



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE CIÊNCIAS**  
**DEPARTAMENTO DE GEOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM GEOLOGIA**

**FRANCISCO CARLOS HENRIQUE PIO DE OLIVEIRA**

**DESENVOLVIMENTO DE MODELOS NEURAIIS E MAPAS GEOLÓGICO-  
GEOTÉCNICOS PARA PAVIMENTAÇÃO NO ESTADO DO CEARÁ**

**FORTALEZA**

**2024**

FRANCISCO CARLOS HENRIQUE PIO DE OLIVEIRA

DESENVOLVIMENTO DE MODELOS NEURAIIS E MAPAS GEOLÓGICO-  
GEOTÉCNICOS PARA PAVIMENTAÇÃO NO ESTADO DO CEARÁ

Dissertação apresentada ao Programa de Pós-Graduação em Geologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Geologia. Área de concentração: Geologia Ambiental e Recursos Hídricos.

Orientador: Prof. Dra. Carla beatriz Costa de Araújo.

FORTALEZA

2024

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)

---

- O47d Oliveira, Francisco Carlos Henrique Pio de.  
Desenvolvimento de modelos neurais e mapas geológico-geotécnicos para pavimentação no estado do Ceará / Francisco Carlos Henrique Pio de Oliveira. – 2024.  
156 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ecologia e Recursos Naturais, Fortaleza, 2024.  
Orientação: Profa. Dra. Carla Beatriz Costa de Araújo.
1. Dimensionamento de pavimentos. 2. Redes neurais artificiais. 3. Mapas geológico-geotécnicos. 4. Módulo de resiliência. I. Título.

CDD 577

---

FRANCISCO CARLOS HENRIQUE PIO DE OLIVEIRA

DESENVOLVIMENTO DE MODELOS NEURAIIS E MAPAS GEOLÓGICO-  
GEOTÉCNICOS PARA PAVIMENTAÇÃO NO ESTADO DO CEARÁ

Dissertação apresentada ao Programa de Pós-Graduação em Geologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Geologia. Área de concentração: Geologia Ambiental e Recursos Hídricos.

Aprovada em: 29/02/2024.

BANCA EXAMINADORA

---

Prof. Dra. Carla Beatriz Costa de Araújo (Orientador)  
Universidade Federal do Ceará (UFC)

---

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

---

Prof. Dr. César Ulisses Vieira Veríssimo  
Universidade Estadual do Ceará (UFC)

---

Prof. Dra. Beatriz Chagas Silva Gouveia  
Departamento Nacional de Infraestrutura de Transportes (DNIT)

Aos meus pais, família e amigos.

## AGRADECIMENTOS

Agradeço primeiramente à toda minha família, minha mãe, meu pai, minha irmã e meu irmão pelo amor incondicional, apoio e conselhos durante toda minha jornada, o apoio e incentivo de todos vocês foram minha motivação.

À minha orientadora Professora Carla Beatriz, que sempre foi solícita em todas as ocasiões, suas orientações e contribuições foram fundamentais para o andamento desta pesquisa e do meu crescimento como profissional. Gratidão por acreditar em mim, pela empatia e tolerância nos momentos mais difíceis durante essa jornada.

À Professora Suelly pela imensa atenção e a todos os integrantes do grupo de pesquisa do DNIT Subprojeto 02 que sempre foram solícitos para me ajudar.

Ao Daniel pela paciência em me ajudar inúmeras vezes na construção dos mapas.

À Larissa do laboratório GRC pelo auxílio e disponibilidade para construção na análise de resíduos.

A todos os professores do PPGGEO, que contribuíram para minha formação acadêmica e profissional durante esse curso.

A toda a banca examinadora por mostrar os defeitos em minha pesquisa, que eu não consegui enxergar, isso foi fundamental para meu aprimoramento.

À minha amiga Carla que sempre me apoiou e incentivou independentemente da situação, sempre foi um grande exemplo de ser humano.

Aos meus amigos do grupo farofa do Dorivas, Rafruno, Delfino, Diego, Mat e Leozin.

Ao CNPq, FUNCAP e DNIT pela concessão da bolsa durante a realização desta pesquisa e pelas informações e apoio prestado.

À UFC pela oportunidade de concluir o mestrado acadêmico.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES). Expresso minha gratidão pelo apoio financeiro oferecido.

“Sorte é o que acontece quando a preparação encontra a oportunidade.” (Sêneca, 4 a.C.–65 d.C.).

## RESUMO

O desenvolvimento de modelos neurais e mapas geológico-geotécnicos para auxiliar projetos de pavimentos no Estado do Ceará é de suma importância na otimização e precisão do dimensionamento de pavimentos. Atualmente, há uma necessidade evidente de ferramentas mais avançadas e específicas para lidar com os desafios geotécnicos. Através do avanço com uso das redes neurais artificiais nos últimos tempos, tem sido possível otimizar os estudos de caracterização geológica-geotécnica de pavimentos, oferecendo uma abordagem inovadora para compreender as propriedades geotécnicas dos materiais utilizados na fundação e nas camadas dos pavimentos. A modelagem neural, quando há disponibilidade de dados em quantidade e qualidade adequados possibilita a previsão de uma variedade de características geotécnicas dos solos, podendo ser uma opção de estimativa mais econômica e complementar em relação à obtenção tradicional de dados por meio apenas de ensaios de laboratório de CBR ou ISC (Índice de Suporte Califórnia) e Módulo de Resiliência (MR) necessários para projeto de pavimentos. O objetivo principal desta dissertação foi desenvolver modelos neurais, por meio do uso de inteligência artificial e mapas geológico-geotécnicos para serem aplicados em projetos de pavimentação no Estado do Ceará. Para isso, foram levantados bancos de dados contendo informações geotécnicas de pavimentos do Estado do Ceará. Ao total os bancos de dados contêm mais de oito mil dados abrangendo informações de propriedades físicas do solo, CBR e classificação AASHTO (American Association of State Highway and Transportation Officials). Todos esses dados são oriundos de projeto da Universidade Federal em parceria com o DNIT (Departamento Nacional de Infraestrutura de Transportes). Através da utilização de Redes Neurais Artificiais (RNAs) foi possível desenvolver modelos neurais para previsão dos valores de CBR e MR, a maior parte desses modelos atingiu valores de correlação acima de 0,7, sugerindo uma relação significativa entre as variáveis utilizadas para estimar CBR e MR. O melhor modelo desenvolvido para CBR teve um valor de correlação de 0,98 na validação, já para o MR o modelo mais representativo teve um valor de 0,86. Isso destaca a promissora facilidade e aplicabilidade dos modelos neurais na previsão do CBR e MR para o dimensionamento empírico e empírico-mecanístico de pavimentos. Por meio dos mapas geológico-geotécnicos foi possível obter uma visão das propriedades geotécnicas e a distribuição dos elementos geológicos nos trechos analisados, o que permite uma abordagem mais aproximada na seleção de materiais e técnicas de construção.

**Palavras-chave:** dimensionamento de pavimentos; mapas geológico-geotécnicos; módulo de resiliência.

## ABSTRACT

The development of neural models and geological-geotechnical maps to assist pavement projects in the state of Ceará is of paramount importance in optimizing and enhancing pavement design accuracy. Currently, there is a clear need for more advanced and specific tools to address the geotechnical challenges. Through advancements in the use of artificial neural networks in recent times, it has been possible to optimize geological-geotechnical characterization studies of pavements, offering an innovative approach to understanding the geotechnical properties of materials used in the foundation and layers of pavements. Neural modeling, when there is availability of adequate quantity and quality of data, enables the prediction of a variety of soil geotechnical characteristics, potentially offering a more economical and complementary estimation option compared to the traditional acquisition of data solely through laboratory tests of CBR (California Bearing Ratio) or ISC (Index of Soil Compaction) and Resilience Modulus (MR) necessary for pavement design. The main objective of this dissertation was to develop neural models through the use of artificial intelligence and geological-geotechnical maps to be applied to pavement projects in the State of Ceará. To achieve this, databases containing geotechnical information on pavements in the State of Ceará were compiled. In total, the databases contain more than eight thousand data points covering soil physical properties, CBR, and AASHTO (American Association of State Highway and Transportation Officials) classification information. All this data originates from a project of the Federal University in partnership with the DNIT (National Department of Infrastructure and Transportation). Through the use of Artificial Neural Networks (ANNs), neural models were developed to predict CBR and MR values, with most of these models achieving correlation values above 0.7, suggesting a significant relationship between the variables used to estimate CBR and MR. The best model developed for CBR had a correlation value of 0.98 in validation, while for MR, the most representative model had a value of 0.86. This highlights the promising ease and applicability of neural models in predicting CBR and MR for empirical and empirical-mechanistic pavement design. Through geological-geotechnical maps, it was possible to obtain a view of the geotechnical properties and distribution of geological elements in the analyzed sections, allowing for a closer approach to the selection of materials and construction techniques.

**Keywords:** artificial neural networks; geological-geotechnical maps; resilience module.

## LISTA DE FIGURAS

Figura 1	– Representação das camadas de Pavimento Rígido .....	27
Figura 2	– Representação das camadas de Pavimento Flexível .....	27
Figura 3	– Esquema representativo de tensões, deslocamentos e deformações em pontos do pavimento asfáltico .....	32
Figura 4	– Fluxograma básico de um método mecanístico-empírico de dimensionamento de pavimentos .....	33
Figura 5	– Tensões impostas no ensaio triaxial .....	37
Figura 6	– Análise gráfica do comportamento de diferentes deformações permanentes .....	42
Figura 7	– Exemplo de neurônio biológico .....	45
Figura 8	– Modelo não linear do neurônio na RNA .....	46
Figura 9	– Rede alimentada com camada única .....	48
Figura 10	– Rede neural de múltiplas camadas .....	50
Figura 11	– Localização do estado do Ceará no Brasil .....	54
Figura 12	– Fluxograma dos modelos de MR e CBR .....	60
Figura 13	– Parte das informações dos solos estruturadas em planilha eletrônica .....	61
Figura 14	– Mapa de pontos geotécnicos georreferenciados .....	63
Figura 15	– Mapa com os pontos analisados na modelagem de MR .....	65
Figura 16	– Mapa com os trechos BR 116, BR 222 usados na modelagem de CBR .....	67
Figura 17	– Histograma de todos os dados de CBR .....	76
Figura 18	– Histograma para os trechos da BR 116 e 222 .....	76
Figura 19	– Comparação dos valores máximo e mínimo, média, desvio padrão do modelo para os trechos da BR 116 /222 e o banco de dados com 8281 amostras .....	77

Figura 20	– Gráfico das classificações AASTHO dos dados de CBR .....	78
Figura 21	– Evolução das correlações com número de iterações na fase de treinamento e validação do modelo C3 .....	81
Figura 22	– Comparação do treinamento e validação do melhor modelo de CBR (C3) .	81
Figura 23	– Percentual de contribuição das variáveis para o modelo de CBR .....	82
Figura 24	– Histograma de todos os dados de MR .....	83
Figura 25	– Classificações AASTHO dos dados de MR .....	83
Figura 26	– Comparação do treinamento e validação do modelo M1 .....	85
Figura 27	– Percentual de contribuição das variáveis de entrada do modelo M1 .....	85
Figura 28	– Comparação do treinamento e validação do modelo M2 .....	86
Figura 29	– Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura .....	87
Figura 30	– Percentual de contribuição das variáveis de entrada do modelo M2 .....	87
Figura 31	– Comparação do treinamento e validação do modelo M3 .....	88
Figura 32	– Percentual de contribuição das variáveis de entrada do modelo M3 .....	88
Figura 33	– Comparação do treinamento e validação do modelo M4 .....	89
Figura 34	– Percentual de contribuição das variáveis de entrada do modelo M4 .....	89
Figura 35	– Comparação do treinamento e validação do modelo M5 .....	90
Figura 36	– Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura .....	90
Figura 37	– Percentual de contribuição das variáveis de entrada do modelo M5 .....	91
Figura 38	– Comparação do treinamento e validação do modelo M6 .....	92
Figura 39	– Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura .....	92
Figura 40	– Percentual de contribuição das variáveis de entrada do modelo M6 .....	93
Figura 41	– Histograma dos valores de correlação para cada modelo de MR e CBR .....	93

Figura 42	– Distribuição dos pontos de CBR nas rodovias BR 116 e BR 222 no Estado do Ceará .....	95
Figura 43	– Mapa dos pontos de CBR distribuídos na Região Metropolitana de Fortaleza (RMF) .....	96
Figura 44	– Mapa dos pontos de CBR distribuídos nas regiões do Jaguaribe e Centro-Sul Cearense .....	97
Figura 45	– Mapa com valores de MR distribuídos na RMF (Valores em MPa) .....	99
Figura 46	– Mapa com valores de MR distribuídos na região do Jaguaribe e Centro-Sul Cearense (Valores em Mpa) .....	100
Figura 47	– Fluxograma da aplicação dos modelos neurais de MR .....	102
Figura 48	– Fluxograma da aplicação dos mapas geológico-geotécnicos .....	103
Figura 49	– Mapeamento geológico-geotécnico da Região Metropolitana do Cariri (RMC) .....	104
Figura 50	– Mapeamento geológico-geotécnico da Região Metrop. de Fortaleza (RMF) .....	104
Figura 51	– Fluxograma do Estudo de viabilidade .....	105
Figura 52	– Fluxograma do Projeto Básico .....	106
Figura 53	– Fluxograma do Projeto executivo e requalificação .....	107

## LISTA DE QUADROS

Quadro 1	– Distribuição dos documentos analisados por programa de pós-graduação .....	29
Quadro 2	– População brasileira por situação em domicílio em 2003 .....	70
Quadro 3	– Exemplo da Numerização de dados alfanuméricos para o MR .....	70
Quadro 4	– Valores máximos e mínimos das variáveis envolvidas na modelagem com utilização das redes neurais artificiais para CBR .....	71
Quadro 5	– Valores máximos e mínimos das variáveis envolvidas na modelagem com utilização das redes neurais artificiais para MR .....	71
Quadro 6	– Exemplo de normalização dos dados de MR .....	72
Quadro 7	– Exemplo de normalização dos dados de CBR .....	73
Quadro 8	– Contagem dos dados da classificação AASHTO/TRB/HRB .....	79
Quadro 9	– Distribuição dos dados em cada modelo de CBR .....	80
Quadro 10	– Valores das correlações de acordo com cada modelo de CBR .....	81
Quadro 11	– Valores das correlações de acordo com cada modelo de MR .....	84
Quadro 12	– Dados de entrada de cada modelo de MR .....	84

## LISTA DE ABREVIATURAS E SIGLAS

AASHTO	American Association of State Highway and Transportation Officials
CBR	Instituto Brasileiro de Geografia e Estatística
CPRM	Atual Serviço Geológico do Brasil
DNER	Departamento Nacional de Estradas de Rodagem
DNIT	Departamento Nacional de Infraestrutura de Transportes
DP	Deformação Permanente
EXP	Expansão
FHWA	Federal Highway Administration
FUNCEME	Funceme - Fundação Cearense de Meteorologia e Recursos
IPECE	Instituto de Pesquisa e Estratégia Econômica do Ceará
IP	Índice de Plasticidade
ISC	Índice de suporte Califórnia
KPa	Kilopascal
LL	Limite de liquidez
MCT	Miniatura, Compactado, Tropical
MeDiNa	Método de Dimensionamento Nacional de Pavimentos
MR	Módulo de Resiliência
NCHRP	National Cooperative Highway Research Program
RMF	Região metropolitana de Fortaleza
RNA	Redes neurais artificiais
SIG	Sistema de informações geográficas
SMA	Stone matrix asphalt
USACE	United States Army Corps of Engineers
UTM	Urchin tracking module

## LISTA DE SÍMBOLOS

$\alpha$	Constante momento
$A^B$	Parâmetros experimentais
$b_k$	Bias
$\text{Cov}(v_m, v_c)$	Covariância entre o valor medido e o valor calculado
$e_k$	Sinal de erro do neurônio $k$
$E_0$	Módulo tangente inicial
$\epsilon_r$	Deformação recuperável
$h_0$	Altura inicial do corpo de prova
$N$	Número de aplicações de carga
$\eta$	Taxa de aprendizagem
$R^2$	Coefficiente de correlação
$u_k$	Saída do combinador linear devido aos sinais de entrada
$v_k$	Campo local induzido
$w_{kj}$	Conjunto de sinapses ou elos de conexão
$X$	Variável a ser normalizada
$X'$	Variável resultante da normalização
$X_{MAX}$	Valor máximo da variável a ser normalizada
$X_{MIN}$	Valor mínimo da variável a ser normalizada
$x_j$	Sinais de entrada
$y_k$	Sinal de saída do neurônio
$\sigma_d$	Tensão desvio
$\sigma_1$	Tensão axial cíclica
$\sigma_3$	Tensão confinante
$\Delta h$	Deslocamento axial recuperável
$h_0$	Altura inicial do corpo de prova
$\Theta$	Tensão volumétrica ou primeiro invariante de tensão
$\epsilon_p$	Deformação específica plástica
$\varphi$	Função de ativação

$\sigma$	Função sigmóide
$E_{med}$	Gradiente do erro quadrático médio
$\{w_{kj}(n)\}$	Vetor de peso sináptico do neurônio $k$
$\{\Delta w_{kj}(n)\}$	Ajuste do vetor de peso sináptico $\{w_{kj}(n)\}$
$\delta_k$	Gradiente local do neurônio de saída $k$
$\delta_d$	Gradiente local no neurônio $y_k(i)$ no $i$ -ésimo exemplo do conjunto de treinamento
$\sigma(V_m)$ :	Desvio padrão dos valores medidos
$\sigma(V_c)$ :	Desvio padrão dos valores calculados

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	21
<b>1.1</b>	<b>Contextualização</b> .....	21
<b>1.2</b>	<b>Objetivos</b> .....	24
<i>1.2.1</i>	<i>Objetivo Geral</i> .....	24
<i>1.2.2</i>	<i>Objetivos Específicos</i> .....	24
<b>1.3</b>	<b>Estrutura de trabalho</b> .....	25
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	26
<b>2.1</b>	<b>Pavimentos</b> .....	26
<i>2.1.2</i>	<i>Revestimentos asfálticos</i> .....	27
<i>2.1.3</i>	<i>Subcamadas dos pavimentos</i> .....	28
<i>2.1.4</i>	<i>Projeto de pavimentos</i> .....	30
<i>2.1.5</i>	<i>Dimensionamento mecanístico-empírico</i> .....	31
<i>2.1.6</i>	<i>Ensaio para camadas granulares</i> .....	34
<i>2.1.6.1</i>	<i>Ensaio CBR</i> .....	34
<i>2.1.6.2</i>	<i>Módulo de Resiliência</i> .....	35
<i>2.1.6.3</i>	<i>Relação entre módulo de resiliência e outros parâmetros</i> .....	37
<i>2.1.6.4</i>	<i>Deformação permanente</i> .....	40
<b>2.2</b>	<b>Redes neurais artificiais</b> .....	44
<i>2.2.1</i>	<i>O neurônio biológico</i> .....	44
<i>2.2.2</i>	<i>Neurônio artificial</i> .....	46
<i>2.2.3</i>	<i>Arquitetura de rede</i> .....	48
<i>2.2.4</i>	<i>Perceptron multicamadas</i> .....	50
<i>2.2.5</i>	<i>Treinamento e validação</i> .....	51
<i>2.2.6</i>	<i>Aplicações do RNA em geotecnia</i> .....	52
<b>3</b>	<b>CARACTERIZAÇÃO DA ÁREA ESTUDO</b> .....	54
<b>3.1</b>	<b>Localização</b> .....	54
<b>3.2</b>	<b>Caracterização Pedológica do Ceará</b> .....	55
<b>3.3</b>	<b>Caracterização Geológica do Ceará</b> .....	57
<b>4</b>	<b>METODOLOGIA</b> .....	58
<b>4.1</b>	<b>Dados Utilizados</b> .....	60
<i>4.1.2</i>	<i>Modelo CBR</i> .....	66

4.1.3	<i>Modelo MR</i> .....	68
4.2	<b>Modelagem</b> .....	68
4.3	<b>Mapas Geologico-geotécnicos</b> .....	73
5	<b>RESULTADOS E DISCUSSÕES</b> .....	75
5.1	<b>Modelagem para o CBR</b> .....	75
5.1.2	<i>Modelos neurais</i> .....	79
5.2	<b>Modelagem para o MR</b> .....	82
5.2.1	<i>Modelos neurais</i> .....	84
5.2.2	<i>Modelo M1</i> .....	84
5.2.3	<i>Modelo M2</i> .....	86
5.2.4	<i>Modelo M3</i> .....	87
5.2.5	<i>Modelo M4</i> .....	88
5.2.6	<i>Modelo M5</i> .....	89
5.2.7	<i>Modelo M6</i> .....	91
5.3	<b>Mapas geológico-geotécnicos para o Estado do Ceará</b> .....	94
5.4	<b>Diretrizes e recomendações para implementação dos modelos de MR e mapas geológico-geotécnicos no Estado do Ceará</b> .....	101
5.4.1	<i>Estudo de viabilidade</i> .....	103
5.4.2	<i>Projeto básico</i> .....	106
5.4.3	<i>Projeto executivo</i> .....	106
5.4.4	<i>Projeto de requalificação</i> .....	107
5.4.5	<i>Considerações finais</i> .....	108
6	<b>CONCLUSÕES E SUGESTÕES DE PESQUISAS FUTURAS</b> .....	109
6.1	<b>Principal conclusão</b> .....	109
6.2	<b>Principais constatações para os modelos criados de CBR</b> .....	110
6.3	<b>Principais constatações para os modelos criados de MR</b> .....	111
6.4	<b>Constatações quanto às aplicações de mapas geológico-geotécnicos na área rodoviária</b> .....	112
6.5	<b>Sugestões para pesquisas futuras</b> .....	113
	<b>REFERÊNCIAS</b> .....	117
	<b>APÊNDICE A - VALORES DE PESOS SINÁPTICOS E BIAS DO MODELO DE CBR</b> .....	128

<b>APÊNDICE B - VALORES DE PESOS SINÁPTICOS E BIAS DOS MODELOS DE MR .....</b>	<b>134</b>
--	------------

# 1 INTRODUÇÃO

## 1.1 Contextualização

Durante a história do desenvolvimento da humanidade o solo tem sido matéria-prima em grande parte das obras civis, por isso, muitos são os processos testados para melhorar as propriedades físicas e mecânicas dos solos, tanto para construção de edificações quanto para a construção de vias de transporte (Muñeton, 2013). A aplicação do conhecimento geológico, ao caracterizar de maneira específica os materiais presentes nos solos e rochas, desempenha um papel fundamental no planejamento e na elaboração de projetos. Essa abordagem visa otimizar a utilização do meio físico, assegurando que os projetos sejam concebidos de maneira sustentável, evitando práticas predatórias ou impactos agressivos ao meio ambiente (Lima, 2022). Em função da geologia estrutural, da litologia, das características mineralógicas das rochas e da alterabilidade minerais pode-se projetar o aproveitamento dos mesmos nas construções rodoviárias bem como inferir problemas decorrentes de seu uso (Werneck, 2006).

Aprimorar ou modificar as condições naturais do solo para adaptação das necessidades de projetos de construções tem sido uma prática antiga, que muitas vezes resulta em redução de custos e outros benefícios tangíveis. Atualmente existem várias técnicas de melhoramento do solo abrangendo tratamentos rasos, médios e profundos do solo envolvendo drenagem, reforço, voltados a geotecnia, dependendo da construção e necessidades do projeto (Correia *et al.*, 2016).

A geotecnia possui um dos papéis mais importantes nas fases iniciais de planejamento e projeto de infraestruturas de transportes, tendo em vista seu impacto no custo, durabilidade e desempenho da estrutura (Patel e Desai, 2010). Países em desenvolvimento, como Brasil e Índia, no qual a grande parte do escoamento da produção e transporte de pessoas é realizado através das rodovias, esse impacto é ainda mais significativo (Alves e Santarem, 2015; India, 2018).

A maior parte das rodovias brasileiras possuem revestimento asfáltico e estão assentes sobre o subleito (terreno natural) e, em geral, camadas que têm como principal componente o solo compactado (sub-base; base ou reforço do subleito). A geotecnia é necessária para além da fundação, as camadas de base e de sub-base constituídas por geomateriais, majoritariamente agregado britado de granulometria extensa, naturais ou reciclados, no qual o comportamento está sujeito as suas características intrínsecas

(propriedades geométricas, físicas, mecânicas e químicas) e das condições de estado (compacidade e teor em água) (Correia *et al.*, 2021). A valorização da geotecnia nas várias fases de estruturação, projeto, construção e operação das infraestruturas de transporte é de grande contribuição para a sustentabilidade geral das obras, ao demonstrar as escolhas mais adequadas em cada uma dessas fases do ponto de vista técnico, econômico, social e ambiental (Correia *et al.*, 2016). Assim, os aspectos geológico-geotécnicos e atividades relacionadas são de fundamental importância desde o início de seu planejamento e etapas de projeto para alcançar um desenvolvimento sustentável geral em projetos de construção de pavimentos, de tal forma que possam ser satisfeitas as necessidades básicas, o uso de recursos de forma eficiente e a preservação dos ecossistemas (FHWA, 2014).

A necessidade da determinação do valor de suporte de um solo advém da importância do dimensionamento das camadas constituintes de um pavimento, desse modo, há uma diversidade de estudos que questionam a eficácia do método CBR (California Bearing Ratio) apontando suas limitações (Souza, 2007). Há muito tempo, o desempenho mecânico dos pavimentos tem sido avaliado em função do CBR, recomendado por normas vigentes brasileiras. Apesar de décadas de calibragem fundamentado em um banco de dados robusto, esse ensaio não é capaz de presumir com clareza os efeitos causados na estrutura (Franco, 2007). Entre as deficiências desse ensaio ressalta-se que, o CBR não representa o efeito real das cargas no pavimento, uma vez que não considera as tensões de confinamento e não leva em consideração a aplicação dinâmica das cargas, ocasionada pelos veículos em movimento (Nguyen *et al.*, 2016). Além disso, esse método também não acompanha os avanços ocorridos na caracterização de materiais e apesar da relevância que desempenhou em seu início até os dias atuais, percebe-se que novos parâmetros e análises devem ser adotados a fim de adequação à realidade rodoviária brasileira (Motta, 1991; Franco, 2007; Soares, Motta, 2009).

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

Em projetos de pavimentos, é essencial conhecer o comportamento dos solos quando submetidos ao carregamento do tráfego local, sendo o MR (Módulo de Resiliência) um dos parâmetros mais importantes a serem determinados quando o dimensionamento é

mecanístico-empírico (Ribeiro *et al.*, 2016), além da deformação permanente (DP). Na prática, no Brasil o pavimento ainda é dimensionado empiricamente. Porém, busca-se uma metodologia de dimensionamento que utilize os recursos disponíveis para desenvolver modelos que possam auxiliar nas análises dos pavimentos. Segundo Santos *et al.* (2020), essas novas necessidades constitui o princípio base da abordagem mecanístico-empírica, adotada atualmente por grande parcela dos órgãos rodoviários ao redor do mundo para o dimensionamento de pavimentos flexíveis.

Os procedimentos de dimensionamento mecanístico-empírico permitem a utilização de uma forma mais racional dos materiais que irão compor o pavimento comparado aos métodos que se baseiam apenas em parâmetros empíricos conforme relatado em Ferreira (2008). Alguns autores avaliaram as vantagens da utilização de métodos mecanístico-empíricos que partem da medida do Módulo de Resiliência (MR) em substituição ao CBR para dimensionamento de pavimentos (Uzan, 1985; Carvalho e Schwartz, 2000; Mashayekhi *et al.*, 2011). Entretanto, esses estudos também demonstraram que o dimensionamento com métodos empíricos pode resultar em estruturas mais robustas do que o necessário, ou seja, ocorrendo um superdimensionamento das mesmas a depender do tipo de tráfego que vai solicitar a estrutura.

Apesar da utilização do MR apresentar diversos ganhos ao dimensionamento de pavimentos, em alguns casos, esse método pode apresentar algumas desvantagens, entre os quais destacam-se: limitação de um banco de dados de projeto surge uma vez que a maioria dos estudos são realizados em escala de laboratório; necessidade de maior conhecimento dos técnicos para a realização dos ensaios, normalmente com equipamentos que são onerosos com disponibilidade limitada (Sas *et al.*, 2015; Mehrpazhouh *et al.*, 2019). Ensaios que são mais usuais, como o CBR, possuem maior facilidade de serem realizados em maior quantidade de laboratórios, justamente por serem testes mais simples. Para a realização do ensaio do módulo de resiliência são necessários câmaras destinadas ao ensaio triaxial de cargas repetidas que consistem em um aparato relativamente sofisticado, o que dificulta, ou até mesmo inviabiliza, o seu deslocamento e a sua utilização fora de locais adequados (Ribeiro, 2016).

No Brasil, não há uma grande quantidade de equipamentos triaxiais de carga repetida e uma parte considerável está disponível apenas em universidades. Tendo em vista os fatores apresentados e a necessidade de estimativas de MR para dimensionamento mecanísticos-empíricos, uma alternativa é o uso de modelos de Redes Neurais Artificiais (RNA). As RNA's são técnicas, amplamente utilizadas para solução de problemas não lineares e que se aplicam para diversas áreas do conhecimento, inclusive a engenharia de rodoviária, com resultados satisfatórios. (Celeste *et al.*, 2019).

Estudos realizados por Ferreira (2008) aplicando técnicas de Data Mining e RNA para predição do Módulo de Resiliência de solos estabilizados e britas a partir de parâmetros geotécnicos simples apresentaram resultados promissores. Foi utilizado um banco de dados existente no laboratório de pavimentação da COPPE-UFRJ. Os resultados desta investigação revelaram-se altamente encorajadores, com r-quadrados da ordem de 0,90. Outros estudos realizados também usaram as redes neurais para estimar valores do módulo de resiliência com bons resultados (Castro, 1998; Honarmand-Ebrahimi, 2006; Tarawneh; Nazzal, 2014).

Inclusive no Ceará desde 2016, vêm sendo desenvolvido modelos para os solos locais (Ribeiro, 2016), mostrando a viabilidade e eficácia das redes neurais para estimativa de valores de módulo de resiliência. Tendo em vista trabalhos com essa perspectiva, enfatizar a importância de citar e criar outros estudos além dos citados anteriormente é essencial para fornecer uma visão abrangente e atualizada para projetos de pavimentos no Estado do Ceará.

Esta dissertação pretende contribuir para o estudo do comportamento mecânico dos solos no Estado do Ceará, por meio de estimativas de MR e CBR, bem como elaboração de mapas geológico-geotécnicos. Para tal, utilizou-se como ferramenta principal as RNA's, que possibilitou realizar estimativas de MR e CBR, a partir de resultados de ensaios básicos, de tal forma que se possa contribuir para facilitar a utilização de métodos de dimensionamento mecanístico-empírico de pavimentos, além de ser uma alternativa para reduzir custos e tempo de operação com ensaios mais complexos.

## **1.2 OBJETIVOS**

### **1.2.1 Objetivo Geral**

Desenvolver modelos neurais e mapas geológicos-geotécnicos para aplicações em projetos de pavimentos no Estado do Ceará.

### **1.2.2 Objetivos Específicos**

- Analisar os bancos de dados de caracterização geotécnica de diversos solos do Estado do Ceará
- Elaborar modelos utilizando RNA de previsão de CBR para trechos das rodovias

- Elaborar modelos utilizando RNA de previsão de MR
- Identificar e definir os melhores modelos neurais para aplicações em projetos de pavimentos no Estado do Ceará
- Desenvolver mapas geológico-geotécnico para projetos de pavimentos no Estado do Ceará
- Apresentar diretrizes e recomendações para aplicação de mapas geológico-geotécnicos e modelos neurais para projetos de pavimentos no Estado do Ceará.

### **1.3 Estrutura do trabalho**

Este trabalho foi dividido em seis capítulos, no primeiro capítulo são apresentados: introdução com o contexto geral do trabalho, objetivos e justificativas motivadoras da pesquisa. O Capítulo 2 corresponde a uma revisão de literatura acerca de tópicos importantes que guiaram este trabalho, sendo em sequência: pavimentos, revestimentos asfálticos, subcamadas dos pavimentos, projeto de pavimentos, dimensionamento mecanístico-empírico, ensaios para camadas granulares, ensaio CBR, módulo de resiliência, deformação permanente e redes neurais artificiais. No Capítulo 3 é realizada a caracterização da área de estudo do trabalho. O Capítulo 4 descreve a metodologia detalhadamente todas as fases do desenvolvimento do estudo. Cada modelo estudado é caracterizado, e todas as hipóteses empregadas são apresentadas.

No Capítulo 5 apresentam-se os resultados obtidos para os modelos de previsão de CBR e MR. No Capítulo 6 são indicadas as conclusões e sugestões para futuros trabalhos. O Apêndice A contém os pesos sinápticos e bias para o modelo de maior correlação de CBR e o QR CODE para acesso online da planilha com os dados detalhados. O Apêndice B apresenta os pesos sinápticos e bias para cada modelo de MR, assim como o QR CODE para acesso online da planilha com os dados detalhados.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, são abordados os elementos mais significativos relacionados ao tema da pesquisa, visando consolidar uma base teórica que contribua para o desenvolvimento da metodologia, a análise dos resultados e as conclusões finais do trabalho.

### 2.1 Pavimentos

O pavimento é uma superestrutura constituída por um conjunto de camadas de espessuras finitas, assente sobre um semiespaço considerado em teoria infinito, a infraestrutura ou terreno de fundação, a qual é denominado de subleito (Dnit, 2006). Dessa forma, a estrutura precisa cumprir alguns critérios, tais como:

- a. Suportar e distribuir ao terreno de fundação tensões causadas pelo tráfego
- b. Facilitar a qualidade de rolamento para melhor comodidade e conforto dos usuários;
- c. Tolerar os esforços horizontais (desgaste), permitindo maior durabilidade da capa de rolamento.

Para Bernucci *et al.* (2022), o pavimento é uma estrutura, destinada técnica e economicamente a resistir aos esforços oriundos do tráfego de veículos e ao clima e a propiciar aos usuários melhoria nas condições de rolamento, com conforto, economia e segurança.

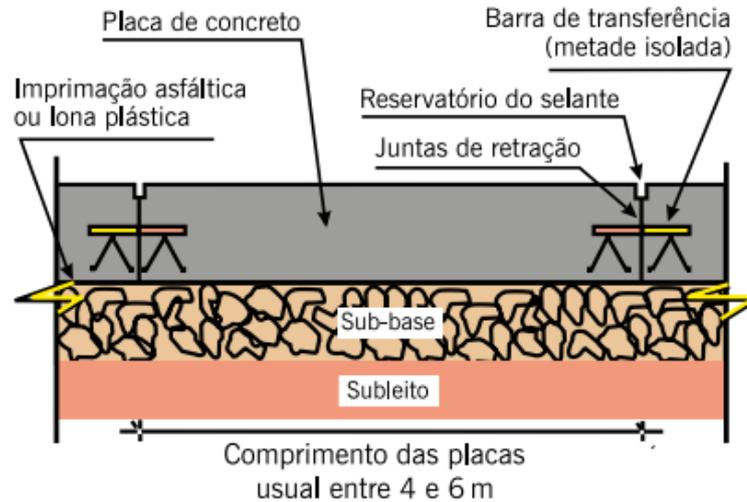
Os pavimentos rodoviários geralmente são categorizados em rígidos e flexíveis. Os pavimentos rígidos têm revestimento de concreto de cimento Portland e os flexíveis revestimentos de concreto de cimento asfáltico de petróleo (Silva, 2012). Um pavimento flexível sob carregamento apresenta um campo de tensões concentrado enquanto um pavimento rígido apresenta um campo bem mais disperso, com as tensões distribuídas em uma área maior (Balbo, 2007; Papagianakis; Masad, 2007).

Os pavimentos asfálticos são comumente constituídos por quatro camadas principais: revestimento asfáltico, base, sub-base e reforço do subleito. Entretanto, algumas dessas camadas podem ser suprimidas em função do tráfego constante e da disposição de materiais na região (Silva *et al.*, 2013).

O revestimento impermeabiliza e proporciona o acabamento final melhorando o conforto e a resistência à derrapagem. A base diminui as tensões nas camadas inferiores distribuindo-as, além de conceder a drenagem da água que penetra (por meio de drenos) e resistir às deformações. A sub-base tem as mesmas funções da base e a complementa, reduz a espessura e promove economia. As camadas da estrutura repousam sobre o subleito, ou seja, a plataforma da estrada terminada após a conclusão dos serviços de cortes e aterros (Rocha,

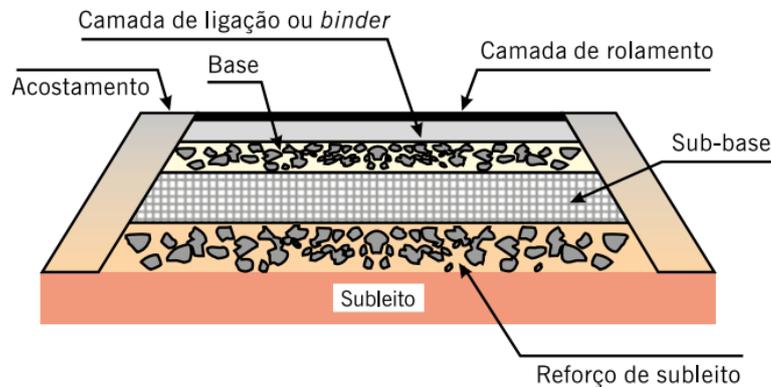
2004). A Figura 1 mostra as camadas dos pavimentos rígidos e a Figura 2 mostra as camadas dos pavimentos flexíveis.

