG. Prediction of subgrade resilient modulus using artificial neural

network. **KSCE Journal of Civil Engineering**, v. 18, n. 5, 2014. p. 1372-1379.

KINGSFORD, C., & SALZBERG, S. L. What are decision trees?. **Nature biotechnology**, v. 26, n. 9, p. 1011-1013, 2008.

KNABBEN, R. M; CARPIO, J. A. V. **Como usar o software MeDiNa: o guia prático para a utilização do software MeDiNa de dimensionamento de pavimentos flexíveis**, 2020.

KOTSIANTIS, S. B. Decision trees: a recent overview. **Artificial Intelligence Review**, v. 39, p. 261-283, 2013.

KOVÁCS, Z. L. **Redes neurais artificiais**. Editora Livraria da Física, 2012

KUMAR, A.; AZIZI, A., TOLL, D. The influence of cyclic loading frequency on the response of an unsaturated railway formation soil. *In: Geo-Congress 2022 (pp. 274-283). Proceedings [...]*, 2022.

LAVANYA, B., & PREETHI, G. R. Performance analysis of decision tree algorithms on mushroom dataset. **International Journal for Research in Applied Science and Engineering Technology**, v. 5, n. 11, p. 183-191, 2017.

LEKARP, F. E DAWSON, A. Modelling permanent deformation behaviour of unbound granular materials. **Construction and building materials**, v. 12, n. 1, 9-18, 1998.

LI, J; PIERCE, L. M; UHLMAYER, J. Calibration of flexible pavement in mechanistic–empirical pavement design guide for Washington state. **Transportation Research Record**, v. 2095, n. 1, p. 73-83, 2009.

LIAW, M. WIENER, Classification and regression by random Forest, **R News**, v. 3, n. 2, 18–22, 2002.

LIMA, C. D. A.; MOTTA, L. M. G.; ARAGÃO, F. T. S. Effects of compaction moisture content on permanent deformation of soils subjected to repeated triaxial load tests. **Transportation Research Record**, v. 2673, n. 2, p. 466-476, 2019.

LIMA, C. D. A. **Avaliação da deformação permanente de materiais de pavimentação a partir de ensaios triaxiais de cargas repetidas**. Tese (doutorado). Programa de Engenharia Civil–COPPE/UFRJ. Rio de Janeiro, 2020.

LIMA, C. D. A. D.; MOTTA, L. M. G. D.; ARAGÃO, F. T. S. **Ensaio de deformação permanente: efeito do número de ciclos na interpretação do comportamento de solos e britas**. *Matéria (Rio de Janeiro)*, v. 26, 2021a.

LIMA, C. D. A.; MOTTA, L. M. G.; ARAGÃO, F. T. S. A permanent deformation predictive model for fine tropical soils considering the effects of the compaction moisture content on material selection. **Transportation Geotechnics**, v. 28, p. 100534. 2021b.

LIN, G.; SHEN, W. Research on convolutional neural network based on improved Relu piecewise activation function. **Procedia Computer Science**, 131, 977-984, 2018.

- LING, X., LI, P.; ZHANG, F.; ZHAO, Y.; LI, Y.; AN, L. Permanent deformation characteristics of coarse grained subgrade soils under train-induced repeated load. **Advances in Materials Science and Engineering**, v. 2017, n. 7, p. 1-15, 2017.
- LIU, Q. F.; IQBAL, M. F.; YANG, J.; LU, X. Y.; ZHANG, P., RAUF, M. Prediction of chloride diffusivity in concrete using artificial neural network: Modelling and performance evaluation. **Construction and Building Materials**, v. 268, p. 121082, 2021.
- LUO, X., GU, F., ZHANG, Y., LYTTON, R. L.; ZOLLINGER, D. Mechanistic-empirical models for better consideration of subgrade and unbound layers influence on pavement performance. **Transportation Geotechnics**, v. 13, p. 52-68, 2017.
- MAHESH, B. Machine learning algorithms - a review. **International Journal of Science and Research (IJSR)**, v. 9, p. 381-386, 2020.
- MALLA, R. B.; S. JOSHI. Resilient modulus prediction models based on analysis of LTPP data for subgrade soils and experimental verification. **Journal of Transportation Engineering**, v. 133, n. 9, p. 491-504, 2007.
- MCCULLOCH, W. S.; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.
- MEI, J.; HE, D.; HARLEY, R.; HABETTLER, T., QU, G.. A random forest method for real-time price forecasting in New York electricity market. *In: 2014 IEEE PES General Meeting Conference & Exposition (pp. 1-5)*. **Proceedings [...]**, 2014.
- MONISMITH, C. L; OGAWA, N.; FREEME, C. R. Permanent deformation characteristics of subgrade soils due to repeated loading. **Transport Res Rec**, v. 1975, n. 537, p. 1–17, 1975
- MORGAN, J. R. The response of granular materials to repeated loading. *In: Australian Road Research Board Proc.* **Proceedings [...]**, 1996.
- NASR, M. S.; MOUSTAFA, M. A.; SEIF, H. A.; EL KOBROSY, G. Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY waste water treatment plant performance-EGYPT. **Alexandria engineering journal**, v. 51, n. 1, p. 37-43, 2012
- NAZZAL, M. D; L. M. MOHAMMAD. Estimation of resilient modulus of subgrade soils using falling weight deflectometer. **Transportation Research Record**, v. 2186, n. 1, p. 1-10, 2010.
- NAZZAL, M. D; O. TATARI. Evaluating the use of neural networks and genetic algorithms for prediction of subgrade resilient modulus. **International Journal of Pavement Engineering**, v. 14, n. 4, p. 364-373, 2013
- NCHRP. **Guide for Mechanistic–Empirical Design of New and Rehabilitated Pavement Structures**. Final report to NCHRP. Applied Research Associates, Inc., Albuquerque, N.Mex. 2004.
- NOORMANSHAH, W. M., NOHUDDIN, P. N., & ZAINOL, Z. Document categorization using decision tree: preliminary study. **International journal of engineering & technology**,