Figura 1 - Representação das camadas do Pavimento Rígido



Fonte: Bernucci *et al.* 2022

Figura 2 - Representação das camadas de Pavimento Flexível



Fonte: Bernucci *et al.* 2022

### 2.1.2 Revestimentos Asfálticos

As soluções utilizadas para a construção do revestimento asfáltico são diversificadas, entre os quais são importantes citar: asfalto - borracha, stone matrix asphalt (SMA), lama asfáltica, concreto asfáltico usinado a quente (CAUQ), etc. Essas soluções são usadas em função do clima, tráfego e durabilidade esperada da estrada. O asfalto-borracha é conhecido por sua resistência a altas temperaturas, enquanto o SMA destaca-se pela capacidade

de suportar cargas pesadas. Já a lama asfáltica, apesar de ser uma alternativa mais econômica, pode demandar maior manutenção ao longo do tempo. O CAUQ é preferido em locais com tráfego intenso devido à sua durabilidade. Em síntese, a escolha dessas soluções é baseada em critérios técnicos que visam garantir a eficiência e longevidade das vias Bernucci (2008).

O asfalto borracaha consiste na mistura de borracha de pneus triturada em misturas asfálticas (Silva, 2005). O SMA é um revestimento asfáltico, usinado a quente, concebido para potencializar o contato entre os agregados graúdos, aumentando o contato grão a grão. As lamas asfálticas seriam constituídas sobretudo por uma associação, em consistência fluida, de agregados minerais, material de enchimento ou filer, emulsão asfáltica e água. O CAUQ é um produto da mistura de agregados de tamanhos variados e cimento asfáltico, ambos aquecidos em temperaturas determinadas, em função da característica viscosidade-temperatura do ligante (Bernucci, 2008).

### **2.1.3 Subcamadas dos Pavimentos**

Os materiais granulares podem ser usados em subcamadas dos pavimentos e são aqueles que não possuem coesão e que não resistem à tração, trabalha eminentemente aos esforços de compressão. Os materiais mais empregados são: brita graduada simples (BGS), brita corrida, macadame hidráulico, macadame a seco, misturas estabilizadas granulometricamente, solo natural, solo agregado, solo melhorado com cimento e solo melhorado com cal (Bernucci, 2006). Esses materiais são amplamente utilizados em camadas de pavimentos em razão de sua eficiência.

O comportamento do solo granular tem uma grande relevância para a engenharia geotécnica e têm sido estudados ao longo dos últimos anos, com o objetivo de compreender as características que este tipo de solo apresenta sob as diversas condições de carregamento (Neves, 2009). Por estarem sempre expostas a grandes cargas essas camadas devem possuir em suas composições materiais que apresentem boas características mecânicas podendo resistir às cargas sem apresentar deformação considerável que prejudique o pavimento (DNIT, 2006).

Para determinar se o material granular é adequado para a utilização de base e da sub-base de pavimentos, geralmente é usado o critério do DNIT (2010a, 2010b, 2010c, 2022), como representado no Quadro 1, o qual estabelece que para a camada de base, o CBR deverá ser maior ou igual a 80% e a expansão menor ou igual a 0,5%; e para a camada de sub-base, o CBR deverá ser maior ou igual a 20% e a expansão menor ou igual a 1%.

Quadro 1 - Caracterização de material para camada granular

<b>Camada</b>	<b>Expansão (%)</b>	<b>CBR (%)</b>
<b>Base</b>	$\leq 0,5$	$\geq 80$
<b>Sub-base</b>	$\leq 1$	$\geq 20$

Fonte: Adaptado DNIT, 2010a, 2010b, 2022; 2010c

As sub-bases granulares são elementos estruturais do pavimento cuja finalidade é distribuir as cargas oriundas do tráfego. Para satisfazer este propósito, devem ser construídas sub-bases com propriedades de resistência necessárias (Montejo, 1998). Além de solos in natura, há uma grande quantidade de trabalhos que mostram que camadas granulares podem ser constituídas ou reforçadas com materiais reciclados ou resíduos industriais. Dentre esses materiais pode-se citar aqueles que já foram testados para o caso do Estado do Ceará: escórias de aciaria, cinzas volantes, resíduos de diversas origens, bem como: da construção e demolição, indústria petrolífera, termelétrica, siderúrgico, refinaria, ambientais.

Na pesquisa realizada por Barros (2013) mostrou-se que a mistura 95% cinza e 5% cal obteve ótimos resultados de módulo de resiliência e tensões verticais 15% menores do que estruturas com base BGS, evitando deformações permanentes. Oliveira (2016) mostrou que resíduos da Pedra Cariri (rocha sedimentar composta principalmente por calcário encontrada na região do Cariri, Estado do Ceará) foram viáveis tecnicamente e economicamente para construção de camadas granulares dos pavimentos com CBR de 60% e expansão de 0,02%, podendo ser usado em camadas de base de rodovias de baixo volume de tráfego. Santos (2021) realizou a reciclagem de materiais fresados em camadas granulares de base e sub-base de pavimentos e observou que o emprego desses materiais proporcionou maior durabilidade e desempenho das estruturas, além de ser uma alternativa mais econômica.

Os maiores problemas em subcamadas de pavimentos asfálticos ocorrem principalmente quando a compactação desejável para a camada não é obtida em todo o maciço de solo, ocasionando em defeitos que aparecem, por vezes, decorridos muito tempo após a construção. Entre os principais defeitos, podem-se citar as deformações permanentes excessivas, que originam a trilha de roda, escorregamentos de saia de aterro e erosão rápida por conta da ação das chuvas. Devido esse motivo, o controle tecnológico de execução desses serviços precisa ser feito seguindo as especificações técnicas, com objetivo de fornecer uma obra de engenharia de boa qualidade, com maior segurança e economia ao usuário (Alves, 2002).

#### 2.1.4 Projeto de Pavimentos

Durante as primeiras décadas do século XX o projeto de pavimentos tinha como principal característica o caráter empírico, ou seja, fundamentado apenas em experiência dos projetistas (Silva *et al.*, 2013). Todavia, com o avanço da economia e seguido ao aumento do volume de tráfego e peso dos carregamentos, resultou na necessidade de melhorar a qualidade dos pavimentos, bem como o entendimento com relação ao seu comportamento mecânico. Assim, a tendência voltou-se para o uso dos métodos mecanísticos-empíricos nas diversas atividades envolvidas no projeto de pavimentos (Motta, 1991; Medina e Motta, 2005; Huang, 2004; NCHRP/TRB, 2004; Franco, 2007; Soares *et al.*, 2009).

Os pavimentos são projetados para determinado período de tempo ou “ciclo de vida”. Durante esse período, o pavimento inicia a sua vida em uma condição mais adequada até alcançar uma condição limite (Nakahara, 2005). Ao alcançar o limite de vida útil do pavimento, os defeitos relacionados à perda de propriedades físicas e químicas dos agregados e dos ligantes betuminosos são denominados defeitos de superfície (Rocha, 2010).

Segundo Nakahara (2005) em níveis de projeto, o desempenho é representado pelos defeitos e pelas perdas da serventia, da resistência à derrapagem e do estado geral devido ao tráfego. Já para nível de rede necessita-se de maior atenção nas medidas de condições gerais dos pavimentos e da rede de cada subdivisão geográfica, principalmente quando às medidas que refletem as necessidades atuais e futuras de investimentos e os efeitos nos custos aos usuários.

Na década de 1960 o método empírico de dimensionamento de pavimentos flexíveis do DNER foi elaborado pelo engenheiro Murillo Lopes de Souza, tendo como base algumas conclusões obtidas na pista experimental da AASTHO e a experiência do Corpo de Engenheiros do Exército dos Estados Unidos (Usace), por meio do trabalho de Turnbull, Foster e Ahlvin, que utiliza o ensaio de CBR, designado “Design of Flexible Pavements Considering Mixed Loads and Traffic Volume”, datado de 1962 (Souza, 1981; Dnit, 2006a; Medina; Motta, 2015).

O método CBR (California Bearing Ratio) é largamente utilizado no Brasil para projetos de dimensionamentos de pavimentos asfálticos orientados e normatizados tanto pelo DNIT (Departamento Nacional de Infraestrutura de Transportes) quanto pelos órgãos estaduais e municipais de infraestrutura responsável pela mobilidade rural e urbana. Porém, esse método tem se mostrado desatualizado e menos eficaz que outros métodos de dimensionamento de pavimentos já aplicados em larga escala em países norte-americanos por serem economicamente viáveis em relação ao método CBR (Rosstengel, 2021).

De acordo com Ferreira (2021) o método citado não atende às necessidades atuais, visto que não inclui as ações que variações climáticas podem causar no pavimento, nem as novas configurações de eixos dos veículos que circulam pelas estradas brasileiras e nem as características físicas de novos materiais utilizados na execução de rodovias. Já o novo método, mecanístico-empírico, foi formulado de forma a abranger todos esses déficits.

De acordo com Rosestengel (2021), desde 2018, foi proposta pelo DNIT a substituição desse método pelo MeDiNa (Método de Dimensionamento Nacional de Pavimentos). Isso ocorreu tendo em vista que, enquanto o MeDiNa adapta os cálculos para um determinado ambiente, o CBR obtém resultados com base em pavimentos dimensionados no estado americano da Califórnia em 1939. O problema fundamental reside no fato de que, ao invés de dimensionarem-se pavimentos adequados para o Brasil, que possui climas equatoriais, semiáridos, tropicais, subtropicais e temperados, são dimensionados pavimentos adequados para o estado temperado da Califórnia, nos EUA.

### **2.1.5 Dimensionamento Mecanístico-Empírico**

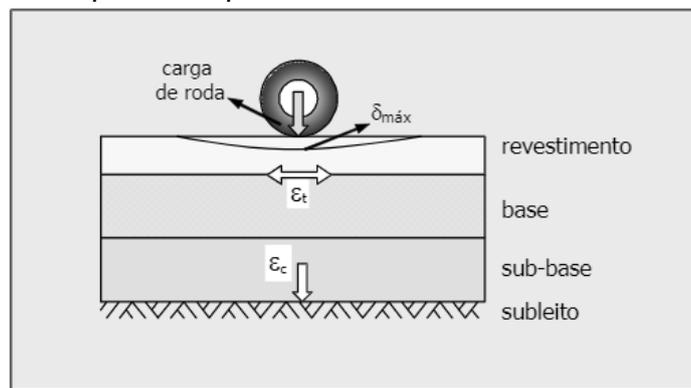
Em relação aos métodos mecanísticos, Franco (2007) afirma que esses estão relacionados ao enfoque das características estruturais do pavimento. O dimensionamento de um pavimento asfáltico denomina-se mecanístico quando adota uma teoria que prevê as tensões e deformações advindas do tráfego e do clima na estrutura, procurando compatibilizá-las com as resistências dos materiais empregados em sua execução (Bezerra, 2004; Senço 2007).

De acordo com Hartmann (2009), quando há a integração de um modelo estrutural para o pavimento, usando as chamadas “funções de transferência”, que correlacionam as respostas da estrutura frente às cargas do tráfego e ao surgimento e evolução de defeitos, conclui-se que se está em presença de um método mecanístico. Ao empregar esse tipo de observação tem-se uma ideia do aspecto funcional da estrutura quando solicitada, o que pode oferecer modificações quanto à natureza dos materiais constituintes, assim como quanto às espessuras das camadas (Morais, 2014).

O objetivo de um método de dimensionamento é proporcionar ao projetista meios para a determinação de uma estrutura adequada do pavimento (Santos, 2020). Mesmo que ainda hoje o empirismo exerça um importante papel no setor rodoviário, para Huang (2004), o dimensionamento de pavimentos, com o passar dos anos, saiu do campo da arte para o da ciência.

Nos métodos mecanísticos-empírico, os valores de tensão-deformação nos pavimentos são derivados por meio de simulações analíticas ou numéricas utilizando como dado de entrada as propriedades dos materiais obtidas em ensaios laboratoriais (Bastos, 2013). Esses métodos fazem uso de análises computacionais que possibilitam relacionar o comportamento estrutural dos materiais com o desempenho das soluções, ao longo do tempo (Santiago, 2017). No dimensionamento mecanístico-empírico, em geral, os pavimentos são considerados como um sistema de várias camadas elásticas, projetando a estrutura de forma que a repetição de esforços não cause, em curto prazo, a ruptura por fadiga dos materiais. A Figura 3 apresenta um exemplo de tensões no pavimento.

Figura 3 - Esquema representativo de tensões, deslocamentos e deformações em pontos do pavimento asfáltico



Fonte: Franco (2007)

A partir da caracterização da estrutura e dos materiais, aí incluídas as espessuras das camadas, os módulos de resiliência e os coeficientes de Poisson dos diversos materiais; e da formação do tráfego atuante, a resposta do pavimento pode ser deduzida através do cálculo das tensões, deformações e deslocamentos produzidos na estrutura. A teoria da elasticidade é amplamente usada como método para o cálculo dessas tensões, deformações e deslocamentos e os procedimentos atuais em uso para esse cálculo consideram os materiais de acordo com dois comportamentos tensão-deformação distintos, quais sejam: comportamento elástico linear e comportamento elástico-não linear (Franco, 2007).

Para Santiago (2017) considera-se o projeto estrutural dos pavimentos, tendo como base as propriedades mecânicas dos materiais constituintes. Tais propriedades, são os dados de entrada que serão analisados, na qual fornece a resposta estrutural do pavimento, i.e, tensões e deformações. Resultados dos ensaios de laboratório e desempenho em campo ligado a essas respostas são empregadas para previsão de falhas ao longo do período de projeto. Os dois

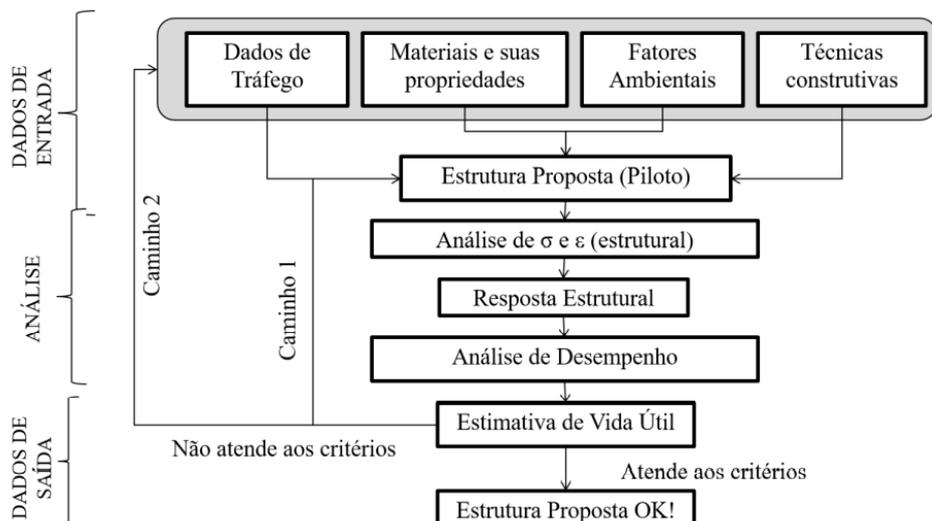
critérios de falha inicialmente utilizados nestes métodos mecânicos são a tensão de compressão vertical no topo do subleito e a tensão de tração horizontal na fibra inferior do revestimento, respectivamente, buscando reduzir as falhas quanto à deformação permanente e ao trincamento por fadiga.

Os dados de entrada necessários são: tráfego, ao qual o pavimento é submetido, condições ambientais da região, informações das camadas e seus materiais constituintes (módulo de resiliência, espessura, coeficiente de Poisson, curva de fadiga do material, entre outros) (Franco, 2007; Santiago *et al.*, 2018).

A Figura 4 representa o esquema principal da estrutura de um método mecânico-empírico, que precisam ser adaptadas as situações e condições específicas de um dado pavimento. Os dados de entrada são: (i) composição do tráfego, tão ou mais elaborada de acordo com a disponibilidade de informações na região; (ii) fatores climáticos, temperatura e pluviometria local; (iii) características dos materiais utilizados nas camadas do pavimento; (iv) consideração de técnicas construtivas disponíveis; (v) sugestão de uma estrutura inaugural de pavimento, que será testada.

De posse desses resultados iniciais submete-se uma estrutura de pavimento piloto a análise de tensões e deformações. Segundo Santiago (2015) os resultados dessa análise são utilizados como *inputs* em equações de desempenho, cujo propósito é prever o comportamento do pavimento, para defeitos pré-determinados, durante o período de projeto. O processo é cíclico, caso não esteja atendido os valores admissíveis para os defeitos, devendo ser redefinida uma nova estrutura de camadas, que será submetida a um novo processo de análise.

Figura 4 - Fluxograma básico de um método mecânico-empírico de dimensionamento de pavimentos



**Fonte:** MOTTA (1991) e HUANG (2004) *apud* Santiago (2017)

Para Santiago (2015) cada região ajusta essa estrutura geral às suas condições específicas e a quantidade e qualidade das informações históricas existentes com respeito ao comportamento dos materiais, do clima e do tráfego. Isso pode ser observado nos diferentes métodos de dimensionamento existentes. Por isso, inclui-se aqui a avaliação de métodos propostos em diferentes países. A ideia é verificar experiências bem-sucedidas à luz da realidade local.

Segundo Araújo (2019) após a inserção dos dados de entrada é realizado o estudo do sistema de camadas (elástica-linear, não linear, viscoelástica, entre outras). Essa análise pode ser realizada através de métodos analíticos ou numéricos, independente da técnica há vantagens e restrições. A metodologia de análise pode ser em duas etapas, quando tem-se uma resposta estrutural (tensões e deformações) e está servindo de dado de entrada para estudo de previsão de desempenho do pavimento ao longo de sua vida útil (dano sofrido ao longo do tempo). De acordo com os resultados de simulação do comportamento do material em campo, é possível avaliar a previsão de vida útil do pavimento, quanto aos defeitos considerados.

## **2.1.6 Ensaios para camadas granulares**

Para Balbo (2007), uma classificação adequada de solos seria aquela que visa relacionar a capacidade de um solo quanto a uma dada aplicação em camada de pavimento, o que depende não somente de testes de suas propriedades físicas, mas também de suas correlações com o comportamento observado em obras quando empregado.

### **2.1.6.1 Ensaio CBR**

De acordo com Marson (2004), nos EUA, na década de 20, por conta do crescimento da demanda de manutenção de malhas viárias e construções de grandes rodovias, surgiram novas pesquisas de avaliações do solo que resultaram no surgimento do ensaio Califórnia Bearing Ratio (CBR). No Brasil, a metodologia do ensaio é regida pela NBR 9895:2016 denominada “Solo – Índice de suporte Califórnia (ISC) – Método de ensaio” e pela DNIT 172/2016 – ME “Solos – Determinação do Índice de Suporte Califórnia utilizando amostras não trabalhadas. Ambas as normas possuem a mesma metodologia, entretanto, elas

diferenciam-se na quantidade de leituras das penetrações, mas, essa diferença de execução não afeta no resultado do ensaio.

O ensaio Índice Suporte California, ou California Bearing Ratio (CBR), busca simular no laboratório as condições de umidade, massa específica após a compactação e carregamento que acontecem em campo (Balbo, 2007). É amplamente realizado para avaliar o comportamento de solos e agregados, muito utilizado na análise de resistência de materiais granulares para pavimentos (Motta, 2005). Na prática, o ensaio de CBR mede a resistência à penetração de uma amostra saturada compactada segundo o método de Proctor, através de um pistão com 49,6 mm de diâmetro (Souza, 2007), em comparação a penetração de uma brita padrão.

#### **2.1.6.2 Módulo de Resiliência**

Em 1986 a AASHTO (American Association of State Highway and Transportation Officials), incorporou o módulo de resiliência (MR) como parâmetro para caracterizar os materiais geotécnicos dos pavimentos, em especial do sub-leito. Na atualidade, para qualquer procedimento de projeto ou análise mecânica, a utilização do módulo de resiliência ou MR, dos materiais constituintes da estrutura dos pavimentos é de vital importância (Klinsky *et al.*, 2014).

O desempenho de pavimentos depende das características do comportamento tensão-deformação dos materiais de cada camada bem como da frequência, da intensidade de tráfego e das condições ambientais e regionais. Em pavimentação, Francis Hveen, adotou ao invés do termo elasticidade, o termo resiliente, tendo em vista que as deformações rodoviárias são mais significativas do que de outros sólidos com quais a engenharia lida. (Rocha, 2020).

Conforme a teoria da elasticidade, tanto o MR quanto o módulo de elasticidade possuem o mesmo conceito, ambos são representados pela razão entre a tensão e a deformação. O que levou a diferenciação entre estes, foram as divergências entre a ordem de grandeza de deslocamentos dos materiais utilizados em pavimentação em relação aos materiais elásticos frequentemente utilizados na engenharia (Brito, 2006).

O módulo de elasticidade é o critério elástico que relaciona a carga aplicada a um certo material e sua deformação, representando a resistência intrínseca do material à deformação devida. Assume-se que toda a energia mecânica fornecida ao sistema é armazenada, tanto para a elasticidade linear, quanto não linear, ao se representar o comportamento do material elástico (Medina e Motta, 2015).

O módulo de resiliência pode ser determinado por meio de ensaios triaxiais de cargas repetidas, no qual, o principal objetivo é simular em laboratório as condições de carregamento impostas aos materiais devido ao tráfego (Maia, 2016). De acordo com a norma DNIT 134 (2010), os ensaios triaxiais são realizados em duas etapas de aplicação de cargas, uma etapa de condicionamento, cujo objetivo é eliminar as deformações plásticas que ocorrem nas primeiras aplicações do carregamento e reduzir o efeito do histórico de tensões, e a segunda etapa de ensaio propriamente dito, onde são medidos os deslocamentos resilientes sofridos pelos materiais em diferentes pares de tensão de confinamento e de carga vertical.

Pode-se definir o módulo de resiliência de um material pela relação entre a tensão desvio aplicado repetidamente e a deformação recuperável correspondente, como representado na Equação 1.

$$MR = \frac{\sigma d}{\epsilon_r} \quad (1)$$

Onde:

MR: O módulo de resiliência;

$\sigma d$ : A tensão desvio ( $\sigma_1 - \sigma_3$ );

$\sigma_1$ : Tensão axial cíclica;

$\sigma_3$ : Tensão de confinamento;

$\epsilon_r$ : Deformação recuperável que pode ser calculado conforme Equação 2

$$\epsilon_r = \frac{\Delta h}{h_0} \quad (2)$$

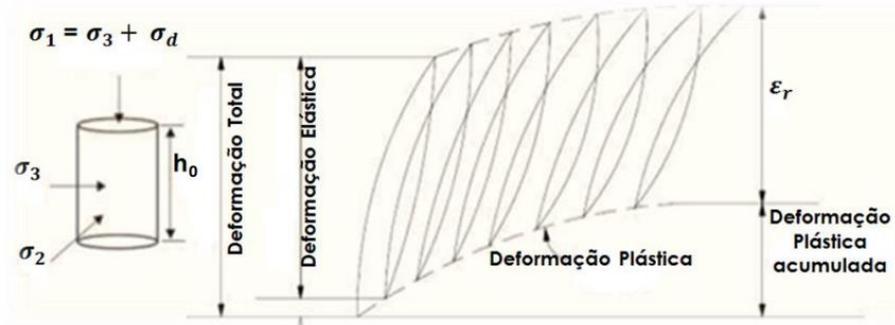
Onde

$\Delta h$ : Deslocamento axial recuperável

$h_0$ : Altura inicial do corpo de prova

Segundo Araújo (2019) as tensões que ocasionam as deformações nos pavimentos são causadas pelas cargas de veículos. Essas deformações são divididas em: recuperável e não recuperável. Após encerrada a ação das cargas a deformação elástica do pavimento, parcela resiliente, é recuperada rapidamente. Porém, parte dessa deformação é permanente, não recuperável, denominada deformação plástica, conforme Figura 5:

Figura 5 - Tensões impostas no ensaio triaxial



Fonte: Huang (2004)

O módulo de resiliência de solos é determinado de acordo com a norma do DNIT 134 (2018), pelo método da COPPE/UFRJ, ou ainda pelo método da AASHTO T 307-99 (2007). No país, ensaios de MR já vêm sendo realizados na COPPE/UFRJ desde a década de 1970. A sua primeira norma data de 1986 e foi produzida pelo Departamento Nacional de Estradas de Rodagem (DNER).

Essa versão teve atualizações, até a última revisão, em 2018. O procedimento estabelecido para o módulo de resiliência oferece dados de entrada para o programa MeDiNa (DNIT, 2018), assim possibilitando dimensionamento mecanístico-empírico de pavimentos asfálticos.

### 2.1.6.3 Relação entre Módulo de Resiliência e outros parâmetros

Em 1960, Heukelom e Foster apresentaram uma relação entre o módulo de resiliência e o CBR, índice de suporte Califórnia. Esta relação foi estabelecida de acordo com o estudo de solos turfosos, arenosos, argilosos, argila arenosa, argila pedregulhosa e macadame, materiais que são encontrados facilmente em bases e sub-leitos de rodovias. A correlação proposta está representada pela Equação 3.

$$M_R = 110 \times \text{CBR}$$

(3)

Onde:

$M_R$  = o módulo de resiliência expresso em  $\text{kgf/cm}^2$

CBR = representado em porcentagem.

Segundo Franzoi (1990) esta relação tem sido uma das mais utilizadas, entretanto a AASHTO só considera esta correlação razoável para solos finos com CBR menor ou igual a 10. Medina e Preussler (1980) propuseram uma nova relação entre módulo de resiliência e CBR. A relação é representada de acordo com a seguinte expressão:

$$M_R = 326 + 67 \times \text{CBR} \quad (4)$$

Onde:

$M_R$  = é o módulo de resiliência (kgf/cm<sup>2</sup>).

O coeficiente de correlação ou determinação ( $R^2$ ) obtido foi igual a 0,82. Esta relação foi proposta para um solo argiloso compactado e um MR determinado à tensão desvio de 2kgf/cm<sup>2</sup>. O CBR, foi definido para a amostra imersa na água por quatro dias e umidade de compactação igual ou superior à ótima.

Entretanto para Venson (2015) relacionar um índice empírico, CBR, com o módulo de resiliência parece não ser o mais adequado, tendo em vista, que, de um lado um índice empírico que não leva em consideração a variação do estado de tensões e do outro, uma propriedade mecânica elástica que, na maioria das vezes, depende do estado de tensões. É possível que o mais viável seja relacionar o módulo de resiliência com outra propriedade mecânica do solo associada às deformações, como, por exemplo, módulo tangente inicial, e também agrupar na relação uma ou mais tensões atuantes no solo. Conforme citado por Ruiz (1964) *apud* Parreira *et al.* (1998), o módulo tangente inicial, derivado de curvas de tensão em relação a deformação, está intimamente relacionado com o módulo dinâmico (Ruiz, 1964) ou com o módulo de descarregamento/re carregamento (Lade, 1974).

Parreira *et al.* (1998) realizaram um estudo, na Escola de Engenharia de São Carlos (EESC), com solos arenosos (em sua maioria A-2-4 e LA') provenientes dos Estados do Ceará, Paraíba, Piauí e São Paulo. Inclusive, foi desenvolvido uma relação que forneceu um  $R^2$  de 0,82. Ainda, na relação em questão, o módulo tangente inicial é aferido através do ensaio de compressão simples.

$$M_R = 0,848 \times E_o^{0,4559} + 1,1472 \times \Theta^{0,8630} \quad (5)$$

Onde:

$E_o$  = módulo tangente inicial (kPa)

$\Theta$  = tensão volumétrica (kPa)

De acordo com Venson (2015) há indícios na relação desta equação que apontam um caminho promissor para futuras relações do módulo de resiliência. Devido os materiais, empregados no desenvolvimento da relação, pertencerem à mesma faixa granulométrica (areia), terem comportamento laterítico (pela classificação MCT) e serem majoritários do grupo (A-2-4), impôs uma elevada seletividade no desenvolvimento da relação que favoreceu para aumentar o coeficiente de determinação. Foi possível observar duas consistências teóricas na estrutura da relação; a tensão volumétrica foi utilizada quando se trabalhou com materiais arenosos, corroborando com Hicks e Monismith (1971) e Uzan (1985); e duas propriedades mecânicas de natureza elástica foram relacionados (módulo de resiliência e módulo tangente inicial).

Em estudo conduzido por Junior (2005) foram realizadas pesquisas para investigar o efeito da variação da energia de compactação (intermediária, intermodificada e modificada) nas propriedades geotécnicas de pavimentação, dentre essas o MR. O estudo envolveu 494 jazidas de materiais granulares provenientes de 118 projetos rodoviários arquivados no DERT/CE, abrangendo todo o Estado do Ceará. Os resultados das análises de laboratório indicaram um aumento significativo nos valores de CBR com o aumento da energia de compactação. Por outro lado, os valores de MR não apresentaram variações relevantes quando sujeitos às diferentes energias de compactação investigadas.

Em pesquisa realizada por Cavalcante e Barroso (2011) foi realizado a investigação da possibilidade de utilizar o Solo Contaminado por Derivados de Petróleo (SCDP) em camadas granulares de pavimentos. O trabalho avaliou o módulo de resiliência das misturas estudadas por meio dos ensaios de Resistência à Compressão Simples (RCS) ao longo dos tempos de cura. A análise do ganho de resistência com o passar do tempo nas misturas estabilizadas com cal é um indicativo do comportamento resiliente desses materiais. Os resultados da estabilização química e granulométrica indicam que todas as misturas apresentam potencial para serem utilizadas em aplicações rodoviárias.

O estudo realizado por Fernandes *et al* (2019) avaliou o MR para camadas granulares, especificamente para a camada de base do pavimento utilizando misturas de cinza/cal. Foram realizados ensaios tanto em laboratório quanto in situ para determinar o MR e avaliar a rigidez da camada de base construída com essas misturas. O estudo relacionou o MR com outros parâmetros, como o estado de tensões, para estabelecer correlações entre os MRs determinados em laboratório e em campo. Foram utilizados modelos matemáticos e análises estatísticas para avaliar a relação entre os módulos medidos com diferentes equipamentos e métodos. Os resultados das comparações realizadas indicaram uma boa correlação entre o MR

obtido em laboratório e em campo, com coeficientes de correlação significativos e também ressaltou a importância de aumentar a quantidade de dados para uma análise mais robusta.

#### 2.1.6.4 Deformação Permanente

A deformação permanente (DP) é parte da deformação total que a camada sofre a cada solicitação de carga, que não volta à sua posição original, gerando, conseqüentemente, os deslocamentos não recuperáveis acumulados ao longo da vida útil do pavimento. Pode ocorrer deformação permanente quando o material é submetido às solicitações repetidas de tráfego de veículos por sobre-compactação ou cisalhamento. (Lima, *et al.* 2015).

Conforme a definição do Departamento Nacional de Infraestrutura de Transportes (DNIT), a deformação permanente em trilha de roda de misturas asfálticas pode acontecer de duas formas: o afundamento plástico e o afundamento por consolidação (Glossário de Termos Técnicos Rodoviários 1997).

É necessário conhecer o tipo de patologia existente e fazer a recuperação para esses casos, especialmente as anomalias no revestimento, visto que segundo Colares (2011), é mais econômico fazer a recuperação de rodovias, enquanto ainda apresentam condições para isso, pois os danos podem avançar e ir além do revestimento, atingindo a estrutura e tornando mais caro a recuperação.

De acordo com a Federal Highway Administration (1985), o cálculo de afundamento de trilhas-de-roda é geralmente realizado através da utilização de modelos de acumulação da deformação permanente apropriados para os materiais que compõem as estruturas dos pavimentos flexíveis, e que o modelo representado pela Equação 6 proposta Monismith *et al.* (1975) parece ser a mais adequada para fins práticos.

$$\varepsilon_p = NA^B \quad (6)$$

$\varepsilon_p$ : deformação específica plástica [%];

N: número de aplicações de carga;

A e B: parâmetros experimentais.

De acordo com Medina e Motta (2015), o modelo de Monismith para cálculo da deformação permanente é amplamente empregado nos estudos com solos brasileiros. Estudos realizados por Bayomy e Al-sanad (1993) utilizaram a mesma equação para estudar a deformação permanente de solos granulares provenientes de subleitos de rodovias. Quatro

níveis de tensão foram aplicados para cada tipo de solo pesquisado e variaram de 10% a 40% em relação à resistência de ruptura compressiva axial de cada um deles. Cada nível de tensão aplicado nos materiais foi combinado com três teores de umidade e para cada uma dessas combinações três amostras de solo foram utilizadas. Os teores de umidade foram: Umidade ótima e umidade ótima com mais e menos 2%.

De acordo com Guimarães (2009), o mais adequado é buscar solos granulares e finos que apresentem acomodamento das deformações permanentes com o número de ciclos de solicitações, fenômeno conhecido como *shakedown*, assim tendo a garantia de que não haverá ruptura plástica. Entretanto, Malysz (2009) relata que quando as deformações iniciais são muito elevadas, ou os ensaios são executados para um grande número de aplicações de carga, o modelo de Monismith perde sua representatividade.

O afundamento plástico pode ser definido como o afundamento causado pela plasticidade de alguma camada do pavimento, enquanto afundamento de consolidação seria o afundamento causado pela consolidação de alguma camada do pavimento (Dnit 2009). Em se tratando de camada asfáltica, o adjetivo plástico está relacionado ao comportamento visco-elástico do ligante asfáltico.

Dentre os diversos tipos de defeitos a que um pavimento pode apresentar, sem dúvida, a deformação permanente em trilha de roda da camada de rolamento é um dos mais significativos, já que esse tipo de defeito além de propiciar uma degradação acelerada da estrutura do pavimento, reduz o conforto ao rolamento, a segurança do usuário, e aumenta os custos operacionais (Moura, 2010). Esse é um dos principais defeitos dos pavimentos que utilizam revestimentos asfálticos, e seu surgimento se dá tradicionalmente nas idades iniciais (Ferreira, 2016).

Em laboratório é possível realizar modelos de previsão de deformação permanente considerando a Teoria do *Shakedown* por meio de ensaios triaxiais de cargas repetidas (Lima, *et al.* 2015). Ainda existe necessidade de desenvolver modelos teóricos que permitam prever a deformação permanente (Collins *et al.*, 2000). Entretanto, se utilizam modelos de previsão desenvolvidos por estudos em laboratório, para solos e agregados utilizam-se ensaios triaxiais de cargas repetidas com controle de preparação dos corpos de prova a fim de representar ao máximo as características existentes em campo.

De acordo com o modelo proposto por Guimarães (2009), previu a deformação permanente a partir das tensões atuantes para melhor aplicabilidade em método de dimensionamento mecanístico-empírico. A Equação 7 é a representação do modelo e foi obtida dos resultados de ensaios de deformação permanente feitos em equipamentos triaxiais de cargas

repetidas, com vários níveis de tensão. É uma ferramenta matemática que descreve de forma satisfatória o comportamento observado nos ensaios triaxiais de laboratório (Guimarães, 2009).

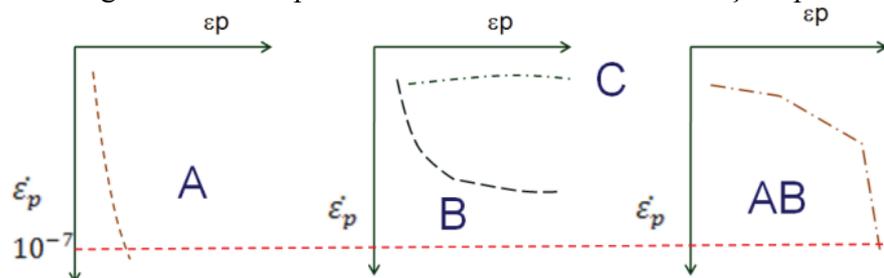
Equação 7 – Modelo de deformação permanente

$$\varepsilon_p = \psi_1 \cdot \left(\frac{\sigma_3}{\rho_0}\right)^{\psi_2} \cdot \left(\frac{\sigma_d}{\rho_0}\right)^{\psi_3} \cdot N^{\psi_4} \quad (7)$$

Para realização dos cálculos dos parâmetros do modelo proposto por Guimarães (2009) devem ser ensaiados 9 (nove) corpos de prova, um a cada par de tensão. No mínimo 6 (seis) corpos de prova devem ser ensaiados, desde que os valores das tensões sejam bem espaçados entre si. É utilizada a técnica de regressão não linear múltipla para se obter as constantes do modelo (Dnit, 2018).

Os comportamentos referentes à deformação permanente podem ser indicados segundo a modelagem correspondente ao modelo proposto por Dawson e Wellner (1999), observada na F, sendo que os comportamentos A, e C foram propostos por Werkmeister (2003) e modelo AB por Guimarães (2009). A Figura 6 apresenta esses comportamentos individualmente.

Figura 6 - Análise gráfica do comportamento de diferentes deformações permanentes



Fonte: Adaptado Guimarães (2009)

O comportamento A, *shakedown*, ocorre quando o material está em estado de acomodamento plástico, não gerando afundamento no pavimento. Neste nível, após uma certa quantidade de aplicações de carga é alcançado um estado de equilíbrio, restando somente deformações elásticas. No comportamento B, *plastic creep*, ocorre escoamento plástico e não é possível determinar se o material entrou em *shakedown* ou se terá um colapso. Nessa situação, a deformação não é totalmente resiliente, ao final de certo número de ciclos a deformação permanente é aceitável, entretanto caso tenha um grande número de cargas o material pode

apresentar falha (Lima e Motta 2015). O comportamento C, *incremental collapse*, apresenta lenta taxa de deformação decrescente, porém a deformação permanente aumenta sucessivamente a cada ciclo de carregamento, podendo ocasionar a ruptura do pavimento. A resposta é sempre plástica e a falha ocorre com número pequeno de ciclos de carga. O comportamento do tipo AB apresenta significativas deformações iniciais seguida de acomodamento plástico e foi detectada para solos finos brasileiros. (Lima e Motta 2015).

No Brasil, Moura (2010) destaca que os principais fatores que contribuem de forma isolada ou em conjunto, para a formação da deformação permanente em trilhas de rodas são: distribuição granulométrica inadequada, superdosagem do ligante asfáltico e forma e textura superficial dos agregados inadequadas.

De acordo com a FHWA – *Federal Highway Administration* (2002), os agregados respondem por 80% da resistência à deformação permanente e os ligantes apenas 20%. Para Faccin (2018) conforme mostra literatura, as características mais relevantes dos agregados que podem influenciar a resistência à deformação permanente são: textura superficial, graduação, forma e tamanho dos agregados.

Em estudo realizado por Bastos (2016) foi investigado a influência do ligante e do agregado, encontrando correlações significativas entre certos componentes da mistura e o Número de Fluxo, que é um parâmetro utilizado no ensaio uniaxial de carga repetida para caracterizar a susceptibilidade à deformação permanente de misturas asfálticas, bem como a contribuição do ligante na resistência ao defeito. O monitoramento em campo permitiu conhecer o comportamento de um pavimento asfáltico típico do Ceará sob aplicação de carga.

A pesquisa conduzida por Vasconcelos (2018) abordou a avaliação da Deformação Permanente (DP) em materiais que compõem camadas de bases e sub-bases de pavimentos. O estudo propõe modelos de previsão da DP para solos da Região Metropolitana de Fortaleza e para misturas estabilizadas quimicamente de solo com cinzas de carvão. Os resultados mostram que a influência da estabilização química e dos tempos de cura na redução dos valores de deformação irreversível dos solos estudados. Após a coleta de 8 solos na RMF e realização de ensaios de DP, destacou-se a importância da estabilização química na redução da deformação. Esses resultados foram importantes para o dimensionamento de pavimentos e para a utilização de resíduos industriais na pavimentação, contribuindo para a eficiência e sustentabilidade das obras viárias na região estudada.

Em tese estabelecida por Cabral (2021) foi possível analisar a Deformação Permanente (DP) de solos empregados em pavimentos da microrregião de Mossoró, com o objetivo geral de desenvolver modelos para serem aplicados em métodos de dimensionamento

mecanístico-empírico de pavimentos, utilizando ensaios mais ágeis e a técnica de Redes Neurais Artificiais (RNA). Os resultados indicaram que o ensaio triaxial de múltiplos estágios, conforme a norma europeia, demonstrou vantagens operacionais e foi recomendado como método para a obtenção da Deformação Permanente (DP) das amostras. Além disso, os modelos desenvolvidos por meio da técnica de Redes Neurais Artificiais (RNA) foram considerados satisfatórios na previsão da DP dos solos, assim como as equações geradas para estimar o módulo de resiliência. Observou-se que os pavimentos dimensionados pelos métodos mecanístico-empíricos foram capazes de antecipar o desempenho das estruturas, considerando as tensões e influências no surgimento de falhas de deformação permanente e áreas trincadas.

## **2.2 Redes Neurais Artificiais**

Para Morais (2010), RNAs são sistemas paralelos que são compostos por uma unidade de processamento simples (nodos ou neurônios) que calculam algumas funções matemáticas que geralmente são não-lineares. Dessa forma, pode-se definir uma rede neural como um processador maciçamente distribuído formado de grande número de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso (Kopiler et al., 2019).

Para Oliveira (2021) as redes neurais têm como principais características a correspondência com modelos adaptáveis e treináveis, que podem demonstrar domínios complexos capazes de generalizar uma informação incompleta, são robustas, são capazes de fazer um armazenamento associativo de informações e processam informações espaço-temporais, garantindo rapidez de processamento.

As redes neurais artificiais (RNAs) são baseadas nos estudos sobre a estrutura do cérebro humano para tentar representar sua forma inteligente de processar informações. Alguns estudos da neurofisiologia consideram que a riqueza computacional do cérebro humano está associada a vasta quantidade de neurônios, interconectados por uma rede complexa de sinapses (Ribeiro, 2016).

### **2.2.1 O neurônio biológico**

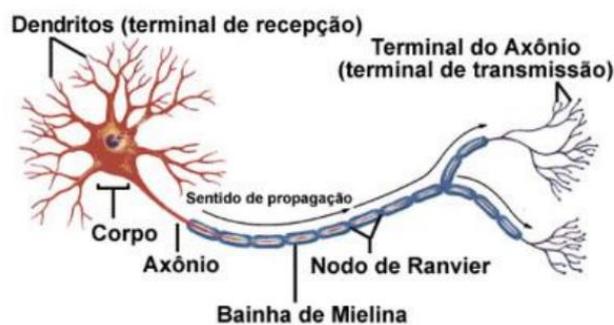
Segundo Kopiler *et al.* (2019) o cérebro é constantemente treinado para realizar o aprendizado de coisas novas através de um processo de aprendizagem por reforço. Da mesma maneira que no cérebro, as Redes Neurais Artificiais (RNAs) são estruturadas na forma de um

número de elementos individuais simples (os neurônios), que se conectam uns aos outros, formando ligações capazes de armazenar e transmitir informações providas do exterior, se assimilando ao sistema nervoso (Teodoro, 2003).

De acordo com Teodoro (2003) as redes neurais são o que há de mais avançado tratando-se em representação do conhecimento. É um sistema capaz de agir de maneira muito próxima a forma como os seres humanos adquirem e representam seus conhecimentos. Baseado em estudos neurológicos, o desenvolvimento das redes neuronais procura formalizar um padrão matemático para as reações elétricas dos neurônios humanos.

Um neurônio é formado por um corpo celular (ou soma), um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos (zonas receptoras) formam uma malha de filamentos muito fina ao redor do neurônio. De maneira que o axônio (linhas de transmissão) consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse que tem como função principal a memorização da informação (Matsunaga, 2012). A Figura 7 apresenta um exemplar de neurônio biológico.

Figura 7 - Exemplo de neurônio biológico



Fonte: Adaptado (Kopiler *et al.* 2019)

O corpo celular ou soma é responsável pelo processamento das informações que vêm ao neurônio em forma de pulsos elétricos e pela produção da resposta a estes estímulos externos, também como pulso elétrico. Os dendritos são as estruturas do neurônio responsáveis por receberem os pulsos elétricos e o axônio é o responsável pela emissão do pulso elétrico produzido pelo neurônio às demais células nervosas com as quais este encontra-se conectado (Haykin, 2001).

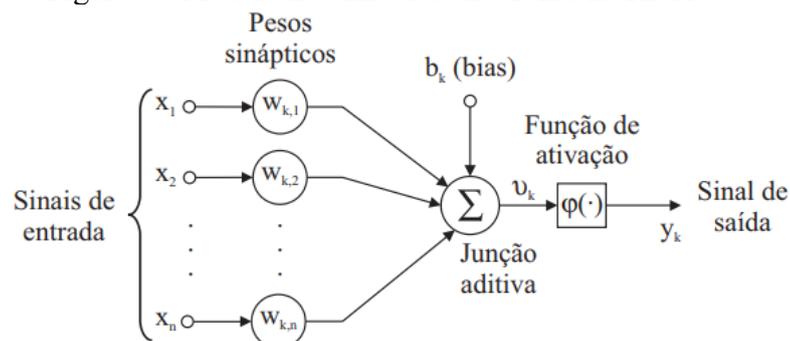
A transmissão das informações entre neurônios constituintes do cérebro humano ocorre por meio das sinapses, que são regiões eletroquimicamente ativas compreendidas entre duas membranas, as pré-sinápticas (axônio) e as pós-sinápticas (dendritos) de neurônios adjacentes. As sinapses são as estruturas principais do cérebro humano responsáveis pela armazenagem das informações, e são modificadas conforme o processo de aprendizagem ao qual o cérebro foi submetido. Qualquer alteração sobre o conhecimento de um determinado fenômeno já aprendido pelo cérebro só será possível pela alteração das sinapses estabelecidas entre os neurônios biológicos (Haykin, 2001).

### 2.2.2 Neurônio Artificial

Segundo Haykin (2005) as redes neurais artificiais vêm sendo utilizadas cada vez mais, nos mais variados tipos de problemas complexos. Essas redes são sistemas computacionais paralelos formados por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, interligados entre si de maneira específica para desempenhar tarefa (Binoti, 2010; Binoti et al., 2012). Os neurônios artificiais são modelos matemáticos simplificados dos neurônios biológicos e processam as informações recebidas e ponderadas através de pesos sinápticos, gerando uma única resposta (Haykin, 2001; Braga et al., 2007).

Segundo modelo apresentado por Haykin (2001) os neurônios ou unidades de processamento são interligados por conexões, que representam as sinapses, onde cada uma delas possui um peso associado, e são compostas pelas camadas de entrada, intermediária e de saída. É necessário identificar cinco elementos básicos do neurônio artificial: um conjunto de sinapses ou elos de conexão, um somador, um limiar, uma função de ativação e uma de saída, os quais se encontram representados na Figura 8 e serão descritos a seguir.

Figura 8 - Modelo não linear do neurônio na RNA



Fonte: Adaptado de Zanetti *et al.* (2008)

- a) Sinapses: caracterizadas por um peso ( $w$ ), que representa a sua intensidade. Segundo Haykin (2001) as sinapses são responsáveis pela armazenagem da informação e variam conforme o processo de aprendizagem da rede;
- b) Somatório: Para Zanetti *et al.* (2008) a junção aditiva possui a finalidade de somar todos os sinais de entrada ( $x_j$ ) ponderados pelos pesos sinápticos de cada neurônio. A Equação 8, representa esse somatório:

$$u_k = \sum_{j=1}^n w_{k,j} \cdot x_j \quad (8)$$

em que:

$w_{k,j}$ : pesos sinápticos do neurônio  $k$ ;

$x_j$ : sinais de entrada  $e$ ;

$u_k$ : saída do combinador linear devido aos sinais de entrada.

- c) Limiar: segundo Nunes (2003) o limiar tem a função determinante na saída do neurônio. Se o valor de  $u_k$  for menor que este limiar, então a saída do neurônio fica inibida, se for maior, fica ativa.
- d) Bias: entrada adicional que pode ser acrescentada ao neurônio artificial, de valor de entrada fixado em +1. Seu peso de conexão,  $w_j$ , é ajustável como qualquer outro peso de conexão. Sua função é prover meios de transladar o valor de limiar da função de transferência (LOESCH e SARI, 1996);
- e) Saída: denominada por  $y_k$ . A equação 9 mostrada a seguir, proporciona o cálculo do valor na saída do neurônio:

$$y_k = \varphi(u_k + b_k) \quad (9)$$

em que:

$y_k$ : sinal de saída do neurônio

$\varphi$ : função de ativação

$u_k$ : saída do combinador linear devido aos sinais de entrada

$b_k$ : bias

- f) Função de ativação: de acordo com Nunes (2003) tem a função de restringir (limitar) o intervalo permissível de amplitude do sinal de saída a um valor finito. O intervalo normalizado da amplitude de saída de um neurônio é escrito como o intervalo fechado  $[0,1]$  ou, alternativamente  $[1,1]$ ;

### 2.2.3 Arquitetura de Rede

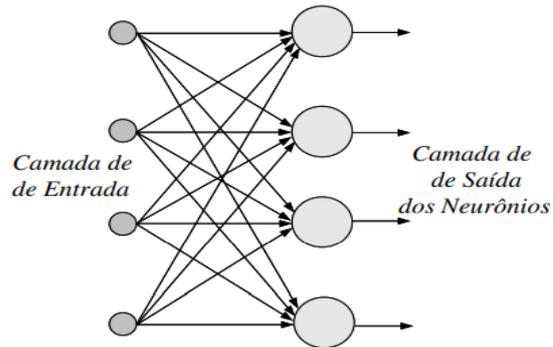
A escolha da melhor arquitetura nas redes neurais é uma das etapas mais delicadas, uma vez que esse processo é experimental e demanda um grande tempo de execução. Em prática, o processo deve ser aplicado com a finalidade de testar vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução de um problema em específico (Miranda et al., 2009).

A forma como os neurônios são organizados numa rede neural é denominada topologia ou arquitetura de rede. Essa arquitetura irá afetar o desempenho da rede bem como as aplicações para as quais ela é desejada e sua estrutura está intimamente ligada ao algoritmo de aprendizado usado para o seu treinamento (Raia Jr, 2000).

Em geral, podemos identificar três classes de arquiteturas de rede fundamentalmente diferentes: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (Fleck, 2016). Duas dessas arquiteturas são em camadas, sendo assim, os neurônios estão organizados em camadas (Barros, 2018). Para Kóvacs (2006) a estruturação da RNA ou arquitetura, mostra o número de camadas por redes e a quantidade de neurônios por camada. As camadas internas das RNA's são geralmente referidas como camadas ocultas, ilustrado na Figura 6.

Em redes neurais alimentadas adiante com camada única (Figura 9), os neurônios estão organizados em forma de camadas (Haykin, 2001). Na sua forma mais simples, possui apenas duas camadas: camadas dos nós de entrada e camada de neurônios de saída. Este tipo de rede é tipicamente alimentado adiante, ou seja, a camada de entrada se projeta sobre a camada de saída, mas não vice-versa (Haykin, 2001).

Figura 9 - Rede alimentada com camada única



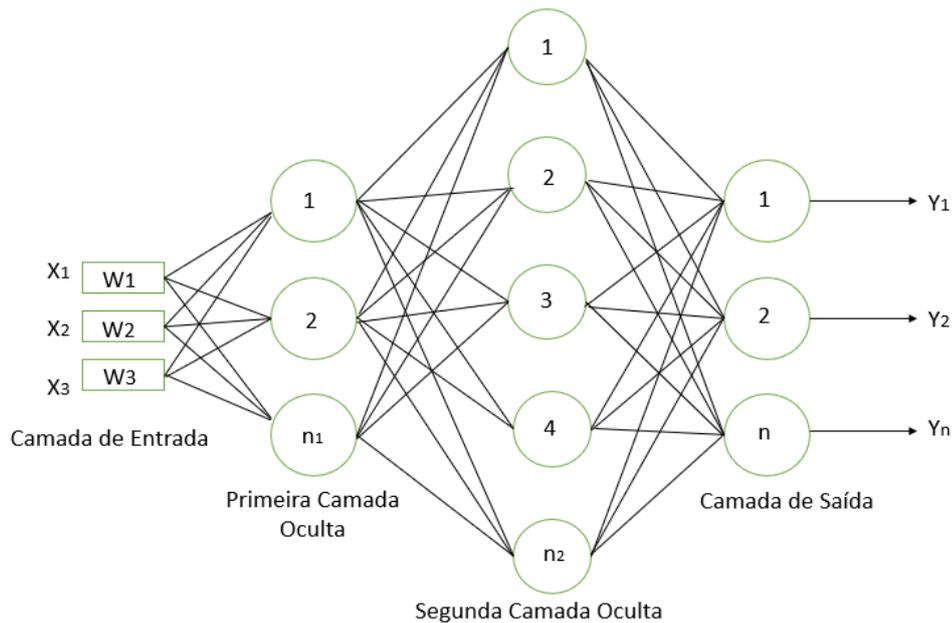
Fonte: Adaptado de Matsunaga (2012)

A versão de uma única camada é chamada de rede de perceptrons, praticamente não é usada, posto que Minsky e Papert provaram no final da década de 60 que este tipo de rede só conseguia classificar corretamente problemas linearmente separáveis (Kopiler *et al.*, 2019).

Segundo Nunes (2003) dentre as topologias, vale ressaltar a *Multilayer Perceptron*, que é baseada em uma camada de entrada, uma ou mais camadas intermediárias e uma de saída. As redes multicamadas, como a *Multilayer Perceptron* (MLP), são determinadas pela presença de uma ou mais camadas intermediárias ou ocultas, onde se localizam os neurônios cuja função é ajustar entre o sinal externo e a saída.

Essas redes podem ser usadas como classificadoras: quando se utiliza apenas uma camada oculta, a classificação das características acontece pela combinação de retas, podendo assim implementar qualquer função contínua. A motivação da utilização de camadas ocultas se dá pela possibilidade da rede extrair estatísticas de ordem elevada, podendo assim a rede adquirir uma perspectiva global devido ao conjunto extra de camadas ocultas que formam novas conexões sinápticas e da dimensão extra de interações neurais (Haykin, 1994). A Figura 10 apresenta a estrutura desse tipo de rede.

Figura 10 - Rede neural de múltiplas camadas



Fonte: Autor (2023) Adaptado de Haykin (1984)

De acordo com Shepherd, 2012 a arquitetura de uma Rede Neural do tipo MLP consiste em nós organizados em duas ou mais camadas internas, tendo em vista que estes nós estão ligados por valores de pesos entre elas. Segundo (Braga, 2011), o treinamento de uma rede MLP é realizado por meio de exemplos (amostras de calibração dos pesos sinápticos) no qual é utilizado um algoritmo de retropropagação do erro (backpropagation) durante o processo de treinamento.

#### 2.2.4 Perceptron Multicamadas

Segundo Fanucchi *et al.* (2013) esse algoritmo constitui-se de duas etapas: forward e backward. Na primeira fase, é obtido somente o resultado da topologia com pesos sinápticos e limiares de ativação atuais. Já na segunda etapa, tendo em vista os valores esperados para a entrada considerada, são obtidos os desvios e, em conjunto com o gradiente local de cada neurônio, são corrigidos os valores dos pesos sinápticos e limiares de ativação.

Segundo Shah e Ghazali (2011) apud Coutinho et al. (2016) a RNA do tipo Multilayer Perceptron (MLP) pertence à classe de RNAs conhecida como *feedforward*, além de ser uma aproximação universal de funções, que tem sido aplicada em diferentes problemas combinatórios e na solução de diferentes tarefas como processamento de informações,

reconhecimento de padrões, previsões do tempo, problemas de classificação, processamento de imagens, previsões de atividades sísmicas e outros.

O *Feed-Forward* é uma característica da arquitetura perceptron, onde as conexões são todas alimentadas na camada de entrada e a informação caminha em direção a camada de saída, sem formar ciclos (Data Science Academy, 2015). A mesma possui uma camada de saída e pelo menos uma camada oculta (Braga; Carvalho; Ludermir, 2000). Para o equacionamento matemático do processo de aprendizagem os trabalhos de Haykin (2001), Araújo (2013), Araújo (2015) podem ser consultados.

### **2.2.5 Treinamento e Validação**

Para Martineli (1999), o conjunto de dados, devidamente pré-processado, deve ser dividido em subconjuntos distintos de treinamento, validação e teste. Na etapa de treinamento os pesos sinápticos são alterados de forma a minimizar a função de custo com base nas informações existentes no conjunto de treinamento (Dantas Neto, 2004). Para Araújo (2013) é esperada que a rede se torne bem treinada a ponto de aprender suficientemente o comportamento do fenômeno estudado, representado pelas informações contidas no conjunto de treinamento, mas com capacidade de generalização deste conhecimento, ou seja, que o modelo seja capaz de dar respostas satisfatórias para estímulos a qual nunca foi submetido.

A característica primordial de uma RNA é sua capacidade de aprender a partir do ambiente em que está inserida e adaptar-se para melhor responder a estes estímulos através de aprendizado. Esta aprende através da adaptação de seus pesos e bias readequando sua estrutura interna a cada iteração do processo de aprendizagem. Para isto o conjunto de dados disponível para a modelagem de um certo fenômeno é separado aleatoriamente em um subconjunto de treinamento e um subconjunto de validação (Haykin, 2001).

A validação do experimento se faz necessária para certificar a capacidade de aprendizado da rede. O desempenho da rede neural artificial constata a capacidade da rede de aprender, de forma generalizada, o comportamento não-linear da liga memória de forma. Nessa etapa não há variação dos pesos, como na etapa de treinamento. O erro da validação consiste na diferença entre os valores dos alvos e os valores obtidos pela rede neural (Araújo, 2019).

É necessário fazer o monitoramento dos processos de treinamento e validação simultaneamente para verificar a ocorrência de “over-ting” ou treinamento excessivo. Isto ocorre quando a partir de um determinado número de iterações, o erro médio calculado na fase

de treinamento diminui, porém aumenta na fase de validação (Kröse e Smagt, 1996 *apud* Dantas Neto, 2004).

A validação é utilizada principalmente quando se quer um grau maior de confiança no conhecimento armazenado pela RNA. Em aplicações de maior complexidade, onde uma falha traria consequências graves, é fundamental que se valide o conhecimento antes de sua utilização. As RNAs podem utilizar o conjunto de validação como um método de parada para o processo de aprendizagem.

### **2.2.6 Aplicações do RNA em geotecnia**

Os modelos de rede neurais não têm forma funcional implícita e, portanto, tem maior liberdade para ajustar os dados do que outros modelos propostos, como por exemplos modelos de regressão. A maior flexibilidade na relação entre variáveis de entrada e saída se traduz em um modelo mais adequado (Wilmot e Mei 2005). Segundo Hanandeh (2022) apontou que estudos usando redes neurais artificiais tem maior precisão do que regressão linear na avaliação e gestão de condições relacionadas a pavimentos.

Em estudos realizados por Cui *et al.* (2020) as redes neurais foram utilizadas para classificar imagens de tráfego de rodovias em uma cidade da China. Como justificativa para uso das redes neurais estão a capacidade de aprender características discriminativas através da concatenação de múltiplas camadas. (Zeiler & Fergus, 2014; Q. Zhang & Zhu, 2018).

O trabalho publicado por Shahin *et al.*, (2001) compreendeu-se em uma revisão bibliográfica sobre os sucessos da aplicação de RNA em problemas de geotecnia. Ferreira (2008) utilizou técnicas de Data Mining e redes neurais artificiais para prognóstico do Módulo de Resiliência de solos estabilizados e britas a partir de parâmetros geotécnicos simples. Para isso, foi utilizado um banco de dados existente no laboratório de pavimentação da COPPE-UFRJ, gerando resultados promissores, com r-quadrados da ordem de 0,90.

Ribeiro (2013) analisou características geotécnicas dos solos da Região Metropolitana de Fortaleza (RMF) localizado no Estado do Ceará. Foi observado pelo autor que essas características auxiliaram a tomada de decisão dos solos, quanto à sua utilização, para fins de pavimentação e para isso foram usados como ferramentas o Geoprocessamento e Redes Neurais Artificiais (RNAs) como técnicas de modelagem. As propriedades estudadas (pedologia, geologia, geomorfologia, vegetação, altimetria e posição) foram comparadas às informações geotécnicas previstas (classificação TRB - Transportation Research Board e CBR - California Bearing Ratio) para solos provenientes da RMF. Como resultado, foram criados

três modelos de RNA's que passaram por um processo de ajuste, validação e testes. Os modelos de RNA's permitiram a estimativa de propriedades geotécnicas, que por sua vez serviram como base para criação dos Mapas Geotécnicos Neurais. As características geotécnicas estimadas por estes modelos possibilitaram a elaboração dos chamados Mapas Geotécnicos Neurais.

Para Bicalho *et al.* (2022) discutiram o emprego de redes neurais como alternativa para estimar aspectos geotécnicos. O trabalho aborda a aplicação das RNA's na determinação dos valores de limite de consistência em solos de granulometria fina. Os estudos mencionados no artigo demonstraram que as RNA's têm o potencial de servir como uma alternativa às relações empíricas baseadas em regressão linear para prever as propriedades dos solos a partir de parâmetros previamente conhecidos, tanto em solos de diferentes regiões do Brasil quanto de outros países.

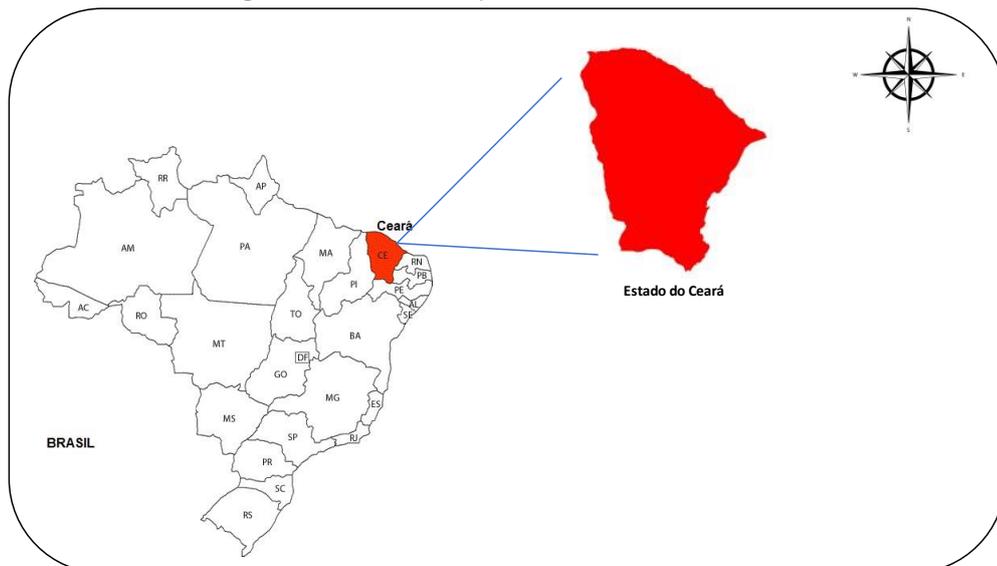
### 3 CARACTERIZAÇÃO DA ÁREA ESTUDO

A área de estudo deste trabalho concentra-se nos trechos de rodovias estratégicas situadas no estado do Ceará. Essas rodovias desempenham um papel vital na conectividade e mobilidade da região, representando importantes vias de transporte que atravessam diferentes cenários geográficos e socioeconômicos do estado. A compreensão aprofundada dessa área é essencial para contextualizar as análises subsequentes relacionadas aos mapas geológico-geotécnicos e modelos neurais de previsão de MR e CBR.

#### 3.1 Localização

Esta pesquisa foi desenvolvida no estado do Ceará, situado no Nordeste do Brasil entre meridianos  $37^{\circ} 14' 54''$  e  $41^{\circ} 24' 45''$  de longitude a oeste de Greenwich e  $2^{\circ} 46' 20''$  e  $7^{\circ} 52' 15''$  de latitude Sul (Figura 12). Possui extensão territorial de  $146.016 \text{ km}^2$  e divide-se, atualmente, em 184 municípios. Sua área corresponde a cerca de 10% da região Nordeste do Brasil; o estado é cercado pelo Oceano Atlântico ao norte, pelo estado de Pernambuco ao sul, a oeste o estado do Piauí e a leste os estados do Rio Grande do Norte e Paraíba (EMBRAPA, 2002). Margeia o Oceano Atlântico ao longo do setor norte e faz fronteira com os estados do Piauí (oeste), Pernambuco (sul), Rio Grande do Norte e Paraíba (leste). A Figura 11 apresenta o mapa de localização do Estado do Ceará.

Figura 11 - Localização do estado do Ceará no Brasil



Fonte: Autor (2023)

A região do Nordeste em que está inserido o estado do Ceará possui boa parte do seu território sob clima semiárido quente com chuvas de verão e inverno seco Geremias (2020). Embora apresente essa condição, há algumas áreas com clima mais moderado como aqueles que registrados nas serras, chapadas, e as áreas que estão próximas ao litoral do Estado. A semiaridez não resulta dos índices de precipitação, que são relativamente elevados (em torno de 1000 mm na zona costeira), mas da grande variação interanual, pois mais de 90% encontram-se na estação chuvosa. Durante os meses de setembro e outubro, o estado praticamente não recebe chuvas. Devido essa variedade climática, é que resulta na sua variabilidade geomorfológica e por consequência os diferentes tipos dos solos (Ipece,2007).

### **3.2 Caracterização Pedológica do Ceará**

O levantamento pedológico prevê a distribuição geográfica dos solos como entidades naturais, identificando suas relações e propriedades observáveis na natureza. Esses solos são reconhecidos como unidades naturais e suas áreas são delimitadas em mapas, destacando classes específicas de solos. As informações contidas nesse levantamento são cruciais para avaliar o potencial e as restrições de uma determinada área (Estados Unidos, 1975). No Estado do Ceará, levando em consideração as condições climáticas, é possível encontrar solos com diferentes profundidades e apresentando diferentes horizontes com variedades de espessuras (FUNCEME, 2012). O Estado do Ceará conta com mais de 10.000 km<sup>2</sup> de solos derivados de sedimentos da Formação Barreiras e que pode ser definido dentro do contexto de solos coesos (Jacomine et al., 1973). Alguns levantamentos de solos no Ceará já constataram características morfológicas semelhantes aos horizontes coesos (Melo, 1968; Jacomine et al., 1973). No entanto, Ramos & Oliveira (1993) relatam problemas de natureza química e física do solo (dificultando à drenagem e compactação), no qual, são resultantes de características naturais do manuseio inadequado do solo.

No Estado do Ceará há várias classes de solos divididos em regiões distintas, as regiões norte e nordeste possuem em sua maior parte classes de Neossolos, Planossolos e Argissolos (Diniz, 2010). Os Neossolos Quartzarênicos presentes no estado caracterizam-se por serem solos arenoquartzosos não hidromórficos e não consolidados, predominantemente encontrados ao longo da faixa costeira e nas dunas da planície litorânea. Esses solos são profundos e possuem uma drenagem excessiva, apresentando uma sequência de horizonte A-C e sendo distróficos, variando de forte a fracamente ácidos, com pH na faixa de 4,5 a 5,5. O horizonte A desses solos é geralmente pouco desenvolvido, exibindo tonalidades de cinza-

escura a muito escura, podendo estar ausente em áreas sujeitas a deflação eólica intensa. Quanto ao horizonte C, costuma ter espessura considerável e apresenta uma variedade de colorações, incluindo tonalidades claras, cinza-claro e bruno-claro. Esses solos são caracterizados por sua elevada fragilidade ambiental (Diniz, 2010).

Para a região central do Ceará há uma associação característica de Planossolos e Argissolos (Mota *et al.*, 2002). Os Argissolos são solos caracterizados por apresentarem um horizonte B textural, com acúmulo de argila em relação aos horizontes adjacentes, e são comuns em regiões tropicais e subtropicais. Eles são conhecidos por sua fertilidade natural e são frequentemente utilizados para atividades agrícolas (Mota *et al.*, 2002). A textura do solo pode variar, indo desde argilosa até média, influenciando na sua capacidade de drenagem. Em regiões tropicais, os Argissolos são frequentemente encontrados em áreas de topografia suave a ondulada. Suas propriedades físicas e químicas tornam esses solos relevantes para práticas agrícolas, sendo essencial considerar suas características específicas ao planejar o uso sustentável da terra. Do ponto de vista morfológico e físico do solo, os Planossolos são frequentemente identificados pela presença sequencial de um horizonte superficial escurecido (A) e outro subsuperficial claro e arenoso (E), caracterizado por uma boa taxa de infiltração de água. Essas características contrastam com o horizonte subjacente, que é mais acinzentado e argiloso (B), apresentando baixa permeabilidade. As tonalidades cinzentas (gleizadas) do solo surgem devido à facilidade de acúmulo de água nas áreas entre sopé e planície colúvio-aluvial, onde os Planossolos são tipicamente encontrados na paisagem (Silva, 2018). Os Planossolos são comumente encontrados em associação com os Neossolos Litólicos e Argissolos Vermelho-Amarelo, predominando em áreas de relevo plano a suavemente ondulado na depressão sertaneja, sob a influência de litotipos anfíbolitos e gnáissico-migamatíticos. No Brasil, regiões de destaque incluem o Nordeste brasileiro, o Pantanal e o Rio Grande do Sul (Silva, 2018).

A região sul há uma significativa predominância de Neossolos Quartzarênicos e Latossolos (Sá *et al.*, 2014). Os Latossolos são solos tropicais e subtropicais altamente intemperizados, caracterizados por uma grande profundidade e por apresentarem um perfil de desenvolvimento simples, com um horizonte B latossólico muito espesso. Eles são típicos de regiões com clima quente e úmido, onde o intenso processo de lixiviação e intemperismo químico promove a desestruturação das rochas e a formação de solos com baixa fertilidade natural. Outras características desses solos é que são ricos em óxidos de ferro e alumínio, como a goethita, hematita e gibbsita, e pobres em minerais primários, devido ao avançado estágio de intemperismo. Ademais, possuem estrutura granular ou subangular, com agregados estáveis e

porosidade bem desenvolvida, o que confere ao solo uma boa aeração e permeabilidade (Montanari *et al.*, 2014).

A região oeste cearense tem maior domínio de Planossolos, Neossolos Quartzarênicos, Argissolos e Luvisolos. Conforme o Sistema Brasileiro de Classificação de Solos (SiBCS) desenvolvido pela Embrapa (1999; 2006), os Luvisolos são categorizados como solos minerais eutróficos com argila de alta atividade. Esses solos apresentam um horizonte B textural imediatamente abaixo de um horizonte A fraco ou moderado, ou de um horizonte E, não atendendo aos critérios para classificação como Plintossolos ou Gleissolos. Em geral, os Luvisolos são pouco profundos, bem a imperfeitamente drenados, possuindo uma sequência de horizontes A (por vezes E), Bt e C. Notavelmente, há uma clara diferenciação entre os horizontes A e Bt, evidenciada pelo contraste de textura, diferenças de cor e/ou estrutura. A presença de pedregosidade superficial é comum, e há a possibilidade de apresentarem características solódicas ou sódicas nos horizontes subsuperficiais, conforme apontado pela Embrapa (1999; 2006).

### **3.3 Caracterização Geológica do Ceará**

O Ceará possui a História Geológica que pode ser dividida em duas partes: o Precambriano, período no qual se inicia com a formação da Terra, em 4,6 Ga e termina em 542 Ma de anos, no final do Proterozóico; e o Fanerozóico, que tem seu início no Cambriano, em 542 milhões de anos, e continua até os tempos atuais (Cavalcanti *et al.*, 2014). Foi no Fanerozóico que se consolidou o supercontinente Pangea, por volta 360 e 270 milhões de anos (Cordani *et al.*, 2000). O qual foi posteriormente fragmentado, separando na porção sul (Gondwana) continentes sul-americano e africano com a formação do oceano Atlântico, entre 230 e 90 Ma.

Do ponto de vista tectônico para Almeida *et al.* (1977), grande parte da região abrangida pelo estado do Ceará está inserida na porção setentrional da Província Borborema, foi parte do supercontinente Gondwana, formado a partir da aglutinação de massas continentais (África, América do Sul, Austrália, Índia e Antártica).

Esta aglutinação envolveu múltiplas e sucessivas colisões, que se iniciaram em 750 Ma e perduraram até 530 Ma, coincidindo com o evento geológico Brasileiro – Pan-Africano (Cordani *et al.*, 2000). Esses eventos foram fundamentais para a formação da estrutura geológica da região, influenciando a composição e distribuição dos diferentes tipos de rochas e minerais encontrados no estado. Essa história geológica complexa desempenhou um papel

importante na configuração do ambiente natural e na formação das paisagens únicas que caracterizam o estado do Ceará hoje.

A Província Borborema, segundo Lustosa (2004), apresenta os domínios representados pelos maciços gnáissicos-migmatíticos-graníticos (maciços Pernambuco-Alagoas, Caldas Brandão/São José de Campestre, Rio Piranhas, Tauá, Santa Quitéria e marginal do Cráton São Francisco), com idades que variam do Arqueano ao Paleoproterozóico, Arqueano ao Paleoproterozóico, e também domínios formados pelas faixas móveis e/ou sistemas de dobramentos vinculados ao Ciclo Brasileiro, ocorrido no Neoproterozóico. Sendo estas as faixas marginais (riacho do Portal, Piancó-Alto Brígida, Pajeú-Parnaíba, Seridó, Jaguaribeano e rio Curu-Independência). Os granitóides, com idades correspondentes ao Ciclo Brasileiro, representam uma feição importante na Província Borborema (Almeida *et al.*, 1977). A Província Borborema abrange a maior parte dos estados do Nordeste do Brasil (menos os Estados do Piauí, Maranhão e Bahia) e distribui-se em três grandes segmentos ou subprovíncias (Setentrional, Meridional e Transversal), separadas por estruturas tectônicas nomeadas de lineamentos Pernambuco e Patos.