v. 7, n. 4.34, p. 437-440. 2018.

OBITE, C. P.; OLEWUEZI, N. P.; UGWUANVIM, G. U., BARTHLOMEW, D. C. Multicollinearity effect in regression analysis: A feed-forward artificial neural network approach. **Asian Journal of Probability and Statistics**, v. 6, n. 1, p. 22-33, 2020.

OLIDIS, C; HEIN, D. Guide for the mechanistic-empirical design of new and rehabilitated pavement structures materials characterization: Is your agency ready. *In: 2004 annual conference of the transportation association of Canada. Proceedings [...]*, 2004.

PAHNO, S; J. J. YANG E S. S. KIM. Use of Machine Learning Algorithms to Predict Subgrade Resilient Modulus. **Infrastructures**, v. 6, n. 6, p. 78, 2021.

PAL, M; S. DESWAL. Extreme learning machine based modeling of resilient modulus of subgrade soils. **Geotechnical and Geological Engineering**, v. 32, n. 2, p. 287-296, 2014.

PARK, H. I.; G. C. KWEON; S. R. LEE. Prediction of resilient modulus of granular subgrade soils and subbase materials using artificial neural network. **Road Materials and Pavement Design**, v. 10, n. 3, p. 647-665, 2009

PATEL, H. H., & PRAJAPATI, P. (2018). Study and analysis of decision tree based classification algorithms. **International Journal of Computer Sciences and Engineering**, v. 6, n. 10, p. 74-78, 2018.

PAUTE, J L; HORNVEH, P; BENABEN, J P. Repeated load triaxial testing of granular materials in the French Network of Laboratories des Ponts et Chaussées. Flexible Pavements, Edited by A G Correia. *In: European Symposium on Flexible Pavements, Euroflex, 1983, Balkema, Rotterdam, pp 53-64. Proceedings [...]*, 1996.

PENG, L; ZENG, J; LI, F; LI. Rapid estimation of resilient modulus of subgrade soils using performance-related soil properties. **International Journal of Pavement Engineering**, v. 22, n. 6, p. 732-739, 2021.

PEREIRA, L. A. F. **Análise comparativa de estruturas de pavimentos utilizando RCD e dimensionadas a partir de parâmetros distintos**. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte, 2021.

PEZO, R. F. A General Method of Reporting Resilient Modulus Tests of Soils: A Pavement Engineer's Point of View. *In: 72nd Annual Meeting of the Transportation Research Board, Washington, D.C., Jan. 1993. Proceedings [...]*, 1993.

PINTO, C. S. **Curso Básico de Mecânica dos Solos em 16 Aulas**. São Paulo: Oficina de Textos, 02-15, 2000.

PRIDDY, K. L.; KELLER, P. E. **Artificial neural networks: an introduction**. SPIE press, 2005.

PROBST, P., WRIGHT, M. N., BOULESTEIX, A. L. Hyperparameters and tuning strategies for random forest. **Wiley Interdisciplinary Reviews: data mining and knowledge discovery**, v. 9, n. 3, p. e1301, 2019.

PUPPALA, A. J.; L. N. MOHAMMAD; A. ALLEN. Permanent Deformation Characterization of Subgrade Soils from RLT Test. **Journal of Materials in Civil Engineering**, v. 11, n. 4, p. 274–282, 1999.

PUPPALA, A. J.; SARIDE, S; CHOMTID, S. Experimental and modeling studies of permanent strains of subgrade soils. **Journal of geotechnical and geoenvironmental engineering**, v. 135, n. 10, p. 1379-1389, 2009.

PUTH, M. T.; NEUHÄUSER, M.; RUXTON, G. D. Effective use of Spearman's and Kendall's correlation coefficients for association between two measured traits. **Animal Behaviour**, v. 102, p. 77-84, 2015.

RAHIM, A. M; GEORGE, K. P. Models to estimate subgrade resilient modulus for pavement design. **International Journal of Pavement Engineering**, v. 6, n. 2, p. 89-96, 2005.

RAHMAN, M. M.; ISLAM, K. M; GASSMAN, S. L. Correlations of permanent strain and damping coefficients with resilient modulus for coarse-grained subgrade soils. **International Journal of Geotechnical Engineering**, v. 15, n. 6, p. 714-723, 2021.

RAHMAN, M. S; ERLINGSON, S. Predicting permanent deformation behaviour of unbound granular materials, **International Journal of Pavement Engineering**, v. 16, n. 7, p. 587-601, 2015.

RAMCHOUN, H.; AMINE, M.; IDRISSE, J.; GHANOU, Y.; ETTAOUIL, M. Multilayer Perceptron: architecture optimization and training. **International Journal of Interactive Multimedia and Artificial Intelligence**, v. 4, n. 1, p. 26, 2016.

REED, R.; MARSII, R. J. **Neural smithing**: supervised learning in feedforward artificial neural networks. Mit Press, 1999.

RIBEIRO, A. J. A. **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, 2016.

RODRIGUEZ-GALIANO, V.; SANCHEZ-CASTILLO, M.; CHICA-OLMO, M.; CHICA-RIVAS, M. J. O. G. R. Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines. **Ore Geology Reviews**, v. 71, p. 804-818, 2015.

SALOUR, F.; ERLINGSSON, S. Permanent deformation characteristics of silty sand subgrades from multistage RLT tests. **International journal of pavement engineering**, v. 18, n. 3, p. 236-246, 2017.

SANCHEZ-PINTO, L. N.; VENABLE, L. R.; FAHRENBACH, J.; CHURPEK, M. M. Comparison of variable selection methods for clinical predictive modeling. **International journal of medical informatics**, v. 116, p. 10-17, 2018.

SAZLI, M. H. A brief review of feed-forward neural networks. **Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering**, v. 50, n.

01, 2006.

SCHAUMLÖFFEL, L. S.; DAMBROS, J. W. V.; FERNANDES, P. R. B.; GUTTERRES, M.; PIATNICKI, C. M. S. Direct and simultaneous determination of four phenolic antioxidants in biodiesel using differential pulse voltammetry assisted by artificial neural networks and variable selection by decision trees. **Fuel**, v. 236, p. 803-810, 2019.

SHOLEVAR, N., GOLROO, A., & ESFAHANI, S. R. Machine learning techniques for pavement condition evaluation. **Automation in Construction**, v. 136, p. 104190, 2022.

SING, A. K.; SAHOO, J. P. Rutting prediction models for flexible pavement structures: A review of historical and recent developments. **Journal of Traffic and Transportation Engineering (English Edition)**, v. 8, n. 3, p. 315-338, 2021.

SPEISER, J. L., MILLER, M. E., TOOZE, J., & IP, E. A comparison of random forest variable selection methods for classification prediction modeling. **Expert systems with applications**, v. 134, p. 93-101, 2019.

SUZUKI, K. **Artificial neural networks: methodological advances and biomedical applications**. BoD—Books on Demand. 2011.

SVOZIL, D.; KVANICKA, V.; POSPICHAL, J. Introduction to multi-layer feed-forward neural networks. **Chemometrics and intelligent laboratory systems**, v. 39, n. 1, p. 43-62, 1997

TAUIL, J. C. S.; F. R. DE CASTRO. Metadados de preservação digital: uma abordagem através da revisão sistemática de literatura. *In: Colóquio de Dados, Metadados e Web Semântica. Proceedings [...]*, 2018.

THERNEAU, T.; ATKINSON, B. rpart: Recursive Partitioning and Regression Trees. **R package version 4.1-15**, 2019.

TITI, H. H.; ENGLISH, R.; FAHEEM, A. Resilient Modulus of Fine-Grained Soils for Mechanistic–Empirical Pavement Design. **Transportation Research Record**, v. 2510, n. 1, p. 24-35, 2015.