## 4 METODOLOGIA

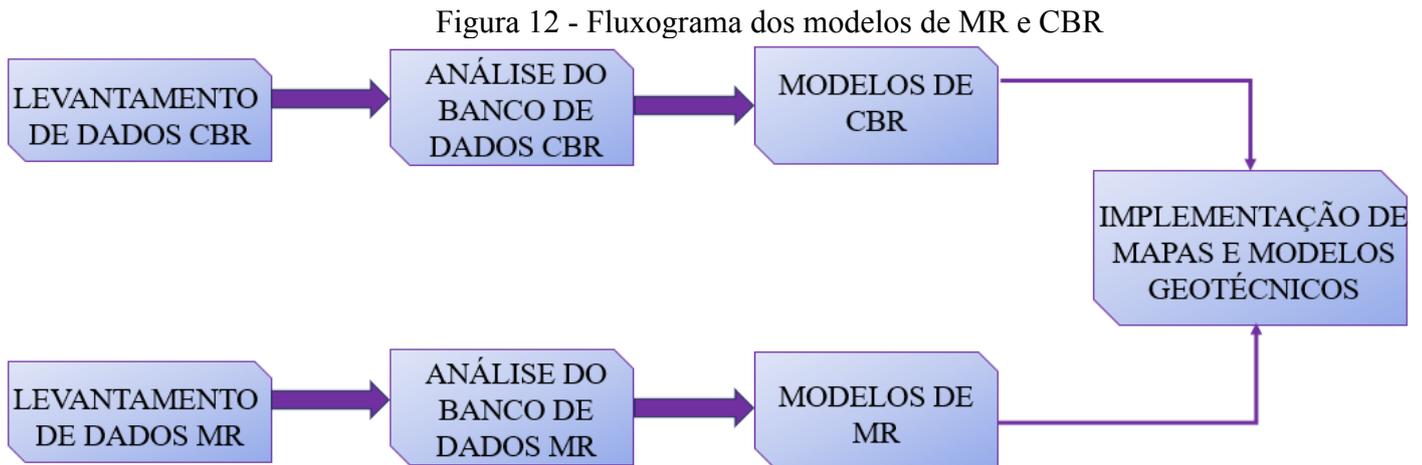
A metodologia proposta para este estudo compreende o desenvolvimento de modelos neurais para previsão de propriedades geotécnicas (CBR e MR), mapas geológico-geotécnicos e as diretrizes para implementação dos resultados em projetos rodoviários. Para o modelo de redes neurais artificiais de previsão do CBR foram realizadas as seguintes etapas:

1. Levantamento e análise do banco de dados geotécnico de pavimento no Estado do Ceará;
2. Desenvolvimento do modelo de RNA para CBR, para preenchimento de falhas no banco de dados para os trechos de rodovia da BR 116 e 222;
3. Produção de mapas geológico-geotécnicos de CBR para os trechos de rodovias estudados;

Para o modelo de redes neurais artificiais de previsão do MR foram realizadas as seguintes etapas:

1. Levantamento e análise do banco de dados geotécnicos de pavimentos no Estado do Ceará;
2. Modelos de previsão do MR para o Estado do Ceará;
3. Produção de mapas de MR para os trechos de rodovia estudados.

Por fim, são realizadas proposições de diretrizes para que os modelos e mapas geológico-geotécnicos desenvolvidos possam ser utilizados em projetos rodoviários no estado do Ceará. A Figura 12 apresenta o fluxograma com a sequência das etapas para obtenção dos modelos de MR.



Fonte: Autor

#### 4.1 Dados Utilizados

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

O processo de aquisição e georreferenciamento dos dados pela equipe do projeto requereu diversas horas de trabalho, pois os dados dos projetos não são georreferenciados, maior parte destes estava em papel e teve que ser transformado em arquivo digital. Para resolver essa questão, foi adotada a metodologia de georreferenciamento dos pontos geotécnicos proposta por Ribeiro et al. (2016). Esses pontos, inicialmente não georreferenciados, são categorizados em três grupos de informações: subleito, empréstimos e jazidas. A localização desses pontos é realizada em relação ao estaqueamento do eixo diretriz da estrada. Os dados do subleito são posicionados sobre o eixo e seus bordos, enquanto as informações das jazidas e empréstimos são determinadas a partir de distâncias conhecidas a partir das estacas das vias. Esse método, detalhado nos estudos geotécnicos, possibilita a extração das coordenadas

geográficas dos locais amostrados, viabilizando a espacialização dos dados, mesmo na ausência de georreferenciamento original.

Para executar esse procedimento, atualmente, uma planilha eletrônica está sendo empregada, conforme ilustrado na Figura 13. Após a conclusão da construção da base de dados na planilha, será realizada a conversão do banco para um formato no Sistema de Gerenciamento de Banco de Dados (SGBD) espacial, utilizando a ferramenta gratuita PostgreSQL/PostGIS. Essa abordagem possibilitará o acesso direto à base por meio de Sistemas de Informações Geográficas, como o QGIS e o ArcGIS.

Figura 13 - Parte das informações dos solos estruturadas em planilha eletrônica

DADOS GERAIS DO SOLO								
IDENTIFICAÇÃO	ORIGEM	COORDENADAS (UTM - 245)			CLASSIFICAÇÕES			
	CIDADE	X	Y	Z	HRB	SUCS	MCT	PEDOLOGIA
1	Paraná	482450	7200000	150	1	USC	1	Podzólico
2	Paraná	482450	7200000	150	1	USC	1	Podzólico
3	Paraná	482450	7200000	150	1	USC	1	Podzólico
4	Paraná	482450	7200000	150	1	USC	1	Podzólico
5	Paraná	482450	7200000	150	1	USC	1	Podzólico
6	Paraná	482450	7200000	150	1	USC	1	Podzólico
7	Paraná	482450	7200000	150	1	USC	1	Podzólico
8	Paraná	482450	7200000	150	1	USC	1	Podzólico
9	Paraná	482450	7200000	150	1	USC	1	Podzólico
10	Paraná	482450	7200000	150	1	USC	1	Podzólico
11	Paraná	482450	7200000	150	1	USC	1	Podzólico
12	Paraná	482450	7200000	150	1	USC	1	Podzólico
13	Paraná	482450	7200000	150	1	USC	1	Podzólico
14	Paraná	482450	7200000	150	1	USC	1	Podzólico
15	Paraná	482450	7200000	150	1	USC	1	Podzólico
16	Paraná	482450	7200000	150	1	USC	1	Podzólico
17	Paraná	482450	7200000	150	1	USC	1	Podzólico
18	Paraná	482450	7200000	150	1	USC	1	Podzólico
19	Paraná	482450	7200000	150	1	USC	1	Podzólico
20	Paraná	482450	7200000	150	1	USC	1	Podzólico
21	Paraná	482450	7200000	150	1	USC	1	Podzólico
22	Paraná	482450	7200000	150	1	USC	1	Podzólico
23	Paraná	482450	7200000	150	1	USC	1	Podzólico
24	Paraná	482450	7200000	150	1	USC	1	Podzólico
25	Paraná	482450	7200000	150	1	USC	1	Podzólico
26	Paraná	482450	7200000	150	1	USC	1	Podzólico
27	Paraná	482450	7200000	150	1	USC	1	Podzólico
28	Paraná	482450	7200000	150	1	USC	1	Podzólico
29	Paraná	482450	7200000	150	1	USC	1	Podzólico
30	Paraná	482450	7200000	150	1	USC	1	Podzólico
31	Paraná	482450	7200000	150	1	USC	1	Podzólico
32	Paraná	482450	7200000	150	1	USC	1	Podzólico
33	Paraná	482450	7200000	150	1	USC	1	Podzólico
34	Paraná	482450	7200000	150	1	USC	1	Podzólico
35	Paraná	482450	7200000	150	1	USC	1	Podzólico
36	Paraná	482450	7200000	150	1	USC	1	Podzólico
37	Paraná	482450	7200000	150	1	USC	1	Podzólico
38	Paraná	482450	7200000	150	1	USC	1	Podzólico
39	Paraná	482450	7200000	150	1	USC	1	Podzólico
40	Paraná	482450	7200000	150	1	USC	1	Podzólico
41	Paraná	482450	7200000	150	1	USC	1	Podzólico
42	Paraná	482450	7200000	150	1	USC	1	Podzólico
43	Paraná	482450	7200000	150	1	USC	1	Podzólico
44	Paraná	482450	7200000	150	1	USC	1	Podzólico
45	Paraná	482450	7200000	150	1	USC	1	Podzólico
46	Paraná	482450	7200000	150	1	USC	1	Podzólico
47	Paraná	482450	7200000	150	1	USC	1	Podzólico

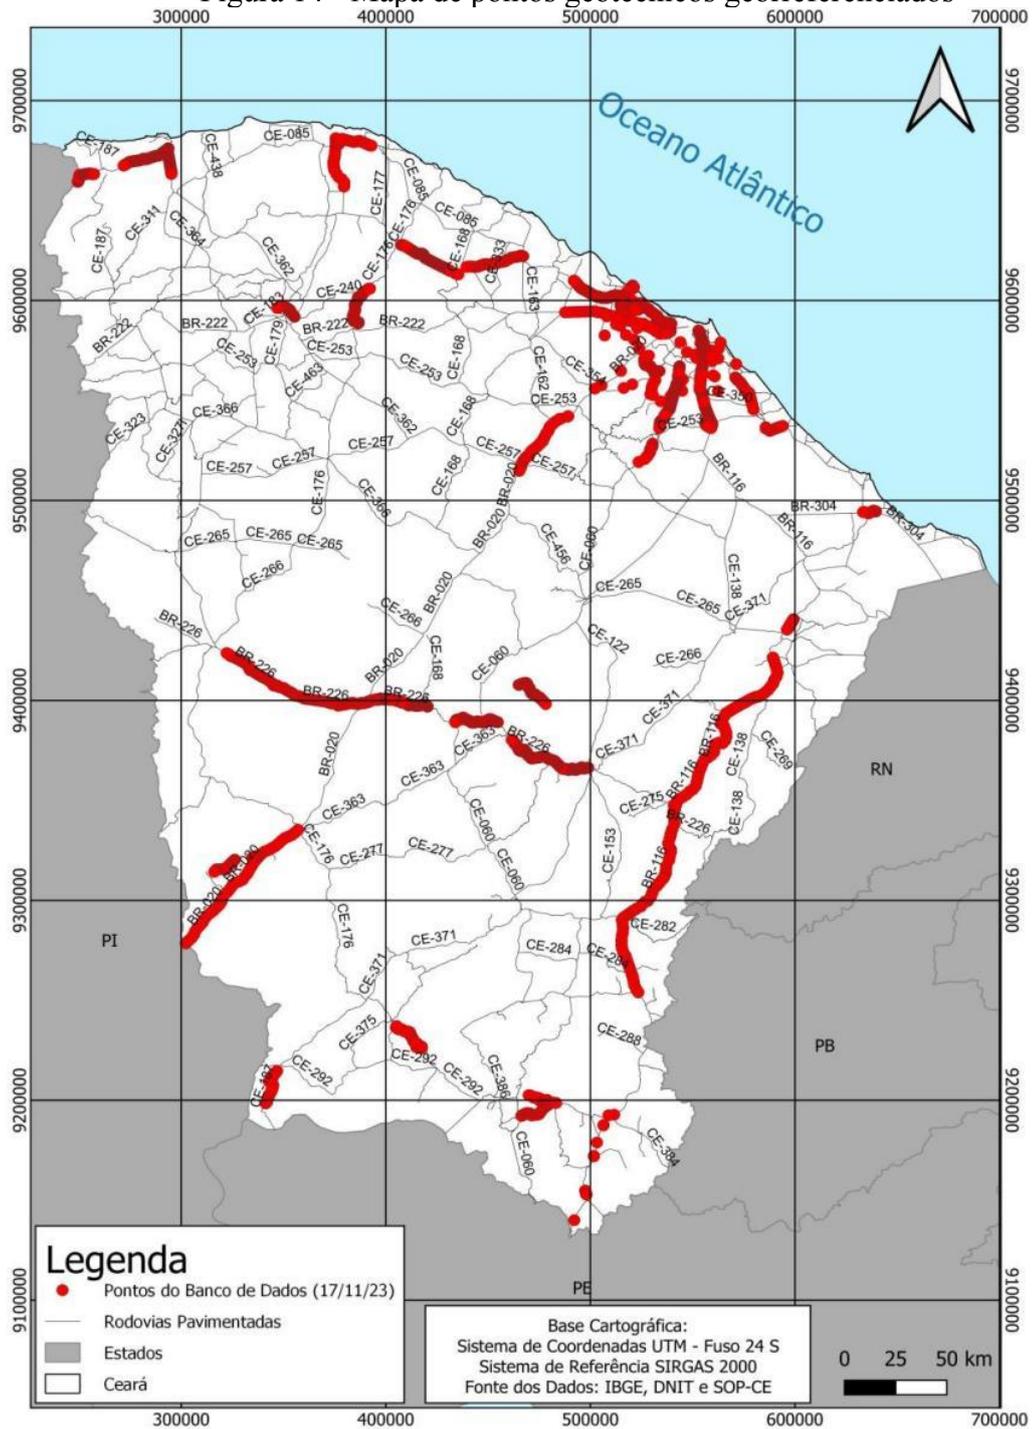
Fonte: Relatório de Pesquisa IPR RP, 2023.

Ao dispor das coordenadas UTM, torna-se viável correlacionar as coordenadas espaciais dos pontos amostrados nos projetos rodoviários com outras informações e camadas do meio físico terrestre. Essa integração é fundamental para a obtenção de variáveis necessárias na elaboração de mapas e na projeção dos futuros modelos a serem desenvolvidos no âmbito do projeto. Dessa forma, quanto mais abrangente a distribuição geográfica dos pontos, maior a capacidade de extrair modelos que representem adequadamente o comportamento mecânico dos solos em relação à sua distribuição espacial.

O banco de dados geotécnico atualmente contém 8.281 amostras de solos, originárias de todos os 47 projetos fornecidos pelo DNIT/CE (100% das amostras desses projetos). É importante salientar que certas peculiaridades identificadas em determinados trechos de projetos rodoviários inviabilizaram a realização do processo de georreferenciamento. Essa impossibilidade decorreu de perdas de referência geométrica ou alterações nas diretrizes de projetos anteriores. Em decorrência desse cenário, foram constituídos dois bancos de dados

distintos: um georreferenciado, contendo 5.194 amostras, e outro não georreferenciado, que abrange 3.087 amostras. O somatório desses conjuntos totaliza 8.281 amostras de solos, todas digitalizadas a partir dos projetos rodoviários em análise. A Figura 14 apresenta as localizações das amostras georreferenciadas.

Figura 14 - Mapa de pontos geotécnicos georreferenciados

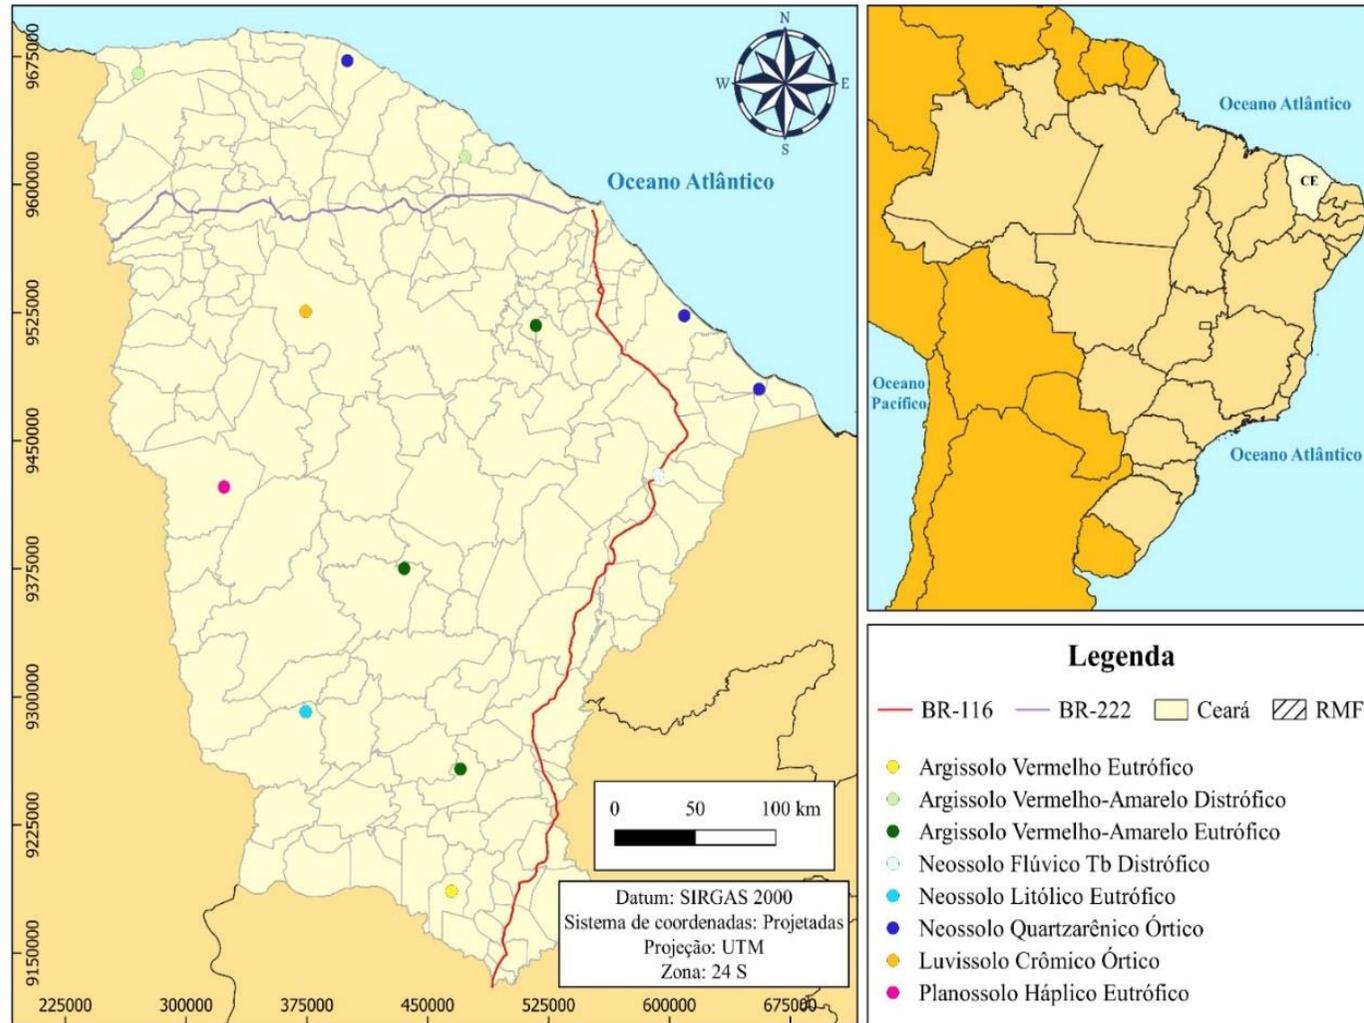


Fonte: Relatório de Pesquisa IPR RP, 2023.

Para os modelos de MR foram disponibilizados dados de amostras de solo coletadas em diferentes classes pedológicas do Estado do Ceará: Argissolo Vermelho-Amarelo Eutrófico, Argissolo Vermelho Eutrófico, Argissolo Vermelho-Amarelo Distrófico, Luvisolo Crômico Órtico, Neossolo Litólico Eutrófico, Planossolo Háptico Eutrófico, Neossolo Flúvico Tb Distrófico, Neossolo Quartzarênico Órtico. Cada uma das amostras foi distribuída, em sua

maior parte, ao longo dos municípios: Barbalha, Paraipaba, Santa Quitéria, Aiuaba, Mombaça, Baturité, Camocim, Crateús, Limoeiro do Norte, Aracati, Iracema, Berberibe e Várzea Alegre. As classes pedológicas mais frequentes foram Argissolo Vermelho-Amarelo Eutrófico, Neossolo Quartzarênico Órtico e Argissolo Vermelho-Amarelo Distrófico. Ambas as duas primeiras classes citadas corresponderam a 25% do total cada, enquanto a última classe mencionada representou 17% do total das classes identificadas no Estado do Ceará. As outras classes não citadas representaram apenas 8% cada uma. A Figura 15 apresenta os locais de cada ponto analisado para modelagem do MR.

Figura 15 - Mapa com os pontos analisados na modelagem de MR

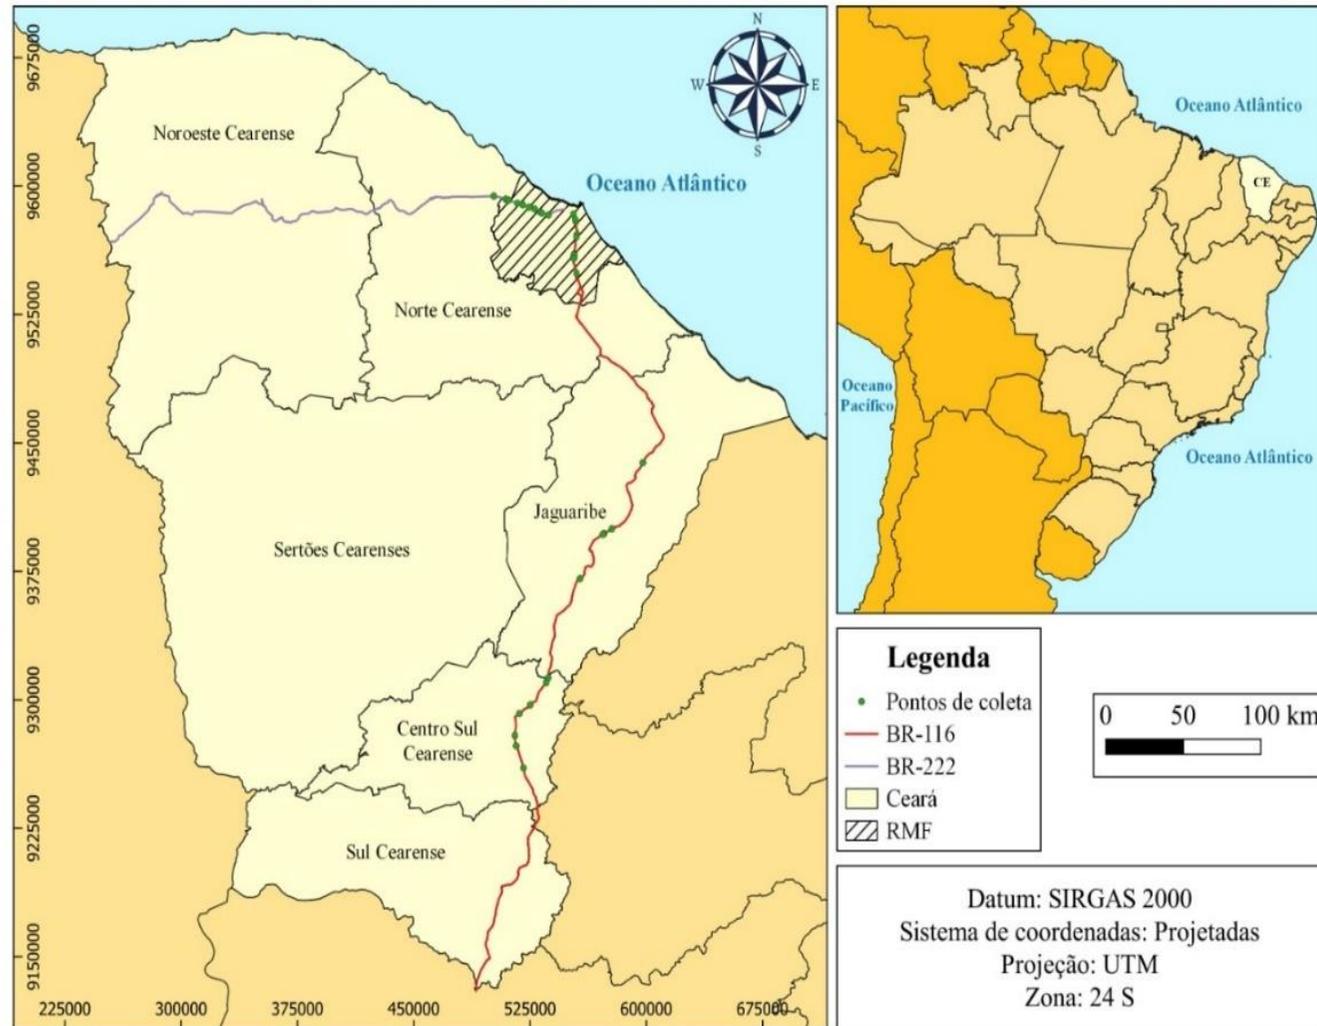


Fonte: Autor, 2023

#### 4.1.2 Modelo CBR

Para desenvolvimento do modelo CBR os dados foram extraídos do acervo de projetos do DNIT/CE e da SOP-CE. Inicialmente o banco de dados fornecido continha o total de 8281 dados de entrada-saída com informações de umidade ótima (OT), densidade (DEN), limite de liquidez (LL), índice de plasticidade (IP), faixas granulométricas de polegadas (P25,4), (P9,5), (P4,76), (2mm), (0,42mm), (0,074mm), CBR e classificação *American Association of State Highway and Transportation Officials* AASHTO. Todos esses dados geotécnicos fornecidos eram dos seguintes trechos das rodovias localizados no Estado do Ceará: BR 116, BR020, BR222, BR226, BR304, BR402, BR403. No entanto, trabalhou-se apenas com os trechos BR 116, BR 222 e os dados referentes ao subleito. Ao total trabalhou-se com 343 dados do tipo entrada-saída do modelo de origem, pois a modelagem com o conjunto total de 8281 dados de entrada-saída não apresentou valores de correlação acima de 0,70, indicando uma correlação relativamente fraca entre as variáveis utilizadas no modelo. Ademais, esse banco de dados foi ajustado para modelagem das redes neurais. Para os dados de entrada foram removidas as variáveis de subleito, Expansão (EXP) e faixa granulométrica de 50,8 (#2) que estavam no banco de dados, pois as colunas com os valores dessas variáveis eram iguais e isso interfere no processo de normalização. Quando todos os valores em uma coluna são iguais, a variação entre os valores é mínima ou inexistente. A Figura 16 mostra os pontos disponibilizados.

Figura 16 - Mapa com os trechos BR 116, BR 222 usados na modelagem de CBR



Fonte: Autor

### 4.1.3 Modelo MR

Para desenvolvimento do modelo MR os dados foram extraídos do banco de dados de ensaios realizados no INCT Asfalto - Laboratório de Mecânica dos Pavimentos. Inicialmente o banco de dados fornecido continha o total de 1342 dados de entrada-saída contendo as informações de percentuais de solo passantes nas peneiras (1", 3/8", #4, #10, #40, #200), classificação da *American Association of State Highway and Transportation Officials* (AASHTO), Limite de Liquidez (LL), massa específica seca máxima ( $\gamma_{dmax}$ ), umidade ótima (ot), *California Bearing Ratio* (CBR), tensão confinante ( $\sigma_3$ ), tensão desvio ( $\sigma_d$ ) e Módulo Resiliência (MR). Todos esses dados foram usados para criação dos modelos. Ao total foram criados 6 modelos diferentes, variando-se os dados de entradas e arquiteturas para cada modelo, sendo o MR comum a todos como dado de saída.

## 4.2 Modelagem

Para a criação do modelo de previsão das variáveis de MR e CBR foi empregado como ferramenta as RNA's, foi utilizado o software QNET 2000, em sua versão demo. O QNET é um programa perceptron multicamadas que utiliza o algoritmo de retropropagação do erro para o treinamento da rede neural artificial. O programa admite até oito camadas intermediárias de neurônios e a escolha entre quatro funções distintas de ativação (sigmoide, gaussiana, secante hiperbólica e tangente hiperbólica) (Dantas neto, 2004). Em geral, não há regras para a escolha da função de ativação a ser empregada no modelo de redes neurais, a escolha da função mais adequada é feita por tentativas e erros, ou seja, a que apresentar resultado mais satisfatório, nesta pesquisa a função que melhor apresentou resultados foi a função sigmoide.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

O monitoramento da convergência do algoritmo que ajustam os pesos no QNET pode ser feito de acordo com a evolução do coeficiente de correlação entre os valores que são calculados e os valores pretendidos em relação ao número de iterações (Amancio, 2014). O coeficiente de correlação é definido como: (Bussab e Morettin, 1987)

$$c(v_m, v_c) = \frac{\text{cov}(v_m, v_c)}{\sigma(v_m) \cdot \sigma(v_c)}$$

(11)

Onde:

$Cov(v_m, v_c)$ : covariância entre o valor medido e o valor calculado;

$\sigma(Vm)$ : desvio padrão dos valores medidos;

$\sigma(Vc)$ : desvio padrão dos valores calculados.

O QNET 2000 proporciona a modelagem por duas fases: treinamento e validação. Para realização do treinamento é necessário escolher dois parâmetros para ajustar os pesos sinápticos  $w_{kj}$ :  $\eta$  (taxa de aprendizagem) que afeta no processo de convergência do algoritmo de retropropagação dos erros; e o fator  $\alpha$  (momentum), que diminui a fragilidade do algoritmo durante essa convergência. Estes parâmetros manipulam o algoritmo de retropropagação na regulagem dos pesos sinápticos ( $w_{kj}$ ). O fator  $\alpha$  correlaciona-se com a estabilidade do algoritmo de retropropagação, geralmente adotado entre 0,8 e 0,9 (Dantas Neto, 2004).

Neste trabalho adotou-se os valores de 0,8 para o fator  $\alpha$  e para a taxa de aprendizagem  $\eta$  variando entre 0,001 e 0,15. Dessa forma de adoção de  $\eta$  permite que o programa otimize os valores aprendizagem fazendo-se a fase de treinamento com maior rapidez e minimizando o risco de não convergência numérica (Araújo, 2015). O programa QNET 2000 admite a mudança desses parâmetros a qualquer momento da fase de treinamento melhorando a eficiência, porém neste trabalho apenas o valor de  $\eta$  foi variado dentro de uma faixa determinada durante o treinamento e o fator  $\alpha$  foi mantido constante.

Antes de iniciar a fase de treinamento foi feito o tratamento dos dados, para tal, realizou-se a normalização das variáveis. É necessária esta normalização, tendo em vista que, as diferentes funções de ativação que realizam o cálculo dos neurônios fornecem valores dentro de um intervalo. Essa etapa também pode ser realizada no próprio programa, mas, apresenta desvantagens pois omite informações dos dados de entrada impedindo a implementação do modelo em planilhas de cálculo (Dantas Neto, 2004). Inicialmente os dados oriundos dos ensaios geotécnicos passaram por um pré-processamento para que se adequassem às restrições impostas pela modelagem neural no QNET 2000. Esse procedimento foi realizado da seguinte forma: numerização e normalização dos dados.

A numerização compreendeu em se atribuir um valor decimal aos dados que possuem valores alfanuméricos (variáveis qualitativas) proveniente de ensaios geotécnicos de laboratório como: o Índice de Plasticidade (IP), o Limite de Liquidez (LL) e a Classificação da

AASHTO, esta etapa foi realizada para ambos os modelos de CBR e MR, abaixo é apresentado uma tabela de exemplo desta etapa. O Quadro 2 e 3 apresentam exemplos de numerização dos dados alfanuméricos.

Quadro 2 - Numerização de dados alfanuméricos para o CBR

Variável	Dados Alfanuméricos	Numerizado
<b>LL</b>	NP	0
<b>IP</b>	NP	0
<b>Classificação AASTHO</b>	A-1-4	1,4
	A-1-A	1,6
	A-1-B	1,8
	A-2-4	2
	A-2-6	2,2
	A-2-7	2,4
	A-3	3
	A-4	4
	A-6	6
	A-7-5	7
A-7-6	7,6	

Fonte: Autor, 2023

Quadro 3 - Exemplo da Numerização de dados alfanuméricos para o MR

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

Fonte: Autor

Após numerização dos dados foi realizado a normalização, no qual consiste em transformar os valores decimais em valores limitantes de uma determinada função. Os valores

dos dados de entrada e saída foram normalizados entre 0,15 e 0,85, considerando uma relação linear entre os valores de mínimos e máximos de cada uma das variáveis ligadas utilizando a Equação 12. Os Quadros 4 e 5 mostram os valores máximos e mínimos das variáveis de CBR e MR. Nos Quadros 6 e 7, é possível observar um exemplo de normalização dos dados de MR e CBR com todos os resultados dos ensaios em valores decimais e em valores normalizados.

Quadro 4 - Valores máximos e mínimos das variáveis envolvidas na modelagem com utilização das redes neurais artificiais para CBR

<b>DADOS DE ENTRADA</b>	<b>MÁXIMO</b>	<b>MÍNIMO</b>
<b>OT (%)</b>	20	4,4
<b>DEN (g/cm<sup>3</sup>)</b>	2,23	1,66
<b>LL (%)</b>	74,3	0
<b>IP (%)</b>	35	0
<b>25,4 (#1")</b>	100	59
<b>9,5 (#3/8")</b>	100	51
<b>4,76 (#10)</b>	100	17
<b>2 (#10)</b>	100	21
<b>0,42 (#40)</b>	99	16
<b>0,0074 (#200)</b>	95	4
<b>CLASSIFICAÇÃO AASHTO</b>	7,6	1,4
<b>DADO DE SAÍDA</b>		
<b>ISC/CBR</b>	106	2

Fonte: Autor

Quadro 5 - Valores máximos e mínimos das variáveis envolvidas na modelagem com utilização das redes neurais artificiais para MR

<b>DADOS DE ENTRADA</b>	<b>MÁXIMO</b>	<b>MÍNIMO</b>
<b>OT (%)</b>	17	4,2
<b>DEN (g/cm<sup>3</sup>)</b>	2,19	1,65
<b>CBR (%)</b>	114	3,8
<b>EXP (%)</b>	5	0
<b>LL (%)</b>	46	0
<b>IP (%)</b>	16,7	0
<b>25,4 (#1")</b>	100	80
<b>9,5 (#3/8")</b>	100	40
<b>4,76 (#10)</b>	100	22

<b>2 (#10)</b>	100	18
<b>0,42 (#40)</b>	89	14
<b>0,0074 (#200)</b>	71	5
<b><math>\sigma_3</math></b>	0,137	0,021
<b><math>\sigma_d</math></b>	0,412	0,021
<b>CLASIFICACÃO AASHTO</b>	7,5	1,1
<b>DADO DE SAÍDA MR</b>	2038	50,069

Fonte: Autor

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

(12)

Onde:

$X'$  = Variável resultante da normalização;

$X$  = Variável a ser normalizada;

$X_{MIN}$  = Valor mínimo da variável a ser normalizada;

$X_{MAX}$  = Valor máximo da variável a ser normalizada.

Quadro 6 - Exemplo de normalização dos dados de MR

Variável	Valor Decimal	Valor Normalizado
<b>OT (%)</b>	14,92	0,74
<b>DEN (g/cm3)</b>	1,93	0,51
<b>CBR (%)</b>	14	0,21
<b>EXP (%)</b>	5	0,85
<b>LL (%)</b>	35	0,68
<b>IP (%)</b>	5,7	0,39
<b>25,4</b>	100	0,85
<b>9,5</b>	96	0,79
<b>4,76</b>	94	0,78
<b>2</b>	92	0,67
<b>0,42</b>	70	0,52
<b>0,074</b>	40	0,85
<b>Classificação AASHTO</b>	4	0,85
<b><math>\sigma_3</math></b>	0,137	0,46

$\sigma_d$	0,412	0,26
MR	385	0,85

Fonte: Autor

Quadro 7 - Exemplo de normalização dos dados de CBR

Variável	Valor Decimal	Valor Normalizado
OT (%)	8,1	0,316
DEN (g/cm <sup>3</sup> )	2,136	0,734
LL (%)	56,8	0,685
IP (%)	32,3	0,796
25,4	97	0,798
9,5	79	0,550
4,76	65	0,554
2	58	0,477
0,42	50	0,436
0,074	27	0,326
Classificação AASHTO	2	0,217
CBR (%)	71	0,614

Fonte: Autor

Foi realizado o teste com várias arquiteturas distintas, alterando o número de camadas, ou de neurônios em função dos resultados obtidos na fase de treinamento e validação. O critério para interromper ou pausar a modelagem baseou-se na observação do comportamento dos valores de correlação durante as fases de treinamento e validação. Se, em qualquer ponto do processo de modelagem, os valores de correlação caírem abaixo do limite de 0,80, a respectiva modelagem é descartada. Posteriormente, um novo modelo com maior número de iterações é construído, até atingir um valor de correlação igual ou superior a 0,80.

### 4.3 Mapas Geológicos-Geotécnicos

Nos últimos anos, muitos projetos relacionados ao aprimoramento de Sistemas de Informação Geográfica (SIGs) começaram a surgir devido ao avanço da tecnologia e da computação. Entre as várias opções de software de código aberto disponíveis, o QGIS (QGIS Development Team, 2017) se destaca, principalmente por sua crescente popularidade global e a abundância de recursos de suporte disponíveis para os usuários.

O QGIS, também conhecido como Quantum GIS, é um Sistema de Informação Geográfica (SIG) que permite a criação, visualização, análise e edição de dados geoespaciais muito utilizado em pesquisas científicas. De acordo com Bruno (2017) o QGIS é um programa que faz parte da Open Source Geospatial Foundation (OSGeo) e é conduzido por um conjunto engajado de desenvolvedores voluntários que consistentemente disponibilizam novas versões e solucionam problemas identificados nesta aplicação, o QGIS está disponível gratuitamente para uso e não requer taxas para sua ativação e utilização (Yu et. al 2016). Apresenta ainda boas possibilidades de personalização, como idiomas e plugins. O QGIS funciona em Linux, Unix, Mac OSX, Windows e Android e suporta inúmeros formatos de vetores, rasters, bases de dados e funcionalidades. Lobo et. al (2012) enfatizam que o QGIS se tornou uma plataforma de exibição de informações geográficas com amplos formatos geoespaciais de leitura e escrita. Os mapas geológico-geotécnicos elaborados neste trabalho foram georreferenciados no sistema de coordenadas UTM, Datum geocêntrico SIRGAS2000, todos os mapas foram feitos no software QGIS em sua versão 3.22.

Os mapas de CBR foram elaborados a partir do georreferenciamento destacado no Capítulo 03, para tal, foram utilizados os mesmos dados da modelagem neural do CBR. Para os mapas de MR, foram usados os mesmos pontos do mapa de CBR, porém, realizou-se estimativas de valores de módulos de resiliência utilizando o melhor modelo neural de MR, pois, esses pontos não dispunham de ensaios de rigidez do solo, uma vez que, neste projeto não foram realizados tais ensaios. O melhor modelo foi escolhido com base nos valores do coeficiente de determinação ( $R^2$ ) e na necessidade de menos parâmetros de entrada. As estimativas de MR foram realizadas considerando  $\sigma_3 = 0,051\text{MPa}$  e  $\sigma_d = 0,103\text{MPa}$ .

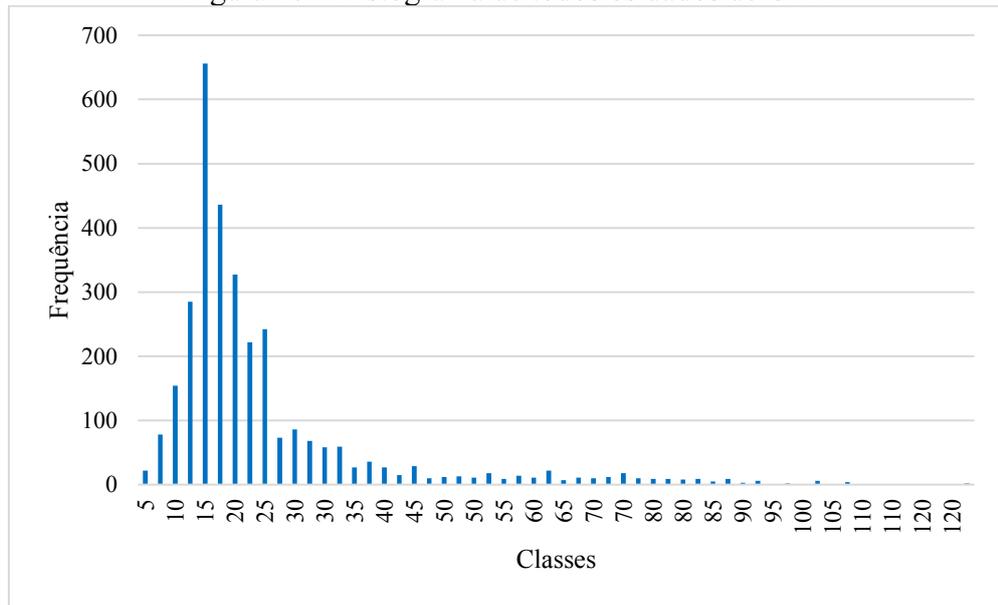
## **5 RESULTADOS E DISCUSSÕES**

Neste capítulo, estão expostos todos os resultados alcançados ao longo do desenvolvimento do modelo de previsão para CBR e MR usando redes neurais artificiais. Neste contexto, são disponibilizados os seguintes elementos: os resultados da progressão do treinamento nas diversas arquiteturas examinadas para os modelos; os índices de correlação associados às várias configurações estudadas; análise de variabilidade de todos os dados; mapas geológico-geotécnico; as recomendações e diretrizes dos modelos e mapas geológico-geotécnicos no Estado do Ceará.

### **5.1 Modelagem para o CBR**

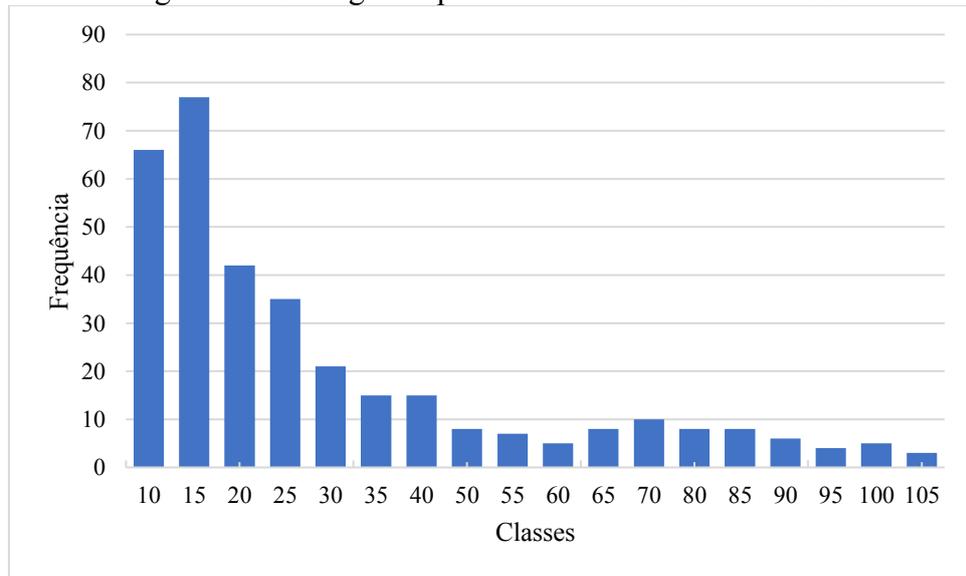
Foi realizado a análise da distribuição dos dados de CBR do banco de dados com as 8281 amostras disponibilizados inicialmente. Por se tratar de muitos dados trabalhou-se com uma maior quantidade de classes para construção dos gráficos de histograma. Conforme Figura 17 os dados tiveram uma alta variabilidade, a maior frequência dos valores de CBR para esse banco de dados, variou entre o intervalo de 10% a 20%. Para o modelo de CBR desenvolvido para os trechos da BR 116 e BR 222 (Figura 18), no qual continha 343 dados, foi possível observar uma maior variação nos valores do histograma quando comparado com o banco de dados com as 8281 amostras. Para a análise de distribuição dos trechos da BR 116 e BR 222 a faixa com maior frequência dos valores de CBR variou entre 10% e 25%. Foi possível verificar que ambos os gráficos apresentaram a mesma variabilidade e dispersão de valores. Na Figura 19 são indicados os valores máximos e mínimos, média e desvio padrão dos dois bancos de dados evidenciando esse comportamento.

Figura 17 - Histograma de todos os dados de CBR



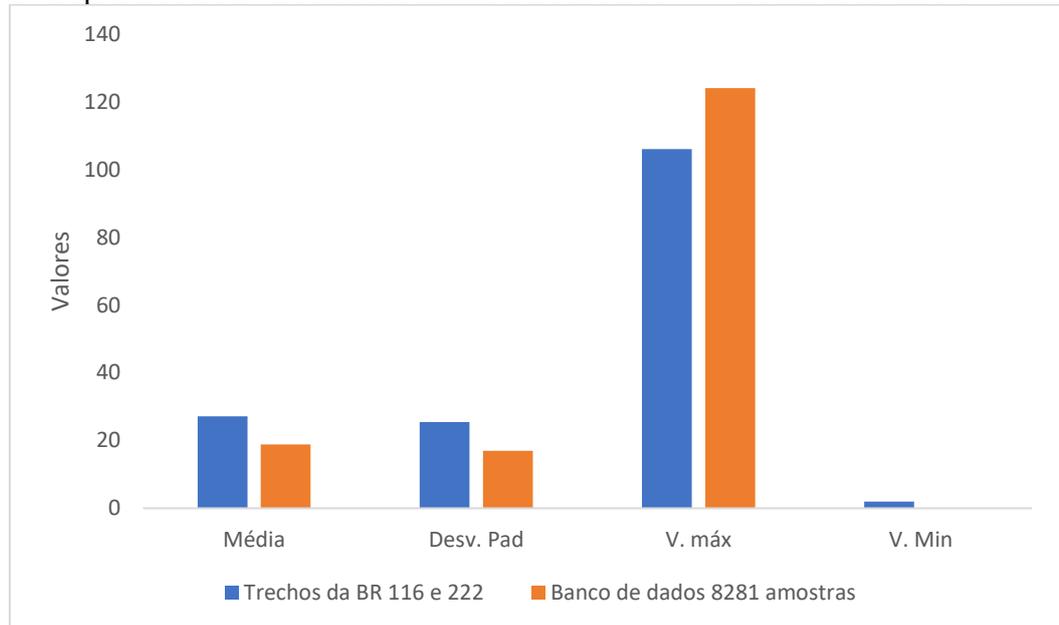
Fonte: Autor

Figura 18 - Histograma para os trechos da BR 116 e 222



Fonte: Autor

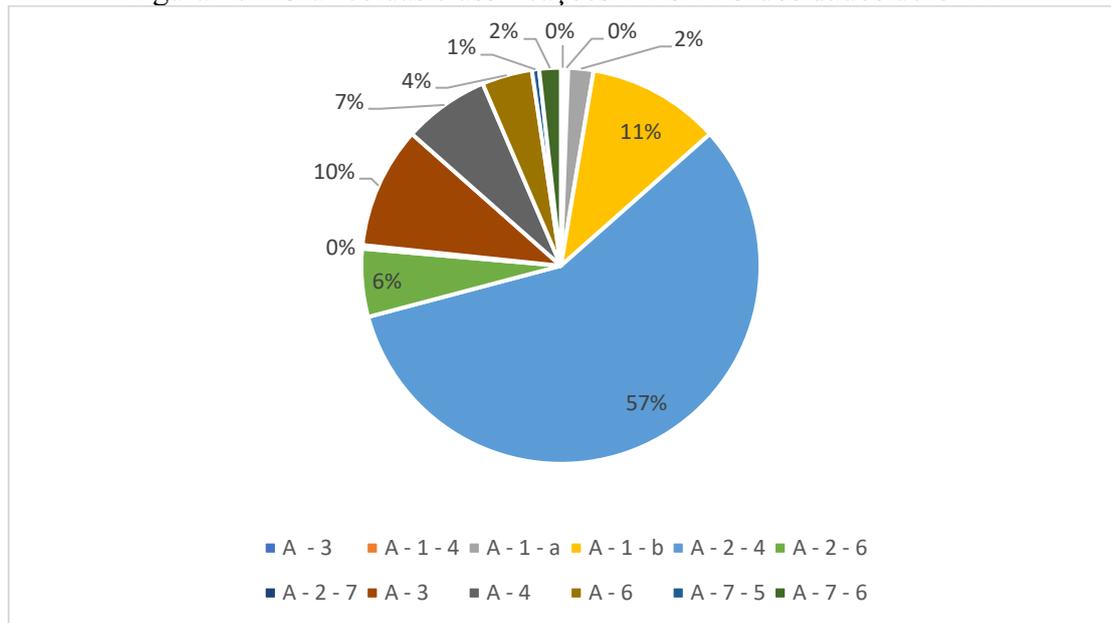
Figura 19 - Comparação dos valores máximo e mínimo, média, desvio padrão do modelo para os trechos da BR 116 /222 e o banco de dados com 8281 amostras



Fonte: Autor (2023)

Foi possível observar que das amostras do banco de dados as três classes que mais se repetiram foram as classes: A-2-4 representando 57%, seguido da classe A-1-b representando 11% e A-3 representando 10% do total de amostras do banco de dados (Figura 20). Estes foram os tipos de solos com maior predominância nos trechos ao longo das estradas BR 116/222. A classe A-2-4 é predominantemente um solo granular composto por partículas como areia e cascalho ou ambos. Para Senço (2007) o solo classificado sobre o grupo A-2 contém uma das principais faixas de solos seja pelo comportamento como subleito, quanto pela possibilidade de estabilização com ligantes.

Figura 20 - Gráfico das classificações AASTHO dos dados de CBR



Fonte: Autor (2023)

Ressalta-se que os solos classificados no subgrupo A-2-4, possuem alguma quantidade de pedregulho e silte, tendo em vista que o segundo material pode estar misturado com areia fina, e neste caso, o silte é não plástico. Os solos do tipo A-3 também são compostos principalmente por partículas granulares, entretanto, difere-se por possuir uma distribuição granulométrica mais ampla. Solos de com essas classificações são caracterizados por possuírem uma boa faixa de graduação, sendo maior parte composto por areia e uma pequena quantidade de partículas finas, ademais, é usado muitas vezes em construção de estradas. Para Souza (2021) o Estado do Ceará é predominantemente coberto de materiais do tipo granular, com cerca de 80%, e por conseguinte, conferindo um comportamento de bom a excelente no que se refere ao seu uso em pavimentação. Os solos da classe A-1-b de acordo com classificação AASHTO, é caracterizado por um material com predominância de pedregulhos e areias, com comportamento considerado de excelente a bom para uso geral em subleito (Lima, 2018). As classes A-7-5, A-1-4 e A-2-7 foram as de menores proporções e também as classes em menor quantidade no banco de dados, as classes A-1-4 e A-2-7 apresentaram apenas uma amostra respectivamente.

Explorando o banco de dados, pode-se ressaltar que dentre as amostras que o compõe, 197 (57%) e 34 (10%) são de solos considerados granulares não-coesivos, apenas 37 (11%) são de solos considerados coesivos, composto principalmente por argila, as outras classes apresentaram representatividade abaixo de 10% conforme é apresentado no Quadro 8.

Assim, foi possível observar que as amostras tiveram uma boa representatividade espacial (boa distribuição na área de estudo) dos pontos de vista qualitativo e quantitativo, resultado semelhante em estudo por Guilherme (2020).

Quadro 8 - Contagem dos dados da classificação AASHTO/TRB/HRB

<b>Classificação AASHTO/TRB/HRB</b>	<b>Contagem</b>
A - 2 - 4	197
A - 1 - B	37
A - 3	34
A - 4	24
A - 2 - 6	19
A - 6	14
A - 1 - A	7
A - 7 - 6	6
A - 7 - 5	3
A - 1 - 4	1
A - 2 - 7	1
<b>Total</b>	<b>343</b>

Fonte: Autor

### 5.1.2 Modelos Neurais

Para desenvolvimento do primeiro modelo neural, houve a tentativa de trabalhar com todas as 8281 amostras do banco de dados, porém não foram obtidos bons coeficientes de correlação, todas apresentavam valores de correlação abaixo de 0,4. Então, foram selecionados apenas as regiões da BR 222 e BR 116 do banco de dados, que continham todas as variáveis do banco de dados. Após essa alteração o banco de dados utilizado no modelo de RNA possuía 343 dados de entrada-saída. Foram separados aleatoriamente 80% desses dados para treinamento e 20% para validação do primeiro modelo. O segundo e terceiro modelo variaram-se a quantidade de dados para treinamento, sendo para o segundo modelo 85% dos dados foram usados para treinamento e 15% para validação, o terceiro modelo continha 97% para treinamento e 3% para validação. Essas modificações necessárias para tentativa de se obter melhores valores de correlação. Tendo em vista que os dois primeiros modelos não atingiram bons valores de correlação, para o terceiro necessitou-se alterar além da quantidade de dados de treinamento e validação. O Quadro 9 mostra as alterações para cada modelo testado.

A busca pela melhor arquitetura foi feita através do processo de tentativa e erro, variando-se o número de camadas ocultas e de neurônios ocultos. Pois, a quantidade de neurônios na camada de entrada e de saída é definida pelo problema, que neste caso são doze

neurônios na camada de entrada (um para cada variável escolhida) e um neurônio na camada de saída referente ao CBR. É possível verificar que os melhores resultados são obtidos a partir de quatro camadas ocultas. Isto aponta que a previsão do CBR é um fenômeno complexo, demandando um grande número de sinapses para armazenagem do conhecimento e desenvolvimento do modelo.

Quadro 9 - Distribuição dos dados em cada modelo de CBR

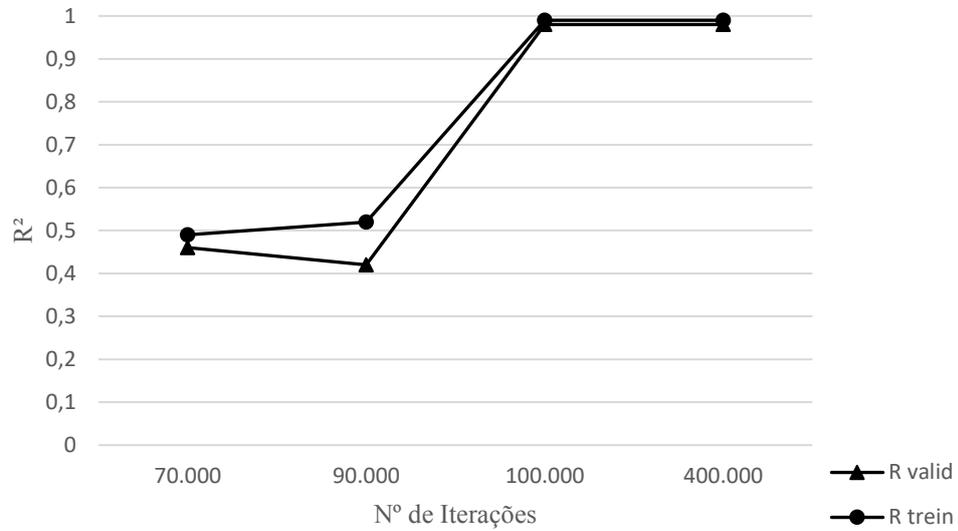
<b>DADOS</b>			
<b>MODELO</b>	<b>Treinamento</b>	<b>Validação</b>	<b>Dados retirados da Validação e Incluídos no Treinamento</b>
<b>CBR C1</b>	<b>275</b>	<b>68</b>	
<b>CBR C2</b>	<b>291</b>	<b>51</b>	
<b>CBR C3</b>	<b>332</b>	<b>10</b>	<b>26</b>

Fonte: Autor

Após aquisição dos dados, foi avaliado de forma criteriosa o conjunto de exemplos utilizados para criação dos modelos de redes neurais, examinando-se a consistência do conjunto de dados disponibilizados, ou mesmo possíveis erros na transcrição de seus resultados. A Figura 21 compara a evolução do comportamento de correlação para a fase de treinamento e validação.

Para alcançar um valor ótimo na validação primeiramente o modelo C3 foi testado e não obteve valor acima de 0,80 para o treinamento, então, os dados mais discrepantes da etapa de validação foram inseridos na etapa de treinamento, mesmo processo observado na literatura e adotado por outros autores (SILVERA, 2014; ARAÚJO, 2015). Esse mesmo método de ajuste foi observado por Silveira (2014) e com o objetivo de fazer com que a rede entendesse melhor o fenômeno. Para Araújo (2015) estes dados que apresentaram maior discrepância, possivelmente possuem um comportamento exclusivo, mais específico e complexo. Os resultados mostram que a exclusão e a modificação dos dados, levaram a um aprimoramento do modelo, fazendo com que a rede conseguisse realizar uma previsão de forma mais eficaz. O Quadro 10 apresenta os valores de correlação para cada modelo.

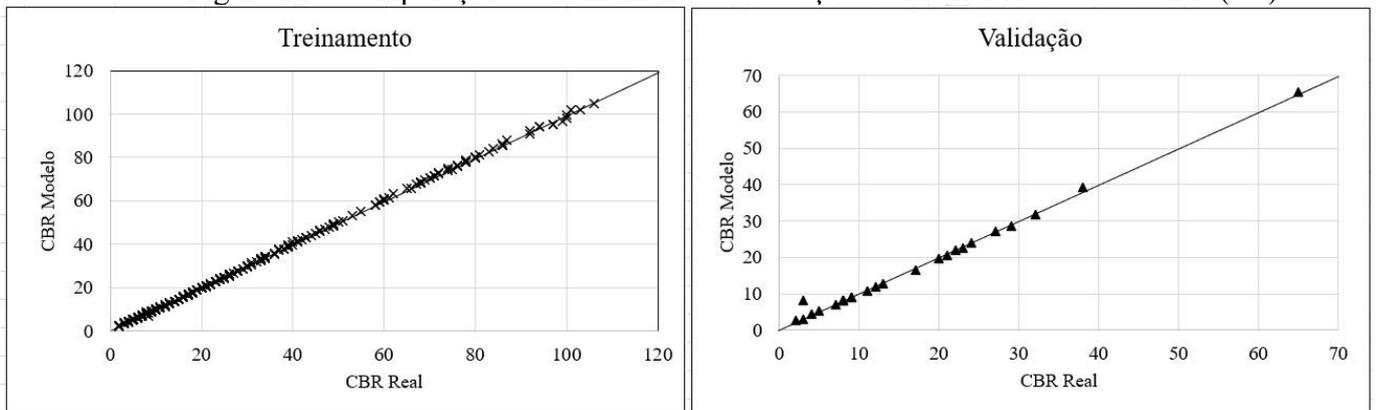
Figura 21 - Evolução das correlações com número de iterações na fase de treinamento e validação do modelo C3



Fonte: Autor

A Figura 22 é uma comparação entre os valores reais e gerados pelo modelo utilizados para cálculo do CBR. Observa-se que tanto na fase de treinamento quanto na fase de validação os valores foram bem próximos.

Figura 22 - Comparação do treinamento e validação do melhor modelo de CBR (C3)



Fonte: Autor

Quadro 10 - Valores das correlações de acordo com cada modelo de CBR

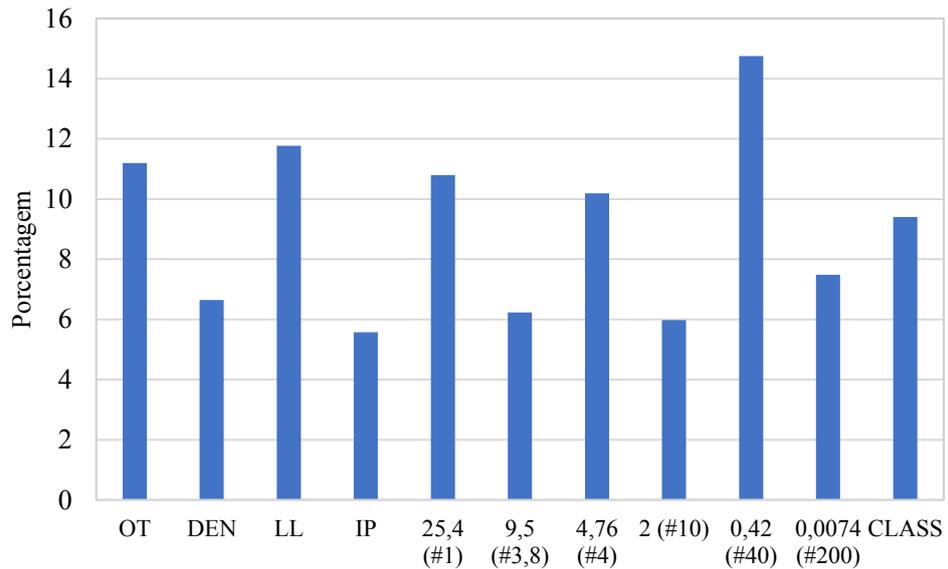
Modelo	Arquitetura	Correlação no treinamento	Correlação na validação
C1	A:12-15-14-10	0,73	0,40
C2	A:12-15-12-9	0,92	0,73

C3	A:12-18-15-12-9-1	0,99	0,98
----	-------------------	------	------

Fonte: Autor

No Apêndice A está apresentado os pesos sinápticos e bias para o modelo C3 de CBR. Para cada variável de entrada do modelo de CBR C3 foi criado um gráfico com o percentual de contribuição dos dados de entrada (Figura 23). Foi analisado que a variável de maior influência para o modelo C3 pertence as faixas granulométricas, sendo percentual que passa na peneira de 0,42mm com 14,75% seguido do limite de liquidez com 11,77% e umidade ótima com 11,20%. A variável de entrada com menor impacto para o resultado final do modelo foi o índice de plasticidade com 5,57%.

Figura 23 - Percentual de contribuição das variáveis para o modelo de CBR

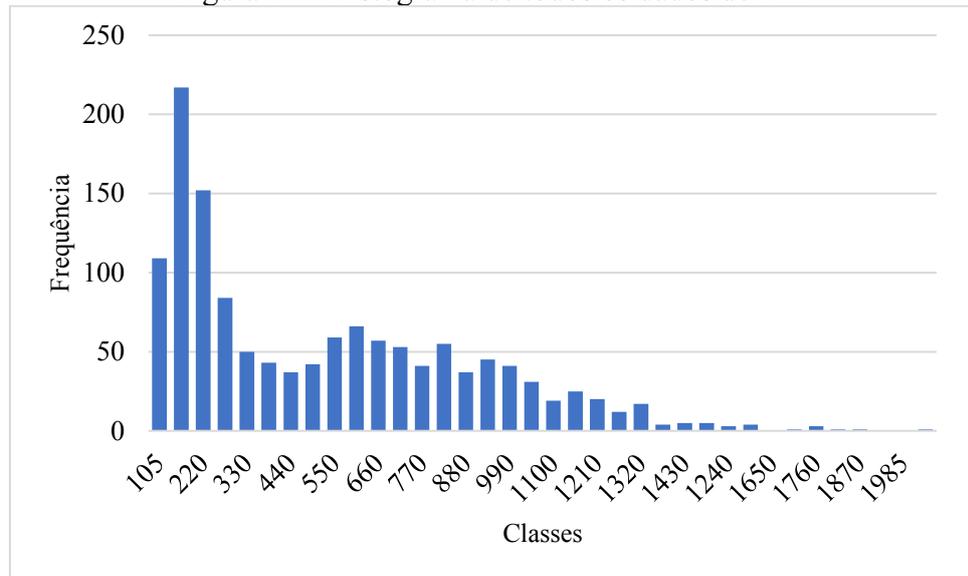


Fonte: Autor

## 5.2 Modelagem para o MR

Foi realizada a análise da distribuição com os 1340 valores do banco de dados disponibilizados. Conforme mostra a Figura 24 os dados tiveram uma alta variabilidade, a maior frequência dos valores de MR variou entre o intervalo de classes 105MPa à 330Mpa.

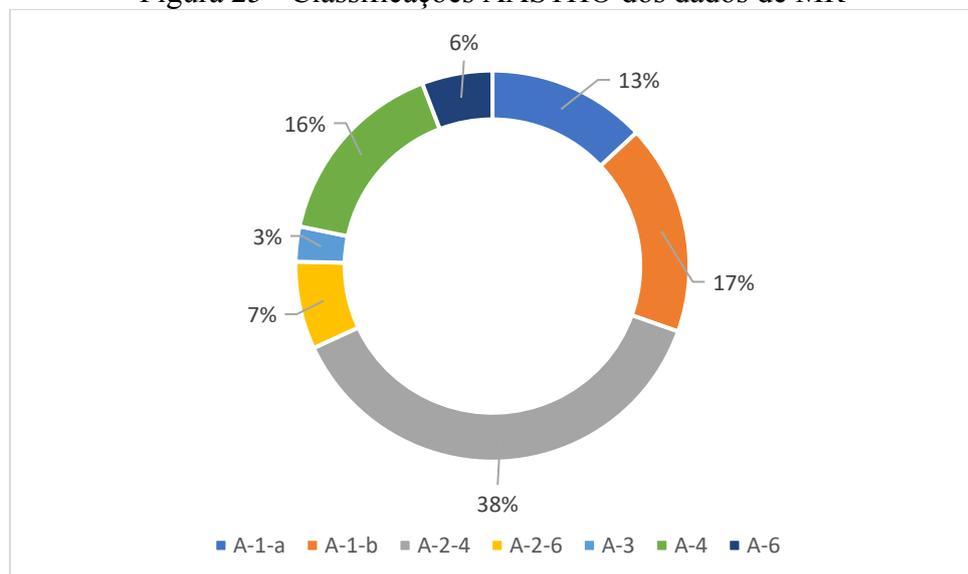
Figura 24 - Histograma de todos os dados de MR



Fonte: Autor (2023)

Analisando a classificação AASHTO do banco de dados de MR foi possível notar que de todas as amostras do banco de dados, a classe que mais se repetiu foi a A-2-4 representando 38% do total, seguido das classes A-1-b e A-4 representando 17% e 16% respectivamente. De acordo com Souza *et al.* (2021) que analisaram cerca de 1790 amostras de solos de projetos rodoviários, os solos predominantes no Ceará são em sua maioria do grupo A-2-4, seguidos pelos solos da classe A-1-b. As classes A-2-6, A-6 e A-3 aparecem em baixas proporções e foram as classes em menor quantidade no banco de dados. Na Figura 25 é possível observar o comportamento de todas as classes.

Figura 25 - Classificações AASTHO dos dados de MR



Fonte: Autor (2023)

### 5.2.1 Modelos Neurais

Para as previsões do MR, inicialmente, foram desenvolvidos seis modelos distintos, alternando as variáveis de entrada e o número de neurônios na camada intermediária de cada modelo. Os resultados dos diferentes modelos dessas estimativas foram organizados de forma a possibilitar sua interpretação e análise. Para alguns modelos (M2, M5 e M6) foram testadas várias arquiteturas até atingir valores de coeficiente de correlação na validação acima de 0,7, o que pode indicar uma forte associação entre as variáveis de cada modelo. No Quadro 11 são indicados os valores de correlação para as etapas de treinamento e validação dos modelos neurais desenvolvidos, além das arquiteturas de rede. No Quadro 12 é apresentado todos os modelos e os dados de entrada de cada um.

Quadro 11 - Valores das correlações de acordo com cada modelo de MR

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

Fonte: Autor

Quadro 12 - Dados de entrada de cada modelo de MR

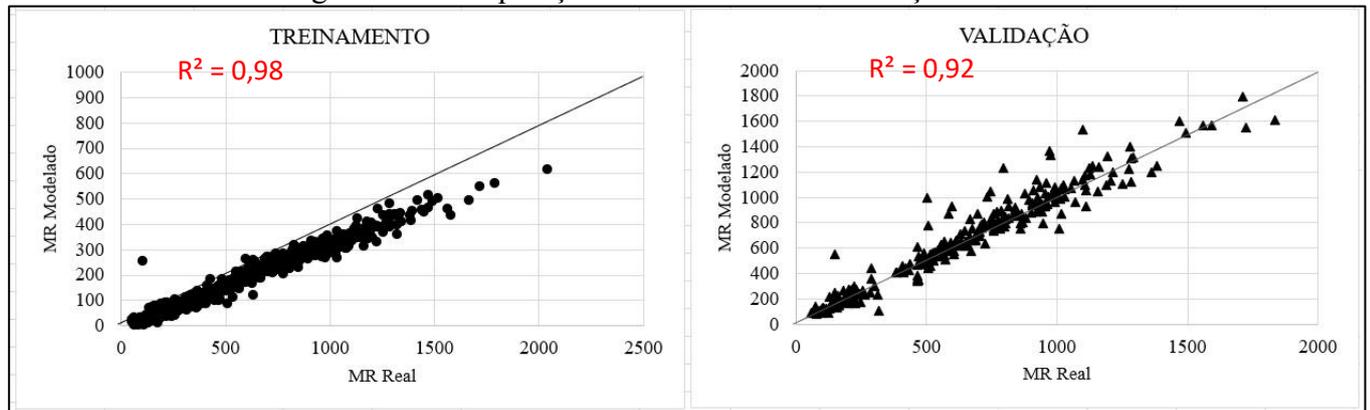
MODELOS	DADOS DE ENTRADA							
M1	OT (%)	DEN (g/cm3)	CBR (%)	EXP (%)	LL (%)	IP (%)	Class	25,4
	9,5	4,76	2	0,42	0,074	$\sigma_3$	$\sigma_d$	
M2	CBR (%)	DEN (g/cm3)	25,4	9,5	4,76	2	0,42	0,074
	$\sigma_3$	$\sigma_d$	Class					
M3	OT (%)	DEN (g/cm3)	25,4	9,5	4,76	2	0,42	0,074
	$\sigma_3$	$\sigma_d$						
M4	OT (%)	DEN (g/cm3)	9,5	2	0,074	$\sigma_3$	$\sigma_d$	
M5	OT (%)	DEN (g/cm3)	CBR (%)	EXP (%)	Class	$\sigma_3$	$\sigma_d$	
M6	DEN (g/cm3)	CBR (%)	EXP (%)	OT (%)	Class	25,4	9,5	4,76
	2	0,42	0,074	$\sigma_3$	$\sigma_d$			

Fonte: Autor

## 5.2.2 Modelo M1

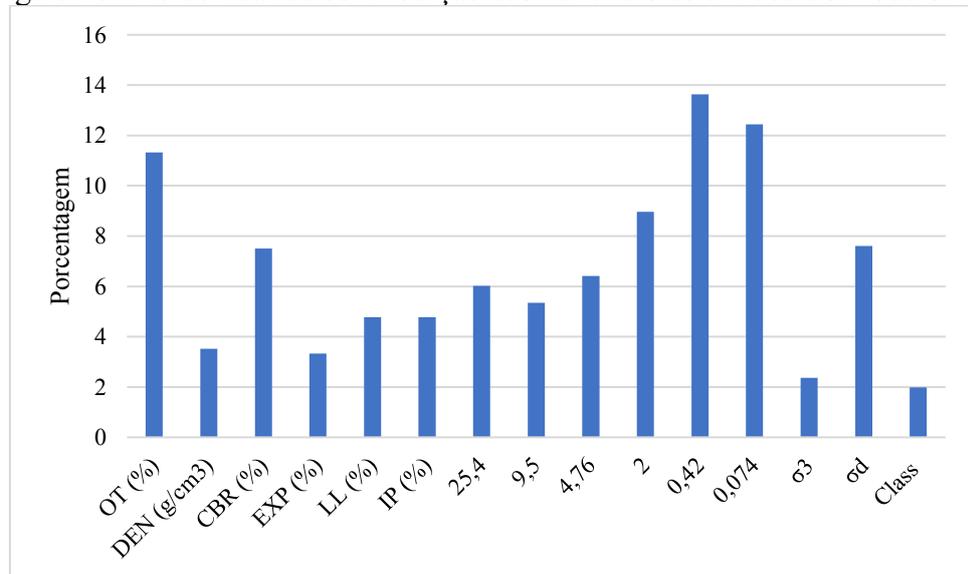
O modelo M1 para estimação individual do MR apresentou as seguintes camadas de entradas: OT, DEN, CBR, EXP, LL, IP, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class. A Figura 26 mostra os valores de correlação obtidos para esse modelo. A variável de maior influência para o modelo M1 pertence às faixas granulométricas e percentual que passa na peneira de 0,42mm com 13,63% seguido do percentual que passa na peneira 0,074mm com 12,44% e umidade ótima com 11,33%. Para este modelo a variável de menor impacto foi a classificação AASHTO. A Figura 27 mostra o gráfico com os valores de contribuição das variáveis.

Figura 26 - Comparação do treinamento e validação do modelo M1



Fonte: Autor

Figura 27 - Percentual de contribuição das variáveis de entrada do modelo M1

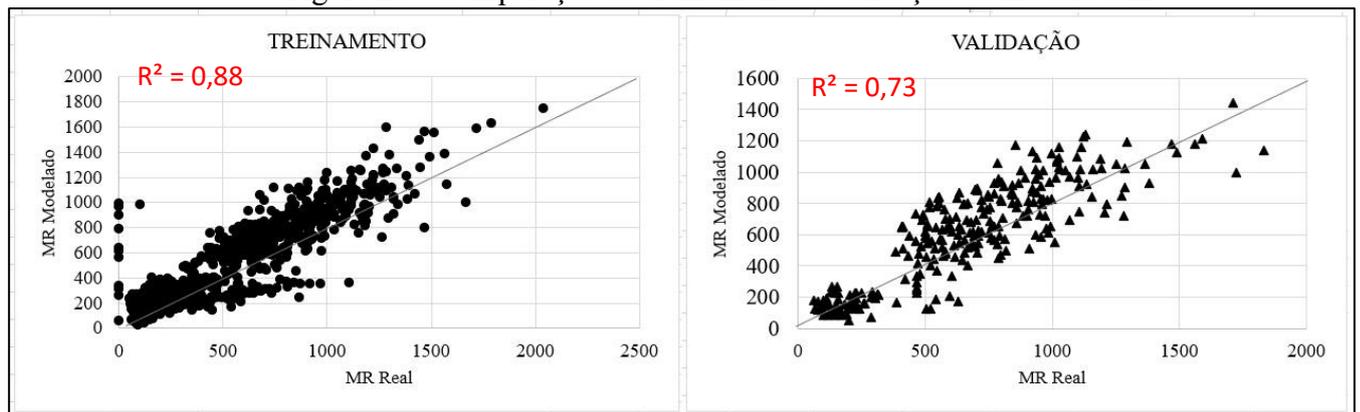


Fonte: Autor

### 5.2.3 Modelo M2

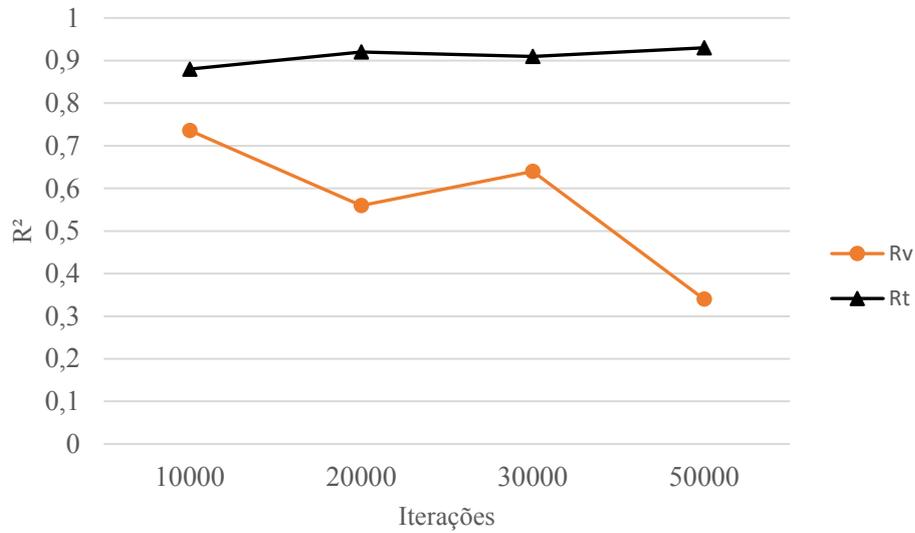
O modelo M2 para estimativa individual do MR utilizou como dados de entrada as seguintes variáveis: DEN, CBR, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class. A Figura 28 mostra os valores de correlação e o comparativo entre os valores reais e os modelados nas fases de treinamento e validação. Comparando o número de iterações nas fases de treinamento e validação, o maior valor de correlação para a validação foi obtido com dez mil iterações (Figura 29). Quanto ao percentual de contribuição a variável de maior influência para o modelo M2 foi a densidade com 25,64% seguido da classificação AASHTO com 14,18% e a tensão confinante com 10,37%. Para este modelo a variável de menor impacto foi a percentual que passa na peneira de 2mm (Figura 30).

Figura 28 - Comparação do treinamento e validação do modelo M2



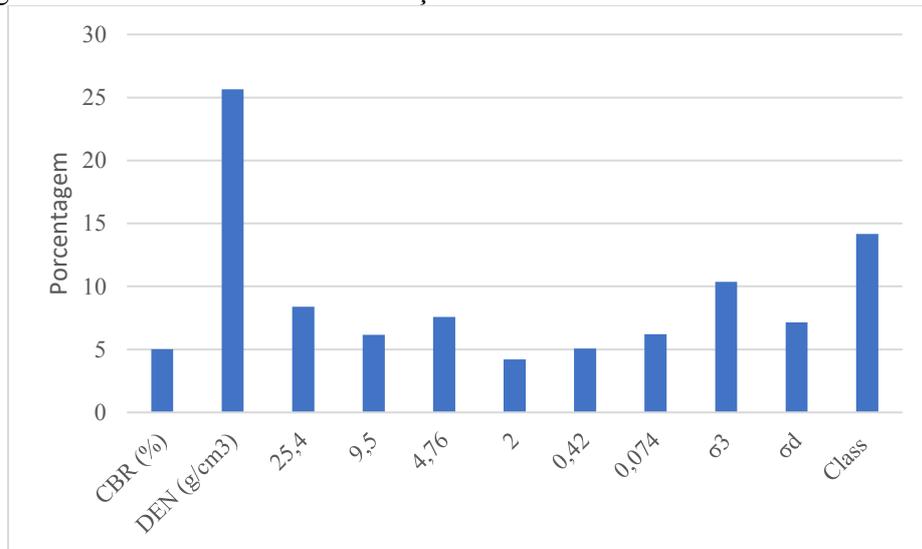
Fonte: Autor

Figura 29 - Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura



Fonte: Autor

Figura 30 - Percentual de contribuição das variáveis de entrada do modelo M2



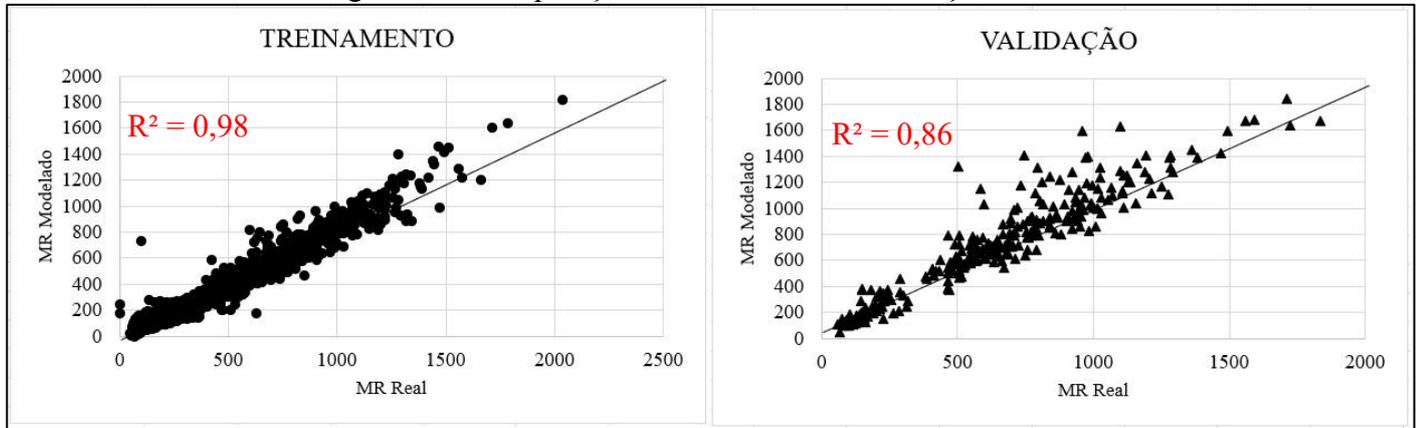
Fonte: Autor

#### 5.2.4 Modelo M3

O modelo M3 utilizou dez variáveis de entrada: OT, DEN, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$  e  $\sigma_d$ . A Figura 31 mostra os valores de correlação obtidos para esse modelo. As variáveis de maior influência para o modelo M3 foram os percentuais que passam na peneira de 9,5mm com 16,39% seguido do percentual que passa na peneira 0,074mm com

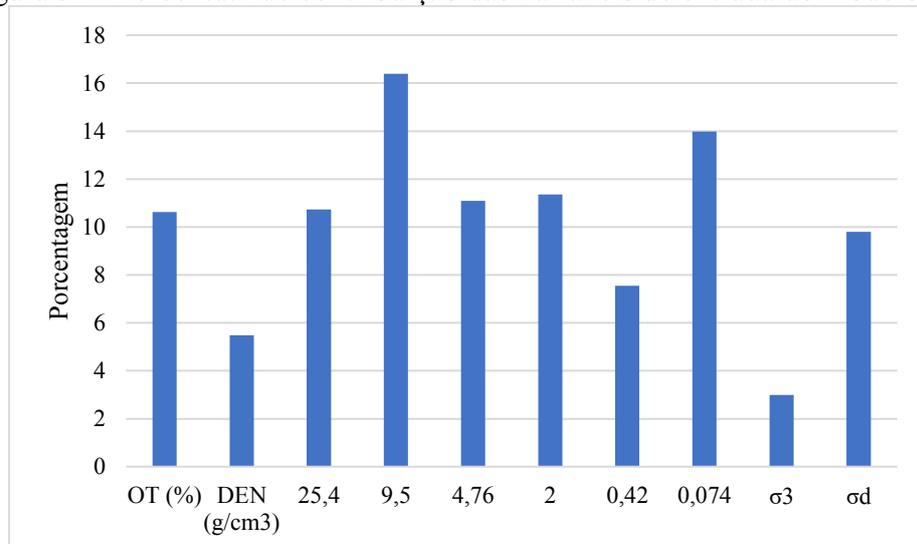
13,98% e percentual da peneira de 2mm com 11,36%. Para este modelo a variável de menor impacto foi a tensão de confinamento ( $\sigma_3$ ) (Figura 32).

Figura 31 - Comparação do treinamento e validação do modelo M3



Fonte: Autor

Figura 32 - Percentual de contribuição das variáveis de entrada do modelo M3



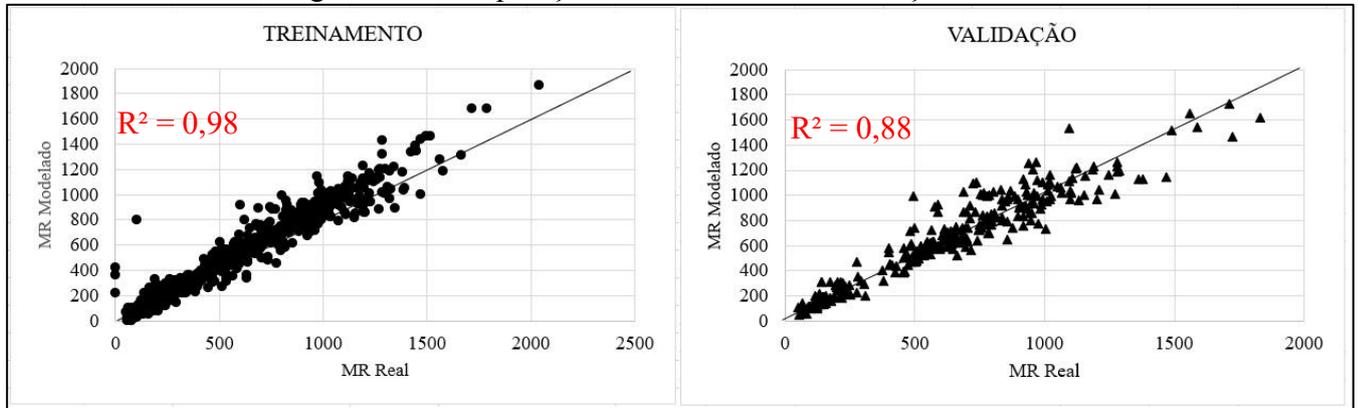
Fonte: Autor

### 5.2.5 Modelo M4

O modelo M4 para estimativa utilizou 7 variáveis de entrada: OT, DEN, (P9,5), (P2), (P0,074),  $\sigma_3$  e  $\sigma_d$ . A Figura 33 mostra os valores de correlação obtidos para esse modelo. A variável de maior influência para o modelo M4 foi a umidade ótima com 18,67% seguido da tensão de desvio ( $\sigma_d$ ) com 18,32% e percentual passante na peneira de 0,074mm com 16,14%.

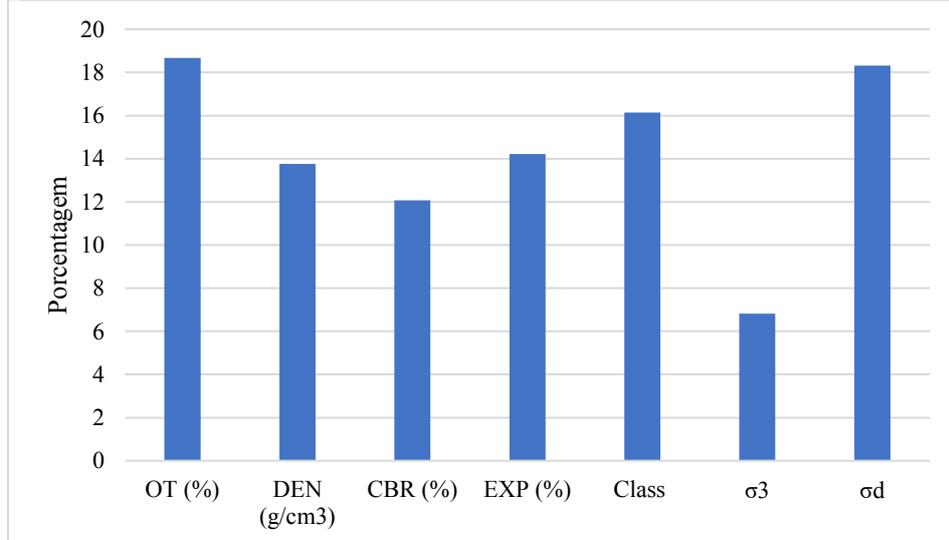
Para este modelo a variável de menor impacto foi a tensão confinante ( $\sigma_3$ ). A Figura 34 apresenta o gráfico com os valores de contribuição das variáveis.

Figura 33 - Comparação do treinamento e validação do modelo M4



Fonte: Autor

Figura 34 - Percentual de contribuição das variáveis de entrada do modelo M4



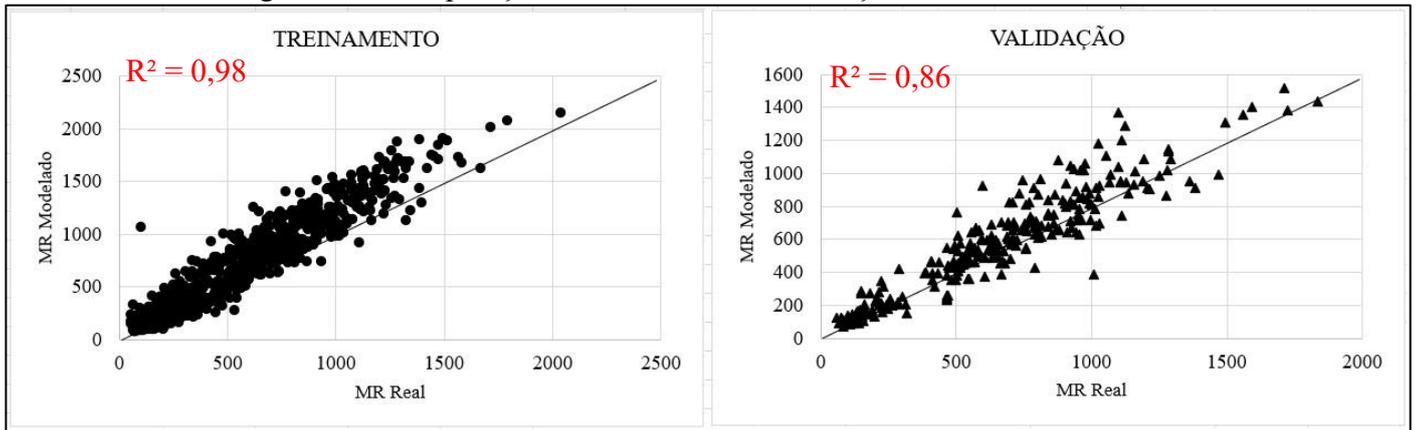
Fonte: Autor

### 5.2.6 Modelo M5

O modelo M5 para estimativa apresenta as seguintes variáveis de entrada: OT, DEN, CBR, EXP,  $\sigma_3$ ,  $\sigma_d$  e Class (Figura 35). Na Figura 36 é possível notar a comparação do número de iterações nas fases de treinamento e validação, o maior valor de correlação na validação foi obtido com oitocentos mil iterações. A medida no qual foram aumentado o número de iterações maior foram os valores de correlação para ambas as fases, treinamento e

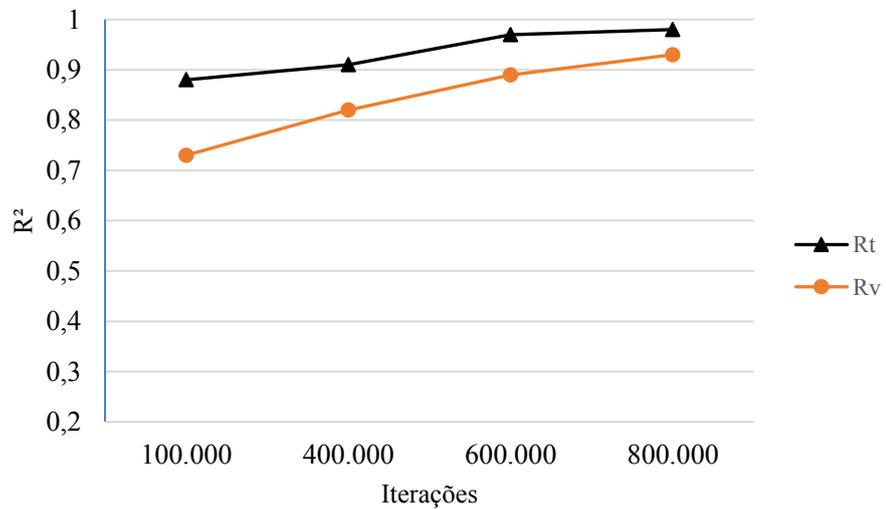
validação. Para os percentuais de contribuição a variável de maior influência para o modelo M5 foi a tensão de desvio ( $\sigma_d$ ) com 22,3% seguido da classificação AASHTO com 21,68% e CBR com 18,19%. Para este modelo a variável de menor impacto foi a tensão de confinamento ( $\sigma_3$ ). A Figura 37 apresenta o gráfico com os valores de contribuição das variáveis.

Figura 35 - Comparação do treinamento e validação do modelo M5



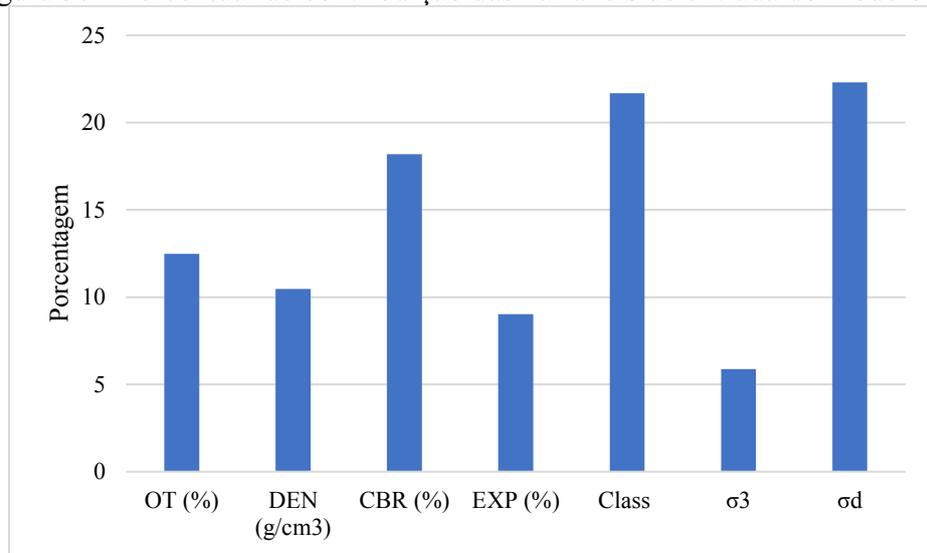
Fonte: Autor

Figura 36 - Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura



Fonte: Autor

Figura 37 - Percentual de contribuição das variáveis de entrada do modelo M5

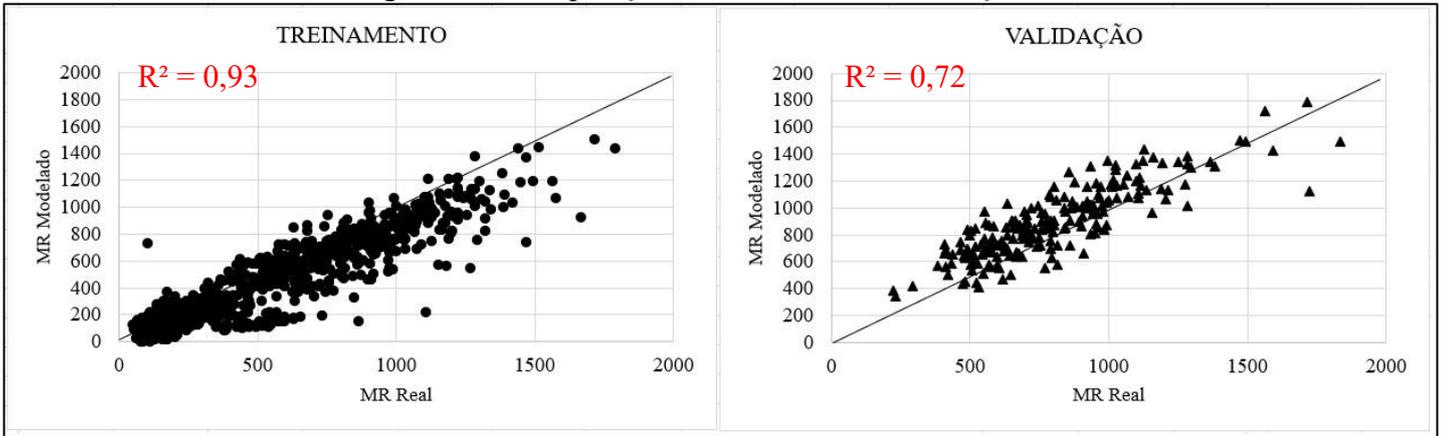


Fonte: Autor

### 5.2.7 Modelo M6

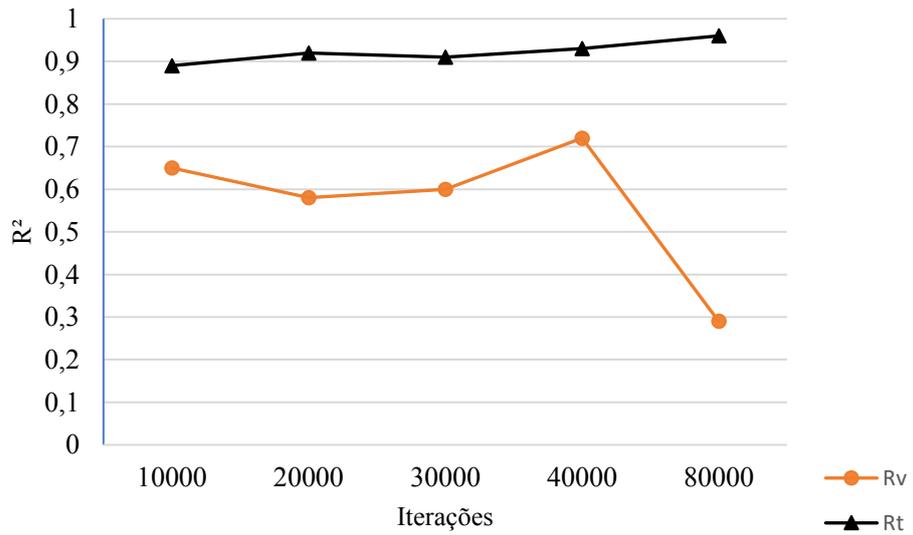
O modelo M6 utilizou 15 variáveis de entrada: OT, DEN, CBR, EXP, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class para a estimativa do Módulo de Resiliência. A Figura 38 mostra os valores de correlação obtidos para esse modelo. Comparando o número de iterações nas fases de treinamento e validação, foi possível perceber que o maior valor de correlação para a validação foi obtido com quatrocentos mil iterações. Na fase de validação, após aumentar o número de iterações superiores a quatrocentos mil, os valores de correlação foram mais baixos, conforme mostra a Figura 39. Para os percentuais de contribuição as variáveis de maior influência para o modelo M6 foram os percentuais que passam na peneira de 4,76mm com 22,16% seguido do percentual que passa na peneira 25,4mm com 11,21% e o percentual da peneira de 0,074mm com 9,08%. Para este modelo a variável de menor impacto foi a expansão com 3,34%. A Figura 40 é o gráfico com os valores de contribuição das variáveis.

Figura 38 - Comparação do treinamento e validação do modelo M6



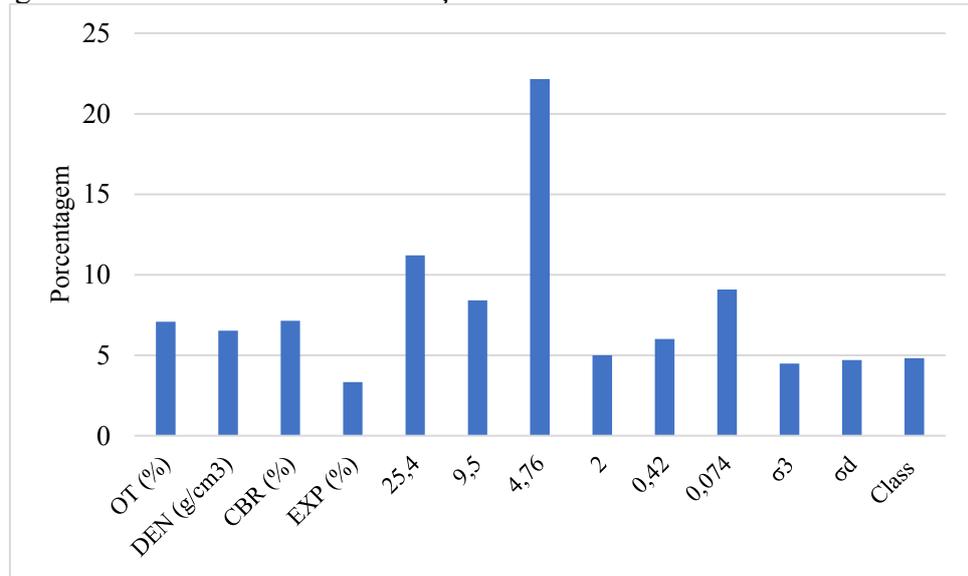
Fonte: Autor

Figura 39 - Evolução das correlações com número de iterações na fase de treinamento e validação do modelo com arquitetura



Fonte: Autor

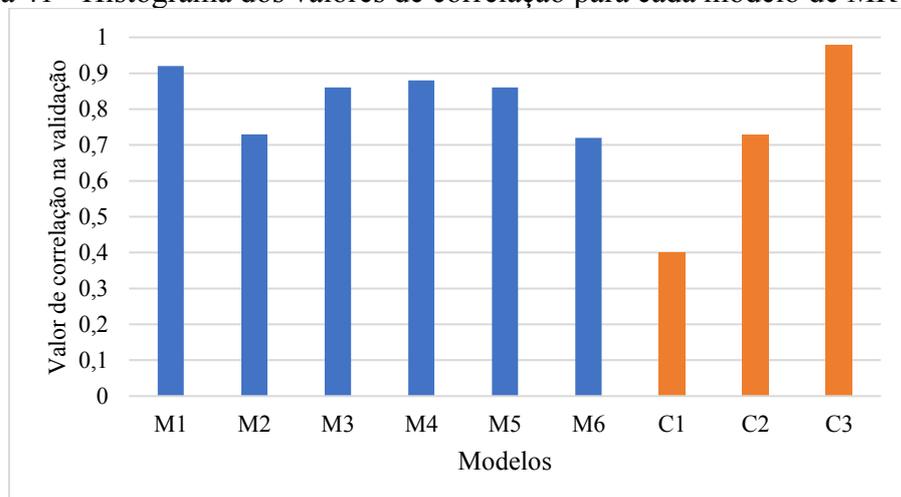
Figura 40 - Percentual de contribuição das variáveis de entrada do modelo M6



Fonte: Autor

Após toda a etapa de modelagem, obtenção dos valores correlação e variáveis de contribuição de cada modelo, foi elaborado um histograma que demonstra a comparação entre os valores da modelagem na validação de MR e CBR. Dentre todos os dados analisados, destacou-se que o valor de correlação mais elevado foi o de CBR. No entanto, os seus demais valores foram baixos, incluindo o menor valor encontrado. Quanto aos valores de MR, observou-se uma maior estabilidade geral. Também é importante ressaltar que os modelos M3, M4 e M5 demonstraram valores de correlação mais estáveis. Esses três modelos foram caracterizados pela menor quantidade de variáveis de entrada e todos acima de 0,70 na validação. A Figura 41 apresenta esses resultados de forma mais clara.

Figura 41 - Histograma dos valores de correlação para cada modelo de MR e CBR



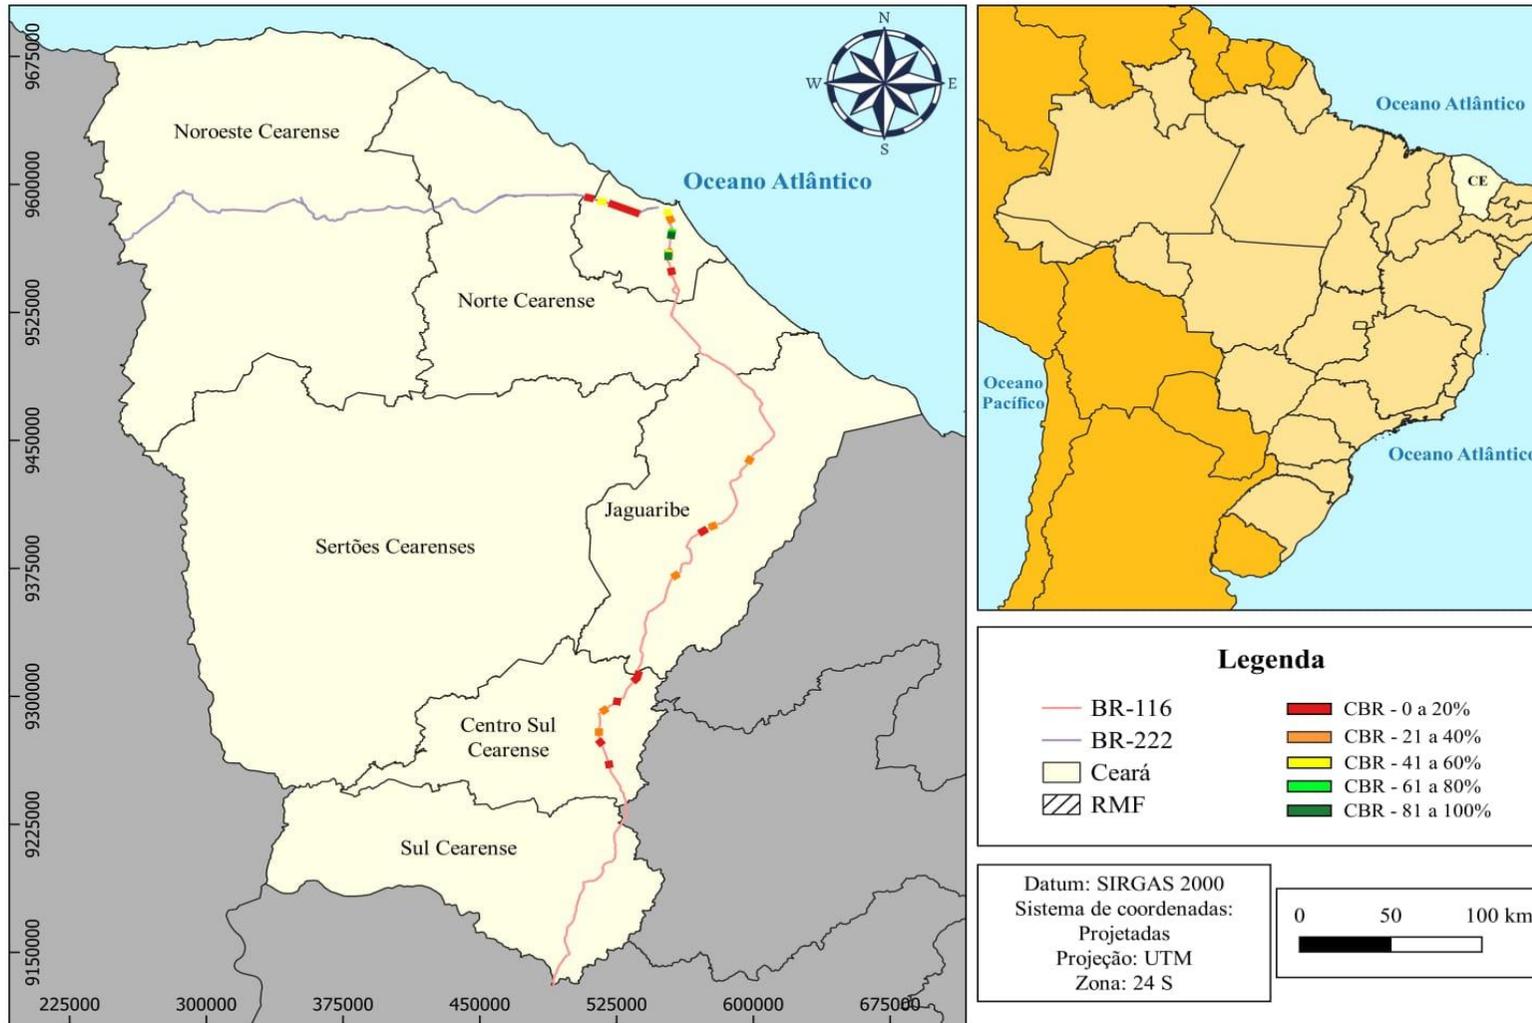
Fonte: Autor

### **5.3 Mapas geológico-geotécnicos para o Estado do Ceará**

Foram elaborados mapas geológico-geotécnicos que resumem características geológico-geotécnicas dos trechos analisados desta dissertação. A Figura 42 apresenta a distribuição dos pontos de CBR ao longo das rodovias BR 116 e BR 222 no Estado do Ceará e as Figuras 43 e 44 são uma ampliação para melhor visualização desses pontos. A maioria dos pontos de análise concentra-se na Região Metropolitana, próximo ao Norte Cearense, e em parte da Região do Jaguaribe e Centro Sul Cearense. Em geral, a maioria dos valores analisados de CBR possuem uma concentração de valores entre 0% e 40%, indicando índices de suporte mais baixos.

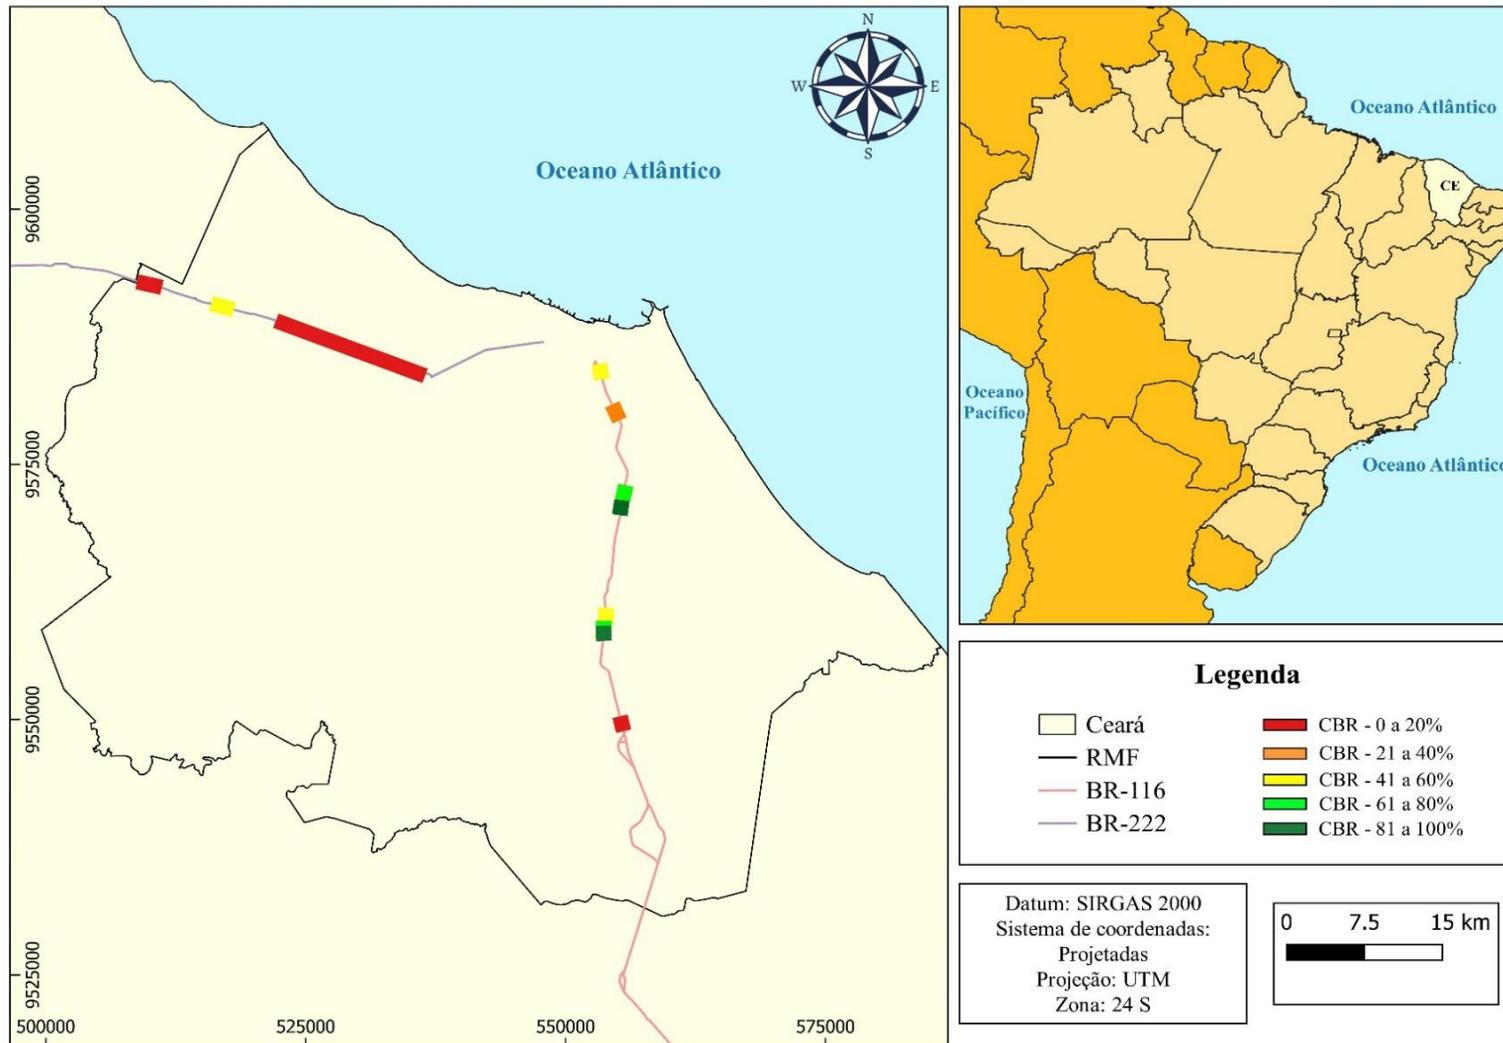
A Região Metropolitana se destaca por ter pontos com CBR mais elevados, especialmente na faixa de 81% a 100%. Foi observado que os pontos estão bem próximos uns dos outros, indicando uma densidade significativa de análises na área, o que pode facilitar o desenvolvimento de projetos de requalificação na região. As regiões do Jaguaribe e Centro-Sul Cearense foram as que apresentaram menores valores de CBR, a maior parte situando-se na faixa de 0% a 40%, entretanto, essas localidades apresentaram uma distribuição mais ampla de valores. De forma geral, notou-se uma baixa quantidade de pontos com CBR acima de 81%, sugerindo que solos com altos índices de resistência são menos comuns nas rodovias analisadas.

Figura 42 - Distribuição dos pontos de CBR nas rodovias BR 116 e BR 222 no Estado do Ceará



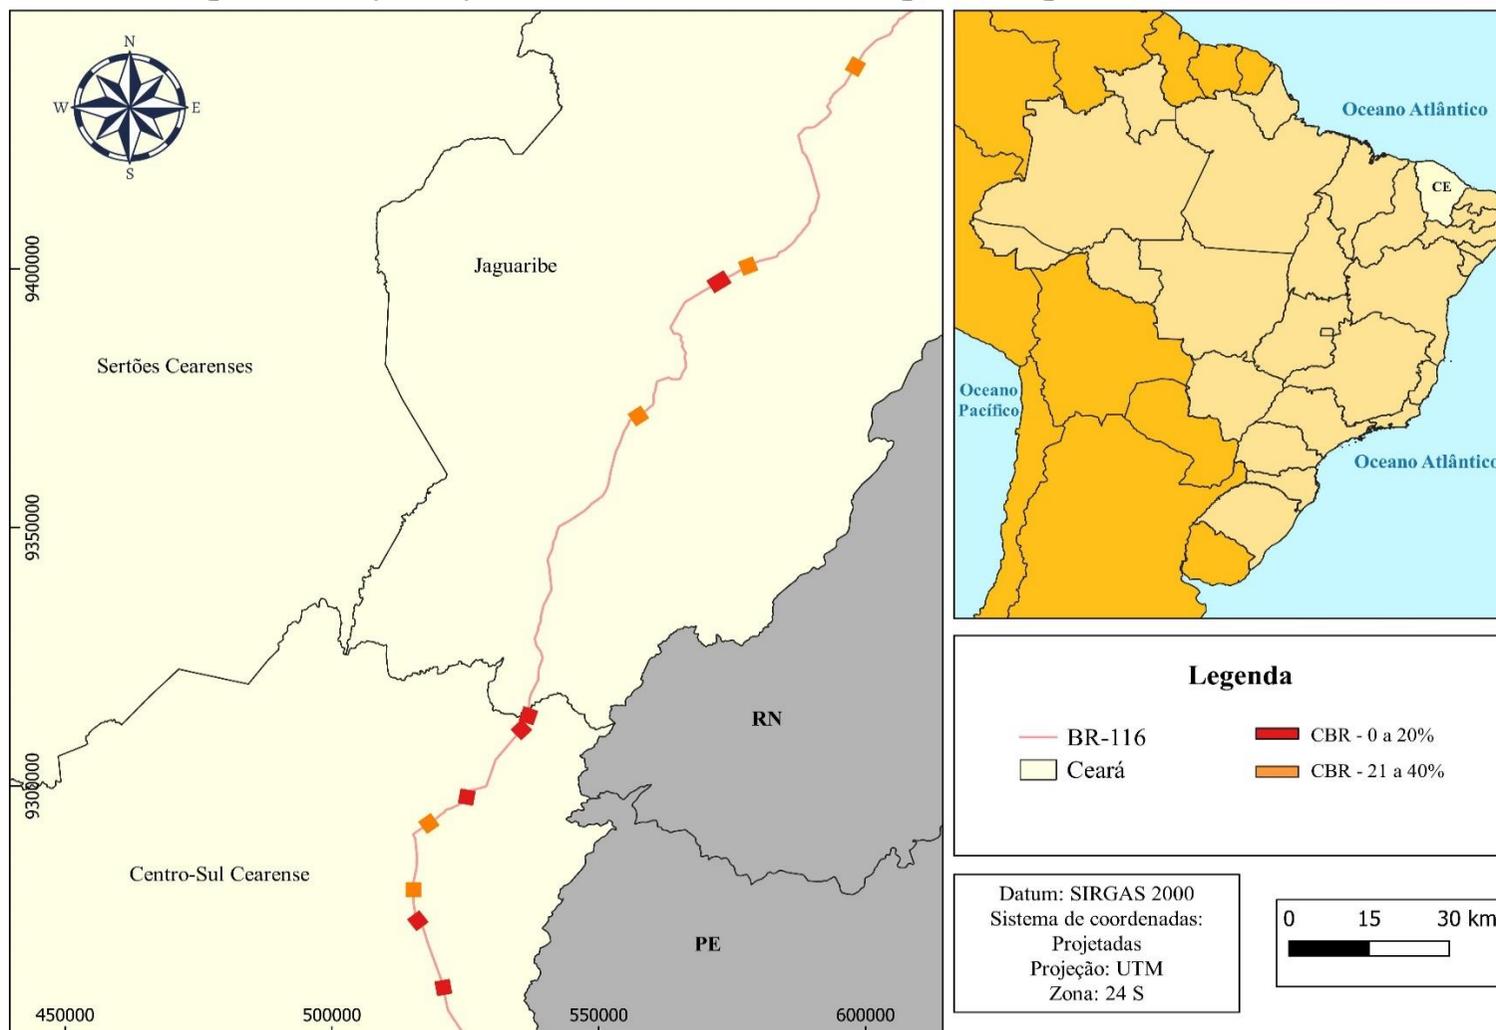
Fonte: Autor, 2024

Figura 43 - Mapa dos pontos de CBR distribuídos na Região Metropolitana de Fortaleza (RMF)



Fonte: Autor, 2024

Figura 44 - Mapa dos pontos de CBR distribuídos nas regiões do Jaguaribe e Centro-Sul Cearense



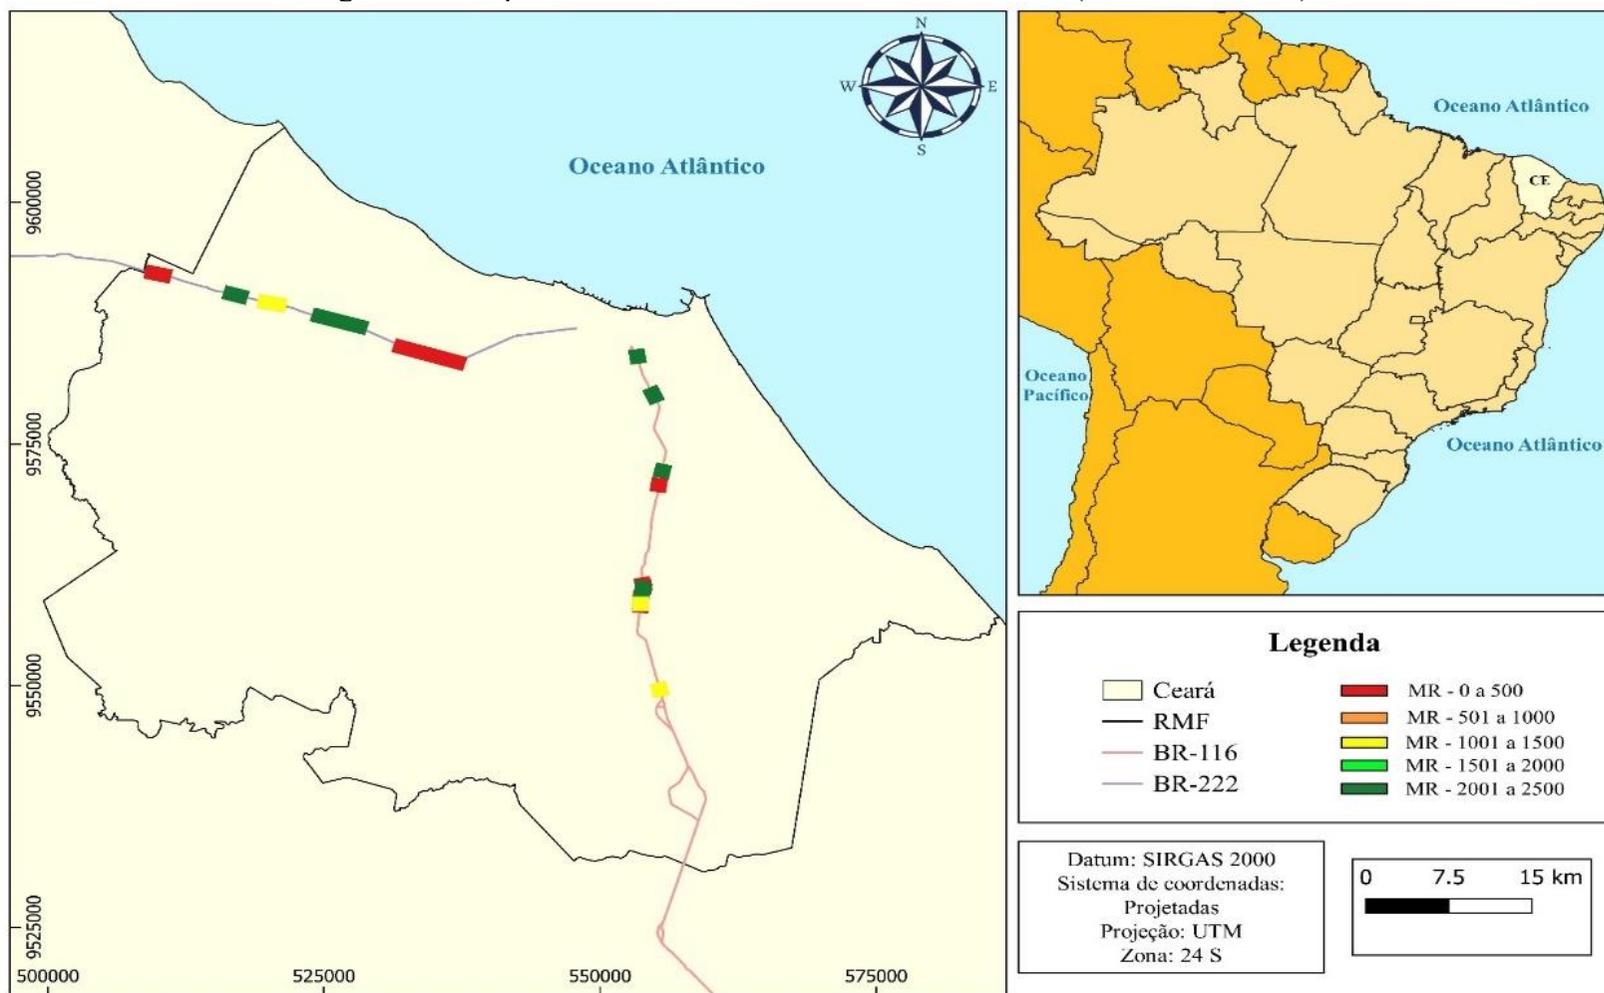
Fonte: Autor, 2024

Inicialmente foi identificado o melhor modelo de MR, no qual apresentou valor de correlação acima de 0,70 e que usou menor quantidade de dados de entrada. O modelo que se enquadra nesses aspectos foi o M4 e após sua escolha, foi realizada a estimativa dos valores de MR dos pontos. Os mapas de Módulo de Resiliência foram desenvolvidos para os mesmos pontos georreferenciados de CBR, mas com os valores estimados de MR. Para a RMF houve pontos com MR estimado por meio do modelo M4 que variaram entre 0 a 500 MPa, porém sua maior parte foi caracterizada por pontos com valores de MR mais altos variando de 1001 a 2500 MPa.

Para a região do Jaguaribe embora tenha-se uma menor quantidade total de pontos nessa área em comparação com outras regiões, nota-se que a proporção de valores mais elevados de MR foi aproximadamente 40% maior. Analisando a relação entre os mapas de CBR e MR notou-se que pontos caracterizados por baixos valores de MR coincidem com correspondentes valores baixos de CBR. Esta correspondência pode sugerir a possibilidade de problemas geotécnicos nestas áreas específicas do solo. Além disso, foram identificadas anomalias, nas quais os valores de MR foram significativamente elevados, diferente dos valores de CBR que foram baixos. A região onde os pontos da região Jaguaribe estão localizados tem uma grande presença de neossolos, esta observação pode ser um elemento importante para entender essa disparidade. Estas discrepâncias apontam para a necessidade de uma investigação mais aprofundada para compreender as peculiaridades geotécnicas presentes nesses pontos específicos.

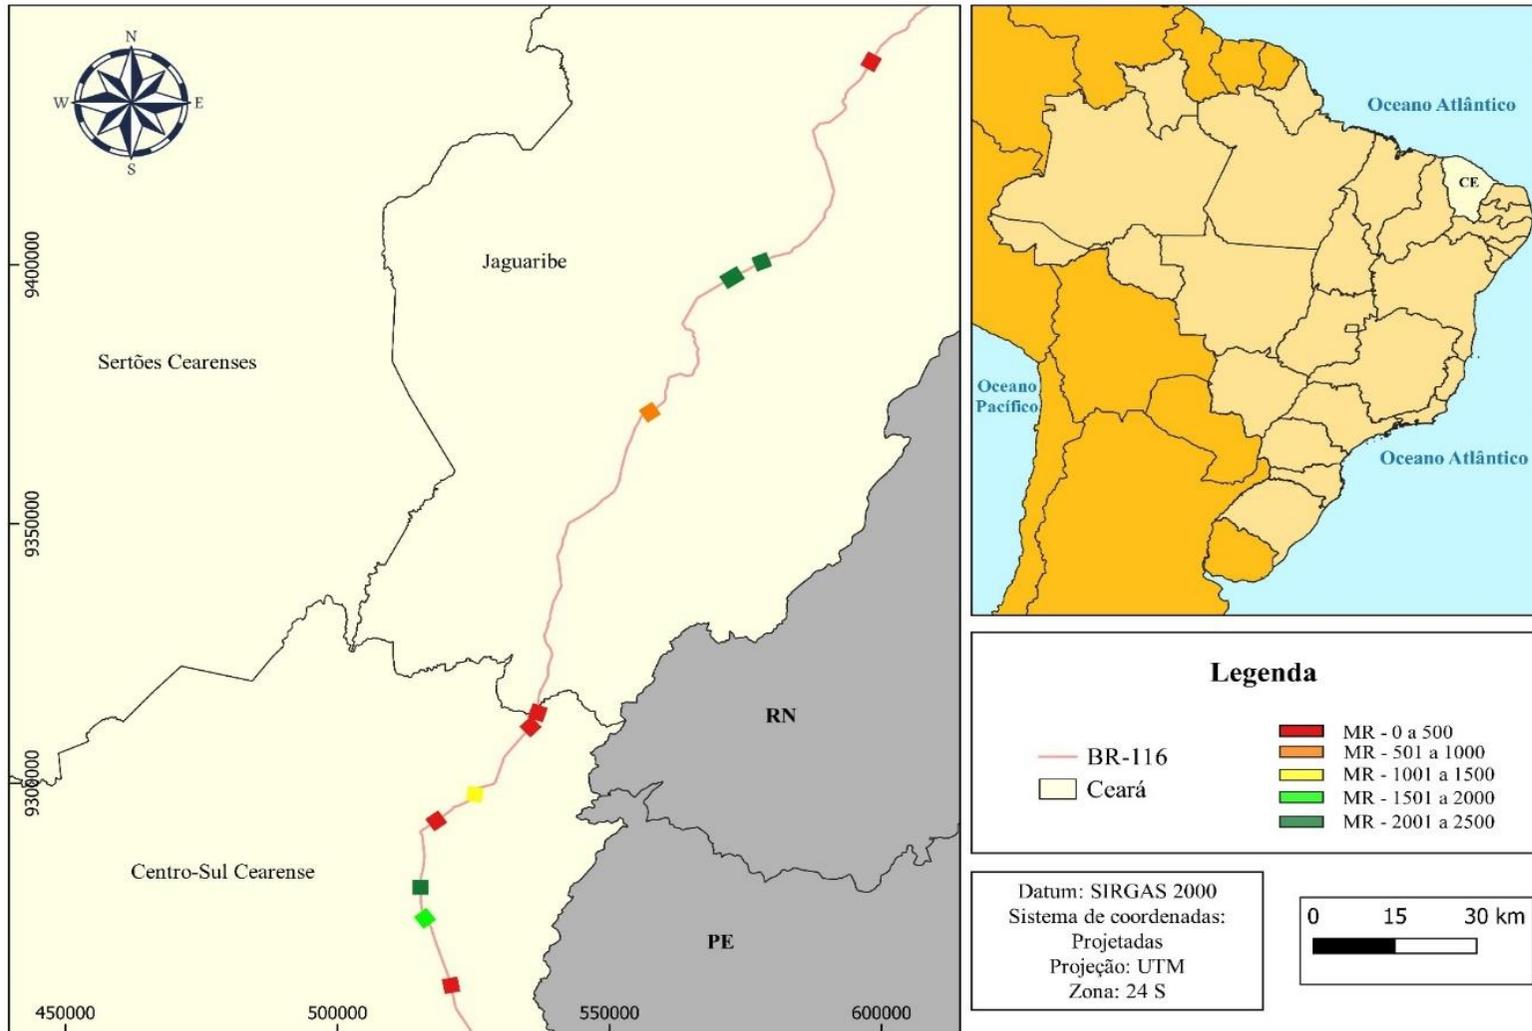
Ao examinar a região Centro-Sul cearense, observou-se uma significativa variação nos valores de MR. Para esta região houve maior quantidade estimada de valores de MR mais baixos, que variou de 0 a 500 MPa, os valores mais altos foram exceções nesta região. As Figuras 45 e 46 apresentam a distribuição dos valores de MR nas regiões do Estado do Ceará.

Figura 45 - Mapa com valores de MR distribuídos na RMF (Valores em MPa)



Fonte: Autor, 2024

Figura 46 - Mapa com valores de MR distribuídos na região do Jaguaribe e Centro-Sul Cearense (Valores em MPa)



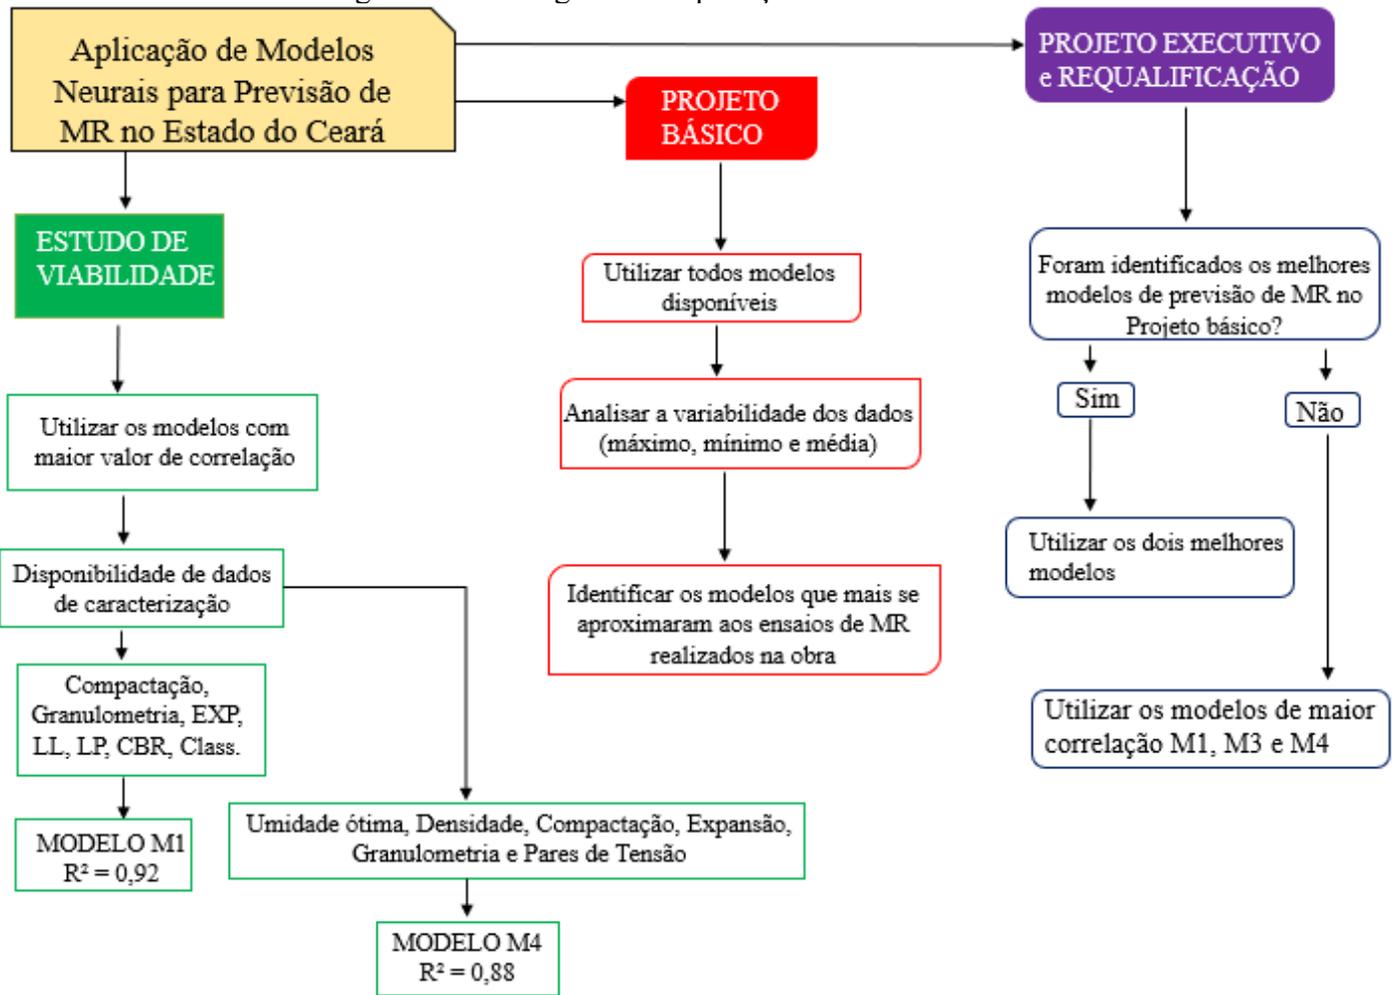
Fonte: Autor, 2024

#### **5.4 Diretrizes e recomendações para implementação dos modelos de MR e mapas geológico-geotécnicos no Estado do Ceará**

A caracterização geológico-geotécnica desempenha um papel crítico na pavimentação, garantindo que a infraestrutura seja projetada e construída com base nas características específicas do local. Isso não melhora apenas a eficácia e a durabilidade da pavimentação, mas também contribui para a segurança dos usuários das estradas e para a gestão responsável dos recursos naturais. Segundo estudo levantado por Santos *et al* (2020), a análise geológico-geotécnica é de extrema importância para garantir a segurança da via. Através dessas avaliações, é possível desenvolver planos de prevenção e sistemas de alerta, bem como implementar projetos de infraestrutura para minimizar os riscos e proteger essas estruturas. Por isso, desenvolver metodologias robustas e estabelecer métricas e critérios para os estudos geológico-geotécnicos para pavimentação é muito relevante.

Com objetivo de facilitar o uso de mapas e modelos geológico-geotécnicos em projetos de pavimentos, são apresentadas as recomendações e diretrizes especificadas em função das etapas do projeto, e subdivididos em: (i) estudo de viabilidade; (ii) projeto básico; (iii) projeto executivo e projeto de requalificação. Na Figura 47 é apresentado um fluxograma das etapas para aplicação dos modelos neurais.

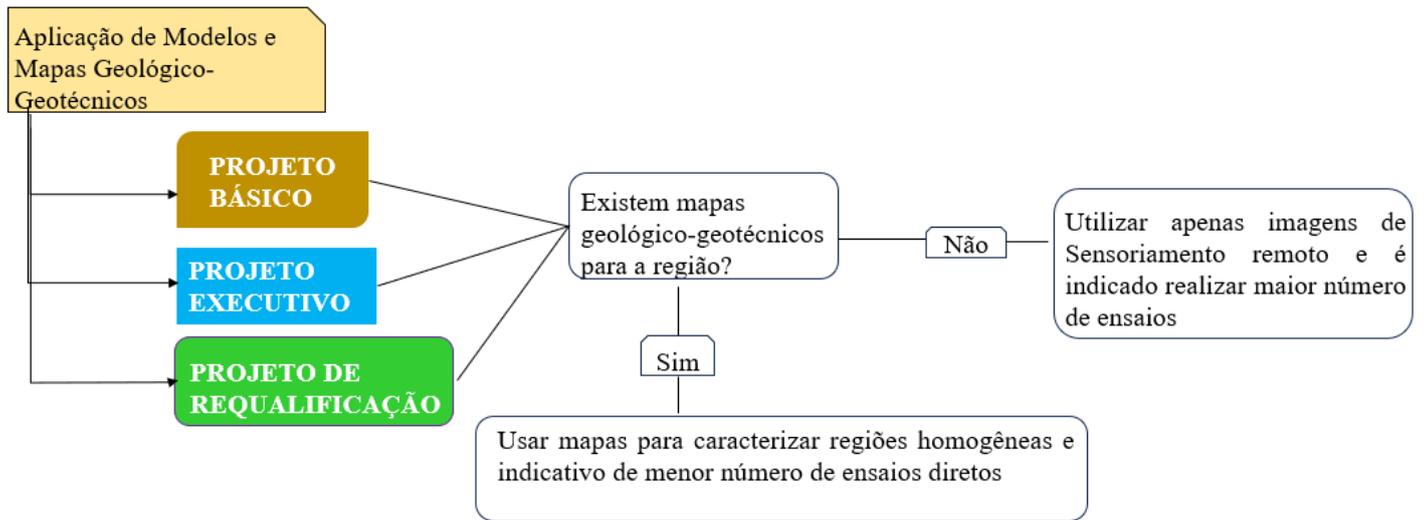
Figura 47 - Fluxograma da aplicação dos modelos neurais de MR



Fonte: Autor, 2023

Diversos estudos mostram as aplicações e vantagens do uso de análises geológico-geotécnicas para a pavimentação, uma das formas dessa análise é por meio da construção de mapas geológico-geotécnicos, por exemplo, Mascarenhas (2016) e Ribeiro (2014). Para os modelos neurais, apesar de já existirem na literatura alguns desenvolvidos, ainda há dificuldade de implementação por técnicos e projetistas, por isso, as diretrizes e recomendações de uso dos mapas e modelos para o Estado Ceará pode facilitar o seu uso. A Figura 48 apresenta o fluxograma da aplicação de modelos e mapas geológico-geotécnicos usadas neste trabalho.

Figura 48 - Fluxograma da aplicação dos mapas geológico-geotécnicos

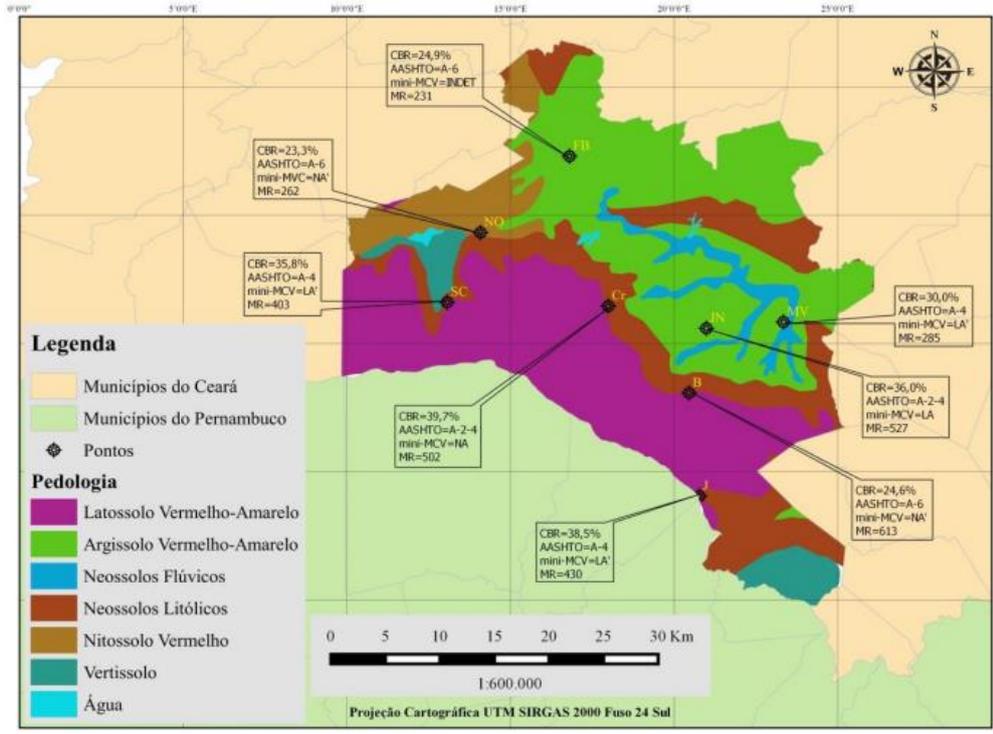


Fonte: Autor, 2023

#### 5.4.1 Estudo de viabilidade

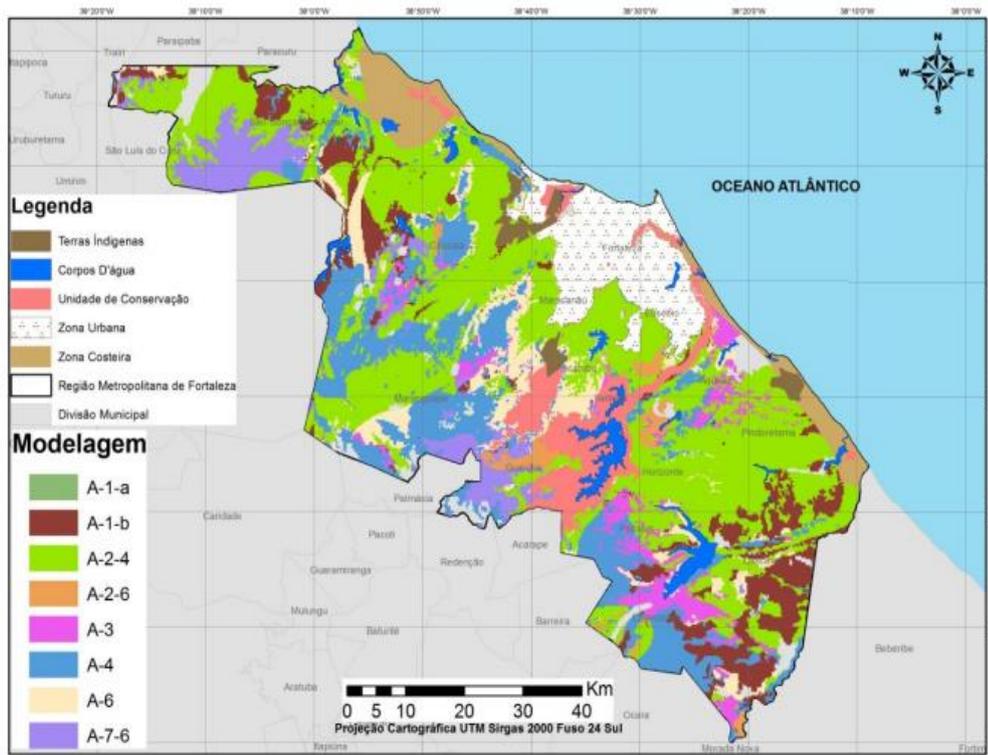
O estudo de viabilidade é a fase inicial para a garantia detalhada de vários fatores para determinar se a pavimentação é ou não uma opção viável e qual é a melhor abordagem para o projeto. Nessa etapa recomenda-se a utilização de mapas e modelos geológico-geotécnicos da seguinte forma: No caso de existirem mapas geológico-geotécnicos para a região estudada como por exemplo os de Mascarenhas (2016) e Ribeiro (2013), Figuras 49 e 50 respectivamente. A recomendação é usar esses mapas para caracterização das regiões homogêneas. Podendo-se assim haver a possibilidade de um menor número de ensaios diretos nesta etapa do projeto. A utilização dos modelos para previsão de MR pode ser estabelecida de acordo com a disponibilidade de dados de caracterização, se possuir os seguintes dados: umidade ótima, densidade, compactação, expansão e granulometria, a indicação é o modelo M4 que apresentou um valor de correlação de 0,88 e precisa de uma menor quantidade de ensaios para a estimativa de MR. Ou, em outras circunstâncias, apresentar os dados: compactação, expansão, CBR, granulometria, LL e LP, poderá ser utilizado o modelo M1 que apresentou o maior valor de correlação, com 0,92. A Figura 51 representa recomendações para aplicação dos modelos neurais para estimativa do MR na fase do estudo de viabilidade.

Figura 49 - Mapeamento geológico-geotécnico da Região Metropolitana do Cariri (RMC)



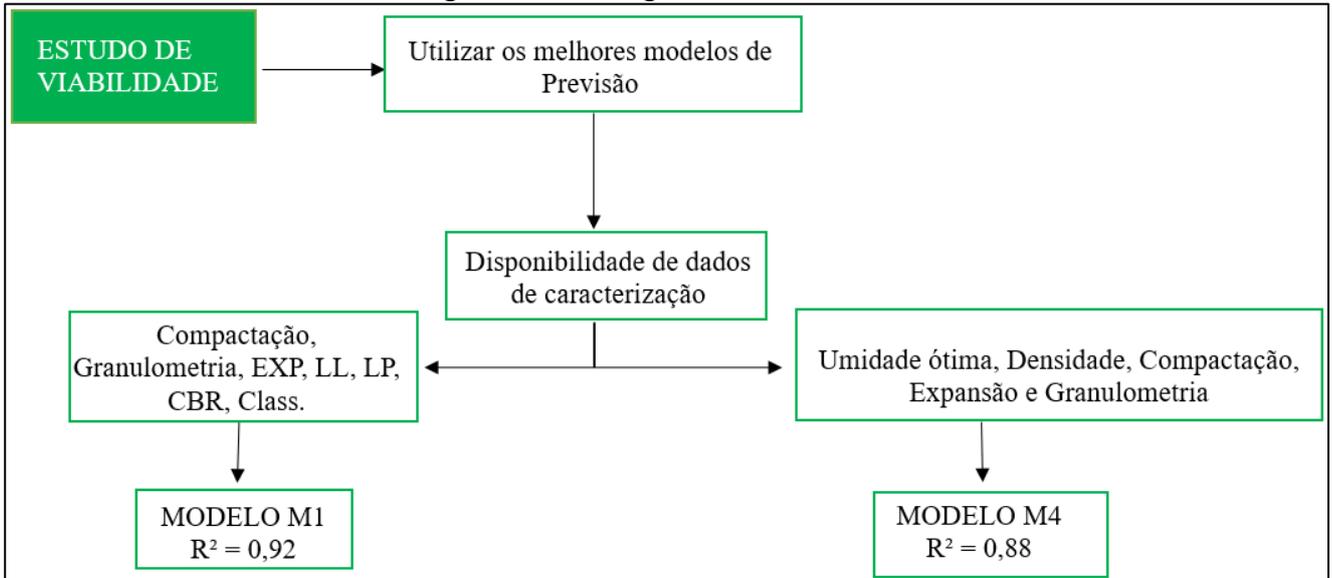
Fonte: Mascarenhas (2016)

Figura 50 - Mapeamento geológico-geotécnico da Região Metrop. de Fortaleza (RMF)



Fonte: Ribeiro (2013)

Figura 51 - Fluxograma do Estudo de viabilidade

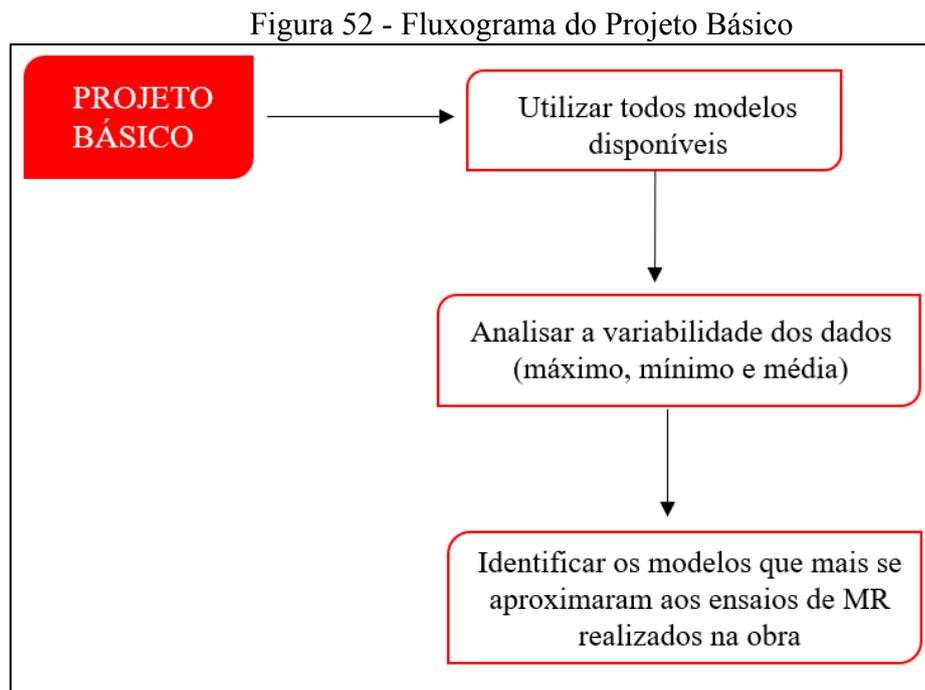


Fonte: Autor, 2023

Na ausência de mapas, recomenda-se como alternativa utilizar imagens de sensoriamento remoto e um maior número de ensaios, que vai de acordo com os critérios do projetista. Uma alternativa que também pode ser viável é a utilização de métodos indiretos, como métodos geofísicos. Os métodos geofísicos, como: eletromagnéticos, georradar (GPR), elétricos e sísmicos, podem ser utilizados para obter informações de subsuperfície de modo indireto, sendo possível correlacionar os resultados da investigação com tipos litológicos diferentes, nível freático, transições de camadas de solos, entre outros. Dentre as vantagens dos métodos geofísicos estão: a possibilidade de realizar investigações ao longo de toda uma extensão (diferente dos ensaios diretos, realizados de forma pontual), a rápida execução e o baixo custo de alguns tipos de ensaios, como alguns tipos de métodos elétricos. Como desvantagem pode ser citada a dificuldade de interpretação dos resultados.

### 5.4.2 Projeto Básico

Na etapa de projeto básico do pavimento, é realizada a criação de um plano geral que estabelece a estrutura e a configuração básica da pavimentação, mas, não entra em detalhes específicos de engenharia. Normalmente são utilizados menos ensaios para esta etapa em comparação a etapa de projeto executivo. A recomendação para esta etapa é a utilização de todos os modelos de MR disponíveis (M1, M2, M3, M4, M5 e M6), analisando a variabilidade dos dados obtidos, tais como os valores máximos, mínimos e média obtidos nos modelos e ensaios. Ademais, recomenda-se verificar os modelos que mais se aproximam ao valor de MR dos ensaios realizados para o projeto. A Figura 52 apresenta as recomendações para aplicação dos modelos neurais na etapa de projeto básico.



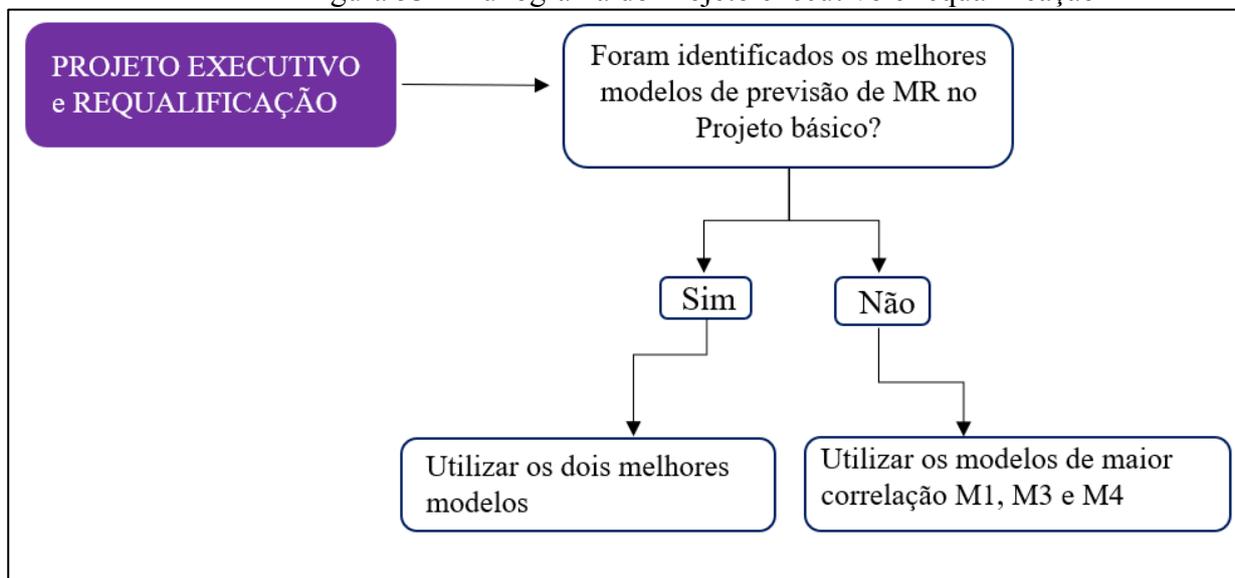
Fonte: Autor, 2023

### 5.4.3 Projeto Executivo

O projeto executivo de pavimentos é a fase seguinte ao projeto básico, nesta fase, os detalhes do projeto são elaborados em profundidade, e são produzidos os documentos técnicos necessários para a construção efetiva da pavimentação. Para esta etapa algumas condições devem ser consideradas, como por exemplo, caso na etapa do projeto básico os

melhores modelos para obra tenham sido selecionados, recomenda-se que além dos ensaios sejam também utilizados os modelos que melhor se adequaram as características geológico-geotécnico da região. Em contrapartida, caso os melhores modelos não tenham sido selecionados na etapa de projeto básico, recomenda-se utilizar os modelos com maior valor de correlação (M1, M3 e M4), além dos ensaios de caracterização. Sendo os principais ensaios de caracterização análise granulométrica, limites de consistência, ensaio de compactação CBR (Paula *et al*, 2022). A Figura 53 apresenta as recomendações para aplicação dos mapas geológico-geotécnicos na etapa do projeto executivo e de requalificação.

Figura 53 - Fluxograma do Projeto executivo e requalificação



Fonte: Autor, 2023

#### 5.4.4 Projeto de Requalificação

Um projeto de requalificação em pavimentos se refere a um conjunto de atividades e planos direcionados para a melhoria, reabilitação ou restauração de estradas, rodovias, ou qualquer superfície pavimentada, esses projetos são desenvolvidos para estender a vida útil da infraestrutura do pavimento, melhorar a segurança viária, reduzir os custos de manutenção e proporcionar uma melhor qualidade de rodagem. Para implementação dos mapas geológico-geotécnicos na etapa do projeto de requalificação, ocorrerá se a região houver disponibilidade de mapas como os apresentados para as rodovias BR 116 e 222 deste trabalho (Figuras 43, 44, 45 e 46) nos trechos indicados pode-se fazer uso desses mapas para estimativa dos valores de

MR, além das coletas de amostras e ensaios indicados pelo projetista ou órgão demandante, nesse caso com a disponibilidade de dados dos mapas e modelos neurais, os ensaios podem ser reduzidos. Não havendo mapas ou modelos fica a critério do órgão demandante ou projetista definir os critérios da investigação, podendo ser utilizados análise de dados de sensoriamento remoto.

#### **5.4.5 Considerações Finais**

A proposta deste trabalho é fornecer e aumentar a quantidade de dados geológico-geotécnicos aos órgãos responsáveis e aos projetistas de infraestrutura de pavimentos. As metodologias indiretas, como o uso de mapas, modelos ou investigações geofísicas, não podem ser utilizadas como substitutos dos métodos diretos, que envolvem ensaios de campo e laboratório. Porém podem ser usados para reduzir a quantidade e custo dos ensaios diretos, além de servir como mais uma base de dados. Recomenda-se a atualização constante dos bancos de dados, modelos e mapas geológico-geotécnicos a fim de melhorar continuamente os projetos.

## 6 CONCLUSÕES E SUGESTÕES DE PESQUISAS FUTURAS

Neste capítulo, destacam-se as conclusões do estudo, abordando os resultados alcançados e os objetivos atingidos a partir das análises apresentadas nos capítulos anteriores. Adicionalmente, são oferecidas sugestões para futuras pesquisas, visando complementar os estudos aqui desenvolvidos.

### 6.1 Principal Conclusão

Neste trabalho foram desenvolvidos modelos e mapas geológico-geotécnicos destinados a previsão de características geotécnicas de materiais granulares necessários para os métodos de dimensionamento mecanístico-empírico de pavimentos, por meio da utilização de redes neurais artificiais do tipo perceptron multicamadas. Os dados obtidos para modelagem foram extraídos do banco de dados do Projeto da Universidade Federal do Ceará com o DNIT, denominado Pesquisa, Treinamento e Acompanhamento Técnico de Pavimentos Asfálticos Nacionais, no qual foi desenvolvido no Subprojeto 2 - Plataforma integrada de estruturação e análise de dados com uso de Inteligência Artificial.

Foram criados seis modelos neurais distintos para previsão do MR e selecionados dois modelos que apresentaram os melhores resultados, sendo M1 o modelo que apresentou maior valor de correlação, com 0,91 e o M4 que apresentou um valor de correlação de 0,88 e com a menor quantidade de dados de entrada, o que representa um modelo que requer menos ensaios e maior facilidade para sua determinação.

A principal contribuição desta dissertação foi a criação de modelos neurais e mapas geológico-geotécnicos como uma forma de auxiliar em projetos futuros de pavimentos no Estado do Ceará tendo como base as características geológico-geotécnica dos solos cearenses. Os modelos neurais foram criados para que possam ser usados futuramente de forma a otimizar projetos de pavimentos. Por meio dos modelos estabelecidos foi possível prever parâmetros geotécnicos (MR e CBR) e definir os melhores modelos de MR para aplicação no Estado do Ceará. Através dos mapas geológico-geotécnicos realizou-se identificação do tipo de solo em diversos pontos analisados e foi possível observar e compreender a distribuição dos valores de MR e CBR nos trechos analisados.

Após análise dos dados, é importante ressaltar que eles ainda estão em fase de teste e necessitam de uma ampliação para uma compreensão mais completa. Todas as conclusões tiradas até o momento estão restritas especificamente aos dados desta dissertação. Isso

ressalta a importância de uma análise detalhada e contínua dos dados para uma compreensão mais precisa e abrangente das regiões estudadas.

## **6.2 Principais constatações para os modelos criados de CBR**

Com base na análise dos histogramas representando a distribuição dos dados de CBR, observa-se que o banco de dados inicial, composto por 8281 amostras, apresenta uma alta variabilidade, com a maior frequência de valores concentrada no intervalo de 9% a 20%. Por outro lado, ao examinar o modelo de CBR desenvolvido para os trechos específicos das rodovias BR 116 e BR 222, composto por 343 dados, nota-se uma maior dispersão nos valores do histograma em comparação com o banco de dados mais amplo. Na distribuição dos trechos das BR 116 e 222, a faixa com maior frequência dos valores de CBR varia entre 8% e 25%. É interessante observar que ambos os gráficos exibem semelhante variabilidade e dispersão de valores, sugerindo consistência nos resultados, mesmo considerando a diferença no tamanho das amostras. Quanto à classificação AASHTO dos solos, o modelo de CBR destacou 197 amostras classificadas como A-2-4, 37 como A-1-b e 34 como A-3.

A modelagem neural do melhor modelo de CBR (C3) com base nos resultados observados apresentou um desempenho significativamente satisfatório na previsão do CBR nos trechos das rodovias BR116 e 222. Este modelo continha como dados de entrada: umidade ótima (OT), densidade (DEN), limite de liquidez (LL), índice de plasticidade (IP), faixas granulométricas de polegadas (P25,4), (P9,5), (P4,76), (2mm), (0,42mm), (0,074mm), CBR e classificação AASHTO. O modelo C3 obteve um índice de correlação de 0,98 na fase de validação, indicando uma relação muito forte entre as previsões do modelo e os valores reais do CBR. Pode-se concluir que as faixas granulométricas, especificamente o percentual que passa na peneira de 0,42mm, emerge como o fator de maior influência na construção do modelo neural para previsão do CBR. A influência significativa do percentual que passa na peneira de 0,42mm, representando 14,75% de contribuição para o modelo, destaca a importância da distribuição granulométrica do solo na determinação do CBR. Isso sugere que a composição granular do solo desempenha um papel crucial, bem como o limite de liquidez e a umidade ótima ressaltando também importância de fatores relacionados à consistência do solo e às condições de umidade ideais.

### 6.3 Principais constatações para os modelos criados de MR

Com os dados coletados de MR e através dos histogramas foi possível entender a tendência central dos valores de MR e a distribuição geral dos dados. Os dados de MR mais frequentemente classificados segundo AASHTO foram A-2-4, A-1-b e A-4, resultados semelhantes às classificações de CBR, com a exceção da classe A-4, que foi a terceira mais predominante nos resultados de MR.

Para os modelos neurais de MR foram desenvolvidos seis modelos distintos, alterando as variáveis de entrada para cada modelo. Esta modificação ajudou a simplificar cada um dos modelos e explorar novas relações entre os dados, descobrindo padrões anteriormente desconhecidos. O modelo que apresentou maior valor de correlação, o M1, apresentou um grau de precisão relevante, com um coeficiente de correlação de 0,92 na validação. Este modelo continha a maior quantidade de variáveis de entrada, com os seguintes dados: Expansão (EXP), umidade ótima (OT), densidade (DEN), limite de liquidez (LL), índice de plasticidade (IP), faixas granulométricas de polegadas (P25,4), (P9,5), (P4,76), (2mm), (0,42mm), (0,074mm), CBR, classificação AASHTO,  $\sigma_3$  e  $\sigma_d$ . O modelo M1 alcançou maiores valores de correlação com apenas uma tentativa de arquitetura. Entretanto, apesar desse desempenho, o modelo M1 não foi considerado o mais representativo de todos os modelos, devido à sua complexidade com um maior número de dados de entrada. Cada uma dessas entradas representa um ensaio laboratorial, resultando em um modelo potencialmente mais dispendioso e demorado, dada a necessidade de diversos ensaios para a configuração de suas camadas. Por outro lado, o modelo M4, embora não tenha atingido um valor de correlação tão elevado, apresentou valor de correlação acima de 0,70 e uma menor quantidade de dados de entrada. O modelo M4, utilizou os seguintes dados de entrada: umidade ótima (OT), densidade (DEN), faixas granulométricas de polegadas, (P9,5), (2mm), (0,074mm),  $\sigma_3$  e  $\sigma_d$ . Este modelo mostrou-se eficiente, demandando menos ensaios para a camada de entrada, destacando a sua maior viabilidade de implementação. Portanto, o modelo principal adotado nesta pesquisa foi o M4, é importante ressaltar que os valores apresentados não representam necessariamente o MR.

Os resultados obtidos neste trabalho demonstram, é possível criar modelos de previsão para os valores do ensaio de módulo de resiliência em uma região específica, de uma forma econômica para serem utilizados na construção de estradas e pavimentação. A maior parte dos modelos de previsão do ensaio de MR neste trabalho tiveram os níveis de

correlação considerados satisfatórios e relevantes, variando de 0,73 a 0,92, resultados similares aos de Ribeiro (2016) no qual obteve correlações de 0,985.

#### **6.4 Constatações quanto às aplicações de mapas geológico-geotécnicos na área rodoviária**

Quanto aos mapas geológico-geotécnicos, foram de fundamental importância para entender as características geológico-geotécnicas locais dos trechos estudados e estabelecer recomendações. Ao analisar os mapas de CBR foi possível observar que a RMF se destacou por possuir maior quantidade de pontos com valores de CBR mais altos, especialmente na faixa de 81% a 100%. A quantidade alta de pontos com índice CBR entre 20% a 40% indica que solos com índices mais altos de resistência são menos frequentes nas rodovias analisadas.

Na análise dos mapas de MR gerados pelo modelo de RNA observou-se que para a RMF houve maior concentração de pontos com valores altos de MR. Para a região do Jaguaribe embora tenha sido observada uma quantidade total de pontos menor em comparação com outras regiões, destaca-se a proporção de valores estimados mais elevados de MR foi relativamente maior, comportamento diferente das outras regiões. Esse padrão peculiar pode indicar uma complexidade das características geotécnicas presentes nos trechos analisados na região Jaguaribe, evidenciando a necessidade de uma análise mais aprofundada para compreender as nuances do comportamento do solo nessa área específica.

Ao examinar de forma mais detalhada a Região Centro-Sul Cearense nos mapas foi possível observar valores estimados mais baixos de MR e uma maior variabilidade nos valores de MR, isso pode sugerir uma heterogeneidade nos atributos geotécnicos dessa área. Essa diversidade pode estar associada a características geológicas e geotécnicas específicas presentes no Centro-Sul Cearense, exigindo uma análise mais aprofundada para compreender as nuances dessas variações e, assim, contribuir para uma avaliação mais precisa da resiliência do solo nessa localidade.

Ao comparar os mapas de CBR e MR, observou-se que alguns trechos com baixos valores de MR coincidem com locais onde o CBR também é baixo. Essa coincidência sugere a possibilidade de problemas geotécnicos nessas áreas do solo. Contudo, foram identificados trechos onde valores de MR eram significativamente altos, ao contrário dos valores baixos de CBR, especificamente nos trechos da região Jaguaribe que é caracterizada por uma grande quantidade de neossolos e argissolos e também os trechos da região Centro-Sul que é caracterizada por uma grande presença de luvissolos, neossolos e planossolos. Esses

aspectos podem facilitar o entendimento dessas discrepâncias. Essas disparidades indicam a necessidade de uma investigação mais detalhada para compreender as características geotécnicas específicas nessas regiões.

A disponibilidade de mapas geológico-geotécnicos, não apenas aprimora a compreensão das rodovias, mas também fornece uma base sólida e acessível para tomadas de decisão informadas em projetos de pavimentação. A integração desses mapas permite uma contribuição para projetos futuros de requalificação das rodovias estudadas e contribui para implementação eficaz do método MeDiNa. Este avanço representa uma base sólida e acessível para tomadas de decisão informadas em projetos de pavimentação.

### **6.5 Sugestões para pesquisas futuras**

Durante o progresso deste estudo, foi possível identificar oportunidades de aprimoramento e áreas para investigações futuras, englobando:

- Recomenda-se que os resultados deste estudo sejam considerados como uma alternativa viável ao processo do ensaio de módulo de resiliência, podendo ser aplicados em planejamentos futuros de pavimentação;
- Sugere-se que as diretrizes e recomendações para aplicação de mapas geológico-geotécnicos e modelos neurais possam ser utilizados para projetos de pavimentos;
- Recomenda-se explorar outras técnicas de modelagem para a previsão do MR e CBR;
- Recomenda-se que os mapas gerados possam servir como ponto de partida ou referência para a utilização de métodos de dimensionamento mecanístico-empírico de pavimentos.
- Sugere-se a integração dos mapas/modelos gerados para previsão de MR no Estado do Ceará.
- Sugere-se estudos mais aprofundados para compreender e esclarecer a alta variabilidade de valores de MR nos trechos de rodovias, na região Centro-Sul do Estado do Ceará.
- Sugere-se análises para identificar anomalias, em que situações que os valores de MR foram consideravelmente altos, ao contrário dos valores de CBR, que foram muito baixos.

## REFERÊNCIAS

AASHTO T 307-99. **Standard Method of Test for determining the resilient Modulus of Soils and Aggregate Materials**. Washington, DC: American Association of State Highway and Transportation Officials, 1999.

ALMEIDA, F. F. M.; HASUI, Y.; NEVES, B. B Brito.; FUCK, R. A. Províncias estruturais brasileiras. In: SIMPÓSIO DE GEOLOGIA DO NORDESTE, 8., Campina Grande. **Atas...** Campina Grande: SBG,1977. p. 363-391.

ALVES, A. B. C. **Avaliação da capacidade de suporte e controle tecnológico de execução da camada final de terraplenagem utilizando o penetrômetro dinâmico cone**. 2002. 185 f. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Santa Catarina, Florianópolis, 2002.

ALVES, K. D. R.; SANTAREM, L. M. S. Um panorama da manutenção rodoviária no Brasil e as experiências internacionais. In: **XXIX Congresso Nacional de Pesquisa em Transporte da ANPET**. Outro Preto 2015.

AMANCIO, L. B.; DANTAS NETO, S. A.; ANJOS, G. J. M. Modelo de Previsão de Recalques Em Estacas Hélice Contínua Utilizando Redes Neurais Artificiais. In: XVII CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA, 2014, Goiânia, **Anais...** Goiânia: COBRAMSEG, 2014. CD-ROM.

ARAÚJO, C. B. C. de. **Gestão integrada de infraestrutura civil em ambiente urbano: água e transportes**. 2019. 235 f. Tese (Doutorado em Engenharia Civil) - Universidade Federal do Ceará, Fortaleza, 2019.

ARAÚJO, C. F. L. C. **Identificação do comportamento de atuadores ativos com molas LMF utilizando redes neurais artificiais não-linear autoregressiva com entrada exógena (RNANARX)**. 2019. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal da Paraíba, João Pessoa, 2019.

BALBO, José Tadeu. **Pavimentação Asfáltica: materiais, projetos e restauração**. São Paulo: Oficina de Textos, 2007. 558 p.

BARROS, K. S. **Estudo de cinzas volantes de uma termelétrica da região metropolitana de Fortaleza-CE para aplicação em camadas granulares de pavimentos**. 2015. 142 f. Dissertação (Mestrado em Engenharia de Transportes) - Universidade Federal do Ceará, Fortaleza, 2015.

BARROS, R. F. **Utilização do revestimento fresado da BR-104 como material de reforço da camada de base e/ou sub-base**. 2013. Monografia (Graduação em Engenharia Civil) - Universidade Federal de Pernambuco, Caruaru, 2013.

BARROS, V. P. A. **Avaliação do desempenho de algoritmos de retropropagação com redes neurais artificiais para a resolução de problemas não-lineares**. 2018. Dissertação (Mestrado em Ciência da Computação) - Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2018.

BASTOS, J. B. S. **Influência da variação da umidade no comportamento de pavimentos da região metropolitana de Fortaleza**. 2013. Dissertação (Mestrado em Engenharia de Transportes) - Universidade Federal do Ceará, Fortaleza, 2013.

BASTOS, J. B. S. **Considerações sobre a deformação permanente de pavimentos asfálticos no dimensionamento mecanístico-empírico**. 2016. 200 f. Tese (Doutorado em Engenharia de Transportes) - Universidade Federal do Ceará, Fortaleza, 2016.

BAYOMY, F. M; AL-SANAD, H. A. Características de deformação de solos sólidos do subleito em Kuwat. **Transportation Research Record**, Washington, DC, n. 1406, p. 77-87, 1993.

BERNUCCI, L. B.; MOTTA, L. M. G.; CERATTI, J. A. P.; SOARES, J. B. **Pavimentação Asfáltica: Formação Básica para Engenheiros**. 2. ed. Rio de Janeiro: Abeda, 2022.

BEZERRA NETO, R. S. **Análise comparativa de pavimentos dimensionados através dos métodos empírico do DNER e mecanístico e proposta de um catálogo simplificado de pavimentos para a região de Campo Grande (MS)**. 2004. 189 f. Dissertação (Mestrado em Engenharia de Transportes) – Universidade de São Paulo, Escola de Engenharia de São Carlos, São Carlos, 2004.

BICALHO, K. *et al.* Estudo do uso da Técnica de Redes Neurais Artificiais em Engenharia Geotécnica. In: **Anais XX COBRAMSEG, 2022**, Campinas. Anais eletrônicos... Campinas, Galoá, 2022. Disponível em: <https://proceedings.science/cobramseg-2022/trabalhos/estudo-do-uso-da-tecnica-de-redes-neurais-artificiais-em-engenharia-geotecnica?lang=pt-br>. Acesso em: 21 set. 2023.

BINOTI, D. H. B. *et al.* Redução dos custos em inventário de povoamentos equiâneos utilizando redes neurais artificiais. **Agrária**, v. 8, p. 125-129, 2012.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2010.

BRAGA, A. P. **Redes Neurais Artificiais: Teoria e Aplicações**. [S.l.]: [s.n.], 2011.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2.ed. Rio de Janeiro: LTC, 2007.

BRAGA, A.; CARVALHO, A.; LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**. 1. ed. [s.n.]: Rio de Janeiro, 2000.

BRITO, L. A. T. **Avaliação e análise paramétrica do ensaio de compressão diametral sob cargas repetidas em misturas asfálticas**. 2006. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

BRITO, J. R; SANTOS, T. C; RABELO, K. R; DE ARAÚJO BARROSO, SUELLY HELENA. Proposta de Ensaio Reduzido de Módulo de Resiliência de Solos Finos para Aplicação em Pavimentos. In: **XX Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica, 2022**, Campinas. COBRAMSEG 2022, 2022. v. 1. p. 1-8.

BRUNO, L. O. Aplicabilidade de Sistemas de Informações Geográficas (SIGs) livres nas ciências ambientais: o uso do QGIS. **Revista Brasileira de Gestão Ambiental e Sustentabilidade**, v. 4, n.8, p. 321-326, 2017.

BUSSAB, W. O.; MORETTIN, P. A. **Estatística básica**. 4. ed. São Paulo: Atual, 1987.

CABRAL, W. S. **Exploração, análise comparativa e modelagem da deformação permanente de materiais granulares da Microregião de Mossoró/RN**. 2021. 181f. Tese (Doutorado em Engenharia de Transportes) - Universidade Federal do Ceará, Departamento de Engenharia de Transportes, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2021.

CARVALHO, André Ponce de Leon F. de. **Redes Neurais Artificiais**. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em: 06 jun. 2021.

CARVALHO, R.; SCHWARTZ, C. Comparisons of Flexible Pavement Designs: AASHTO Empirical Versus NCHRP Project 1-37A Mechanistic-Empirical. *Transportation Research Record: Journal of the Transportation Research Board*, v. 1947, n. 36, p. 167-174, jan. 2006. doi: 10.3141/1947-16.

CAVALCANTE, F. C. I. T.; BARROSO, S. H. A. **Avaliação do Emprego do Solo Contaminado por Derivados de Petróleo para Aplicação em Bases e Sub-Bases de Pavimentos**. In: XXV Congresso de Ensino e Pesquisa em Transportes, 2011, Belo Horizonte. Anais XXV ANPET, 2011. v. 1. p. 1-12.

CELESTE, A. B.; OLIVEIRA, F. H. L. de. Study of retroanalysis of asphaltic pavements resilience modules with the use of artificial neural networks. **Transportes**, v. 27, n. 4, p. 123–133, 2019.

COLLINS, I. F. E.; BOULBIBANE, M. Análise geomecânica de pavimentos soltos com base na teoria de Shakedown. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 126, n. 1, p. 50-59, jan. 2000.

CORDANI, U. G. *et al.* Evolução crustal da plataforma Sul-Americana. In: **Tectonic evolution of South America**. Rio de Janeiro: IGC, 2000. p.19-40.

CORREIA, A. G. *et al.* A geotecnia nos pavimentos e vias-férreas e perspectivas para a era digital. **Geotecnia**, n. 152, p. 113-141, 2021.

CORREIA, A. G.; WINTER, M.; PUPPALA, A. A review of sustainable approaches in transport infrastructure geotechnics. **Transportes Geotechnics**, v. 7, p. 21–28, 2016.

COUTINHO, E. *et al.* Utilização de Técnicas de Inteligência Computacional me Predição de Dados Meteorológicos. Seropédica: **Revista Brasileira de Meteorologia**, v.31, n.1, p. 24-36, 2016. Disponível em: <https://doi.org/10.1590/0102-778620140115>. Acesso em: 22 jun. 2023

DANTAS NETO, S. A. **Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificadas com Borracha Granulada de Pneus Usados**. 2004. 265 f. Tese (Doutorado em Engenharia Civil) – Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2004.

DATA SCIENCE ACADEMY. Capítulo 6 – O Perceptron – Parte 1. In: ACADEMY, Data Science. Deep Learning Book. [S.l.: s.n.], 2015. p. 7. Disponível em: <https://www.deeplearningbook.com.br/o-perceptron-parte-1/>. Acesso em: 03 jun. 2022.

DAWSON A. R.; WELLNER F. Plastic behavior of granular materials. **Final Report ARC Project 933**. University of Nottingham. Reference PRG99014, April 1999.

DINIZ, S. F. **Caracterização fisiográfica e pedológica da região norte do estado do Ceará** (Tese de doutorado). Universidade Estadual Paulista, Rio Claro, 2010.

DNER – ME 093/64 – **Densidade real dos solos**, 1964.

DNER-ME 024/94: pavimento: determinação das deflexões pela viga Benkelman. Rio de Janeiro, 1994, 6 p.

DNER-ME 036/94: **Solo – determinação da massa específica aparente, “in situ” , com emprego do balão borracha**. Rio de Janeiro: IPR, 1994

DNER-ME 037/94: **solo – determinação da massa específica aparente, “in situ” , com emprego do óleo**. Rio de Janeiro: IPR, 1994

DNER-ME 092/94: **solo – determinação da massa específica aparente “in situ”, com emprego do frasco de areia**. Rio de Janeiro: IPR, 1994

DNIT – Departamento Nacional de Infraestrutura de Transportes. **Histórico**. Disponível em <http://www.dnit.gov.br/historico/>. Acesso em 16/01/2022.

DNIT (2018) ME134 – **Pavimentação – Solos – Determinação do módulo de resiliência – Método de ensaio**. Departamento Nacional De Infraestrutura De Transportes. Rio de Janeiro.

DNIT 134 – ME – **Pavimentação – Solos – Determinação do Módulo de Resiliência – Método de Ensaio**. Rio de Janeiro, 2010.

DNIT. Departamento Nacional de Infraestrutura de Transportes. **Manual de Pavimentação**. 3.ed. Rio de Janeiro: DNIT, 2006a. 274 p

DNIT. **Pavimentação: Reforço do subleito - Especificação de Serviço 138**. Rio de Janeiro. 2010a.

DNIT. **Pavimentação: – Sub-base estabilizada granulometricamente - Especificação de Serviço 139**. Rio de Janeiro. 2010b.

DNIT. **Pavimentação: – Base estabilizada granulometricamente - Especificação de Serviço.141**. Rio de Janeiro. 2010c.

DNIT. **Pavimentação: Sub-base de solo melhorado com cimento - Especificação de Serviço 140**. Rio de Janeiro. 2022.

EMBRAPA. **Limitações do uso dos solos do Estado do Ceará por suscetibilidade à erosão**. Fortaleza: EMBRAPA, 2002, 19p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Sistema brasileiro de classificação dos solos**. Brasília: EMBRAPA/SPI/CNPS, 1999. 412p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Sistema brasileiro de classificação dos solos**. 2. ed. Rio de Janeiro: Embrapa Solos, 2006. 360p.

ESTADOS UNIDOS. Soil Conservation Service. **Soil taxonomic**: a basic system of soil classification for making and interpreting soils surveys. Washington: USDA, 1975. 754p. (USDA. Agriculture Handbook, 436).

FACCIN, C. **Concretos Asfálticos em Utilização no Rio Grande do Sul: Comportamento Mecânico e Desempenho em Campo Quanto a Deformação Permanente**. Dissertação (mestrado) Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Santa Maria, 2018.

FANUCCHI, R. Z, OLESKOVIEZ, M., and BARBOSA, D. Análise da detecção de faltas de alta impedância utilizando redes neurais artificiais com topologias baseadas em perceptron multicamadas e redes rbf. In: **Simpósio Brasileiro de Automação Inteligente (SBAI)**, Fortaleza, 2013.

FHWA Federal Highway Administration (2014). **Speed Concepts: Informational Guide**. US DOT. Disponível em: [https://safety.fhwa.dot.gov/speedmgt/ref\\_mats/fhwasa10001](https://safety.fhwa.dot.gov/speedmgt/ref_mats/fhwasa10001). Acesso em: 24 ago. 2022.

FEDERAL HIGHWAY ADMINISTRATION. **Especificação do Aglutinante Superpave**. Washington: FHWA, 2002.

FERNANDES, P. V. A.; VIEIRA, F. A. F.; SILVA, B. T. A.; BARROSO, S. H. A. **Avaliação do Parâmetro de Módulo de Resiliência para Camada de Base Cinza/Cal de Pavimento a Partir de Ensaios in Situ Aplicando o Geogauge**. 2019. In: 33º Congresso de Pesquisa e Ensino em Transporte ANPET, Balneário Camboriú-SC, 10 a 14 de novembro de 2019.

FERREIRA, A. D. **Comparação entre Método Empírico e Mecânico-Empírico para Dimensionamento de Pavimentos Flexíveis**. Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC. 15 a 17 de setembro de 2021. Disponível em: [www.confea.org.br/midias/uploadsimce/Contecc2021/Civil/COMPARA%C3%87%C3%83O%20ENTRE%20M%C3%89TODO%20EMP%C3%8DRICO%20E%20MECAN%C3%8DTI%20COEMP%C3%8DRICO%20PARA%20DIMENSIONAMENTO%20DE%20PAVIMENTOS%20FLEX%C3%8DVEIS.pdf](http://www.confea.org.br/midias/uploadsimce/Contecc2021/Civil/COMPARA%C3%87%C3%83O%20ENTRE%20M%C3%89TODO%20EMP%C3%8DRICO%20E%20MECAN%C3%8DTI%20COEMP%C3%8DRICO%20PARA%20DIMENSIONAMENTO%20DE%20PAVIMENTOS%20FLEX%C3%8DVEIS.pdf). Acesso em: 20 de nov. 2022.

FERREIRA, J. G. H. M. (2008) **Tratamento de Dados Geotécnicos Para Predição de Módulos de Resiliência de Solos e Britas Utilizando Ferramentas de Data Mining** [Rio de Janeiro] 2008. XVI, 264p. 29,7cm (COPPE/UFRJ, D.Sc., Engenharia Civil, 2008). Tese - Universidade Federal do Rio de Janeiro, COPPE.

FERREIRA, J. G. H. M. **Tratamento de dados geotécnicos para predição de módulos de resiliência de solos e britas utilizando ferramentas de data mining**. 2008. Tese (Doutorado) – Universidade Federal do Rio de Janeiro, COPPE, Rio de Janeiro, 2008. XVI, 264 p.

FERREIRA, J. L. S.; SOARES, J. B.; BASTOS, J. S. Métodos de seleção granulométrica com foco na resistência à deformação permanente. **Revista Transportes**, v. 24, n. 2, p. 46-52, 2016. DOI: 10.4237/transportes.v24i2.1129.

FINE, T. L. Feedforward neural network methodology. [S.I.]: Springer Science & Business Media, 2006.

FLECK, L; TAVARES, M. H. F; EYNG, E; HELMANN, A.; ANDRADE, M. d. M. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.

FRANCO, F. A. C. P. **Método de dimensionamento mecânico-empírico de pavimentos asfálticos – SisPav**. Tese (Doutorado) - Universidade Federal do Rio de Janeiro, COPPE/UFRJ. Rio de Janeiro, 2007.

FRANZOI, S. **Algumas Peculiaridades Resilientes de Solos Lateríticos e Saprolíticos**. 1990. Dissertação (Mestrado). São Paulo. Escola Politécnica da Universidade de São Paulo.

FUNCEME. Fundação Cearense de Meteorologia e Recursos Hídricos. **Levantamento de reconhecimento de média intensidade dos solo-Mesorregião do sul do estado/Fundação Cearense e recursos hídricos**. Fortaleza: FUNCEME, 2012.

GEREMIAS, Manuel. **Profundidades de coleta de solo para fins de levantamento pedológico no estado do Ceará: um diagnóstico crítico**. 2020. 59 f. Dissertação (Mestrado em Ciência do Solo) - Centro de Ciências Agrárias, Universidade Federal do Ceará, Fortaleza, 2020.

GÓMEZ-MUÑETÓN, C. M. **Avaliação geotécnica de um perfil de solo tratado biotecnologicamente para fins de pavimentação**. 2013. Tese (Doutorado) - Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 2013. Publicação G.TD-083A/13, 161 p.

GUILHERME, A. T. P. et al. Previsão estatística e mapeamento das propriedades geotécnicas dos solos da microrregião de Mossoró-RN. **Brazilian Journal Of Development**, v. 6, n. 4, p. 22297-22318, 2020.

GUIMARÃES, A. C. R. **Um Método Mecânico-Empírico para a Previsão da Deformação Permanente em Solos Tropicais Constituintes de Pavimentos**. Tese de (Doutorado) - Programa de Engenharia Civil da COPPE/UFRJ, Rio de Janeiro, 2009.

HANANDEH, S. Introducing mathematical modeling to estimate pavement quality index of flexible pavements based on genetic algorithm and artificial neural networks. **Case Studies in Construction Materials**, v. 16, 2022, e00991. ISSN 2214-5095. DOI: 10.1016/j.cscm.2022.e00991. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214509522001231>. Acesso em: 17 jun. 2023.

HARTMANN, Diego Arthur. **Análise dos defeitos e da irregularidade de pavimentos flexíveis a partir do Guia da AASHTO de 2004**. 2009. 75p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2009. 75 p.

HAYKIN, S. **Redes Neurais - Princípios e Práticas**. Bookman, São Paulo, 2. ed. 2001.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Hamilton: Bookman, 2007. 898 p.  
Magalhães, P. H. L. (2005). **Avaliação dos Métodos de Capacidade de Carga e Recalque de Estacas Hélice Contínua via Provas de Carga**. Tese apresentada ao programa de engenharia civil e ambiental da universidade de Brasília como requisito parcial à obtenção do título de mestre.

HEUKELOM, W.; FOSTER, C. R. Dynamic