VENKATESH, N., HEERALAL, M.; PILLAI, R. J. Resilient and permanent deformation behaviour of clayey subgrade soil subjected to repeated load triaxial tests. **European Journal of Environmental and Civil Engineering**, v. 24, n. 9, p. 1414-1429, 2020.

WAGH, V. M.; PANASKAR, D. B.; MULEY, A. A. Estimation of nitrate concentration in ground water of Kadavariverbasin-Nashik district, Maharashtra, India by using artificial neural network model. **Modeling Earth Systems and Environment**, v. 3, n. 1, p. 1-10, 2017.

WANG, K.; ZHUANG, Y. Characterizing the permanent deformation Response-Behavior of subgrade material under cyclic loading based on the shakedown theory. **Construction and Building Materials**, v. 311, p. 125325, 2021.

WANG, R.; ZHOU, F.; CHEN, D. H.; ZHENG, G.; SCULLION, T.; WALUBITA, L. F. Characterization of Rutting (Permanent Strain) Development of A-2-4 and A-4 Subgrade Soils

Under the HVS Loading. **Journal of Performance of Constructed Facilities**, v. 24, n. 4, 2009.

WERKMEISTER, S. **Permanent deformation behaviour of unbound granular materials in pavement construction**. Ph.D. Dissertation, University of Technology, Dresden, Germany, 2003.

WERKMEISTER, S.; DAWSON, A. R.; WELLNER, F. Permanent deformation behavior of granular materials and the shakedown concept. **Transportation Research Record**, v. 1757, n. 1, p. 75-81, 2001.

WERKMEISTER, S.; DAWSON, A. R.; WELLNER, F. Permanent deformation behaviour of granular materials. **Road materials and pavement design**, v. 6, n. 1, p. 31-51, 2005.

WINTER, B. Linear models and linear mixed effects models in R with linguistic applications. **arXiv preprint**, arXiv:1308.5499, 2013.

WOJCIECHOWSKI, J., HOPKINS, A. M., & UPTON, R. N. Interactive pharmacometric applications using R and the shiny package. **CPT: pharmacometrics & systems pharmacology**, v. 4, n. 3, p. 146-159, 2015.

WYTHOFF, B. J. Backpropagation neural networks: a tutorial. **Chemometrics and Intelligent Laboratory Systems**, v. 18, n. 2, p. 115-155, 1993.

XIAO, Y; M. WATSON. Guidance on conducting a systematic literature review. **Journal of Planning Education and Research**, v. 39, n. 1, p. 93-112, 2019.

YADAV, K., & THAREJA, R. Comparing the performance of naive bayes and decision tree classification using R. **International Journal of Intelligent Systems and Applications**, v. 11, n. 12, 2019.

ZAGO, J. P., PINHEIRO, R. J. B., BARONI, M., SPECHT, L. P., DELONGUI, L., & SAGRILO, A. V. Study of the permanent deformation of three soils employed in highway subgrades in the municipality of Santa Maria-RS, Brazil. **International Journal of Pavement Research and Technology**, v. 14, n. 6, p. 729-739, 2021.

ZHANG, J; J. PENG; L. ZENG; J. LI; F. LI. Rapid estimation of resilient modulus of subgrade soils using performance-related soil properties. **International Journal of Pavement Engineering**, v. 22, n. 6, p. 732-739, 2021.

ZHAO, Y.; DENNIS, JR, N. D; ELLIOT, R. P. Prediction of subgrade permanent strain using simple soil properties. *In: Geotechnical Engineering for Transportation Projects*, pp. 1076-1085. **Proceedings [...]**, 2004.

ZHOU, C; HUANG, B; DRUMM, E; SHU, X; DONG, Q. Soil resilient modulus regressed from physical properties and influence of seasonal variation on asphalt pavement performance. **Journal of Transportation Engineering**, v. 141, n. 1. p. 04014069, 2015.

ZHOU, X.; LU, P.; ZHENG, Z.; TOLLIVER, D.; KERAMATI, A. Accident prediction accuracy assessment for highway-rail grade crossings using random forest algorithm

compared with decision tree. **Reliability Engineering & System Safety**, v. 200, p. 106931, 2020.

ZOU, J.; HAN, Y.; SO, S. S. Overview of artificial neural networks. **Artificial Neural Networks**, v. 14, n. 22, 2008.

ZUPAN, J. Introduction to artificial neural network (ANN) methods: what they are and how to use them. **Acta Chimica Slovenica**, v. 41, p. 327-32, 1994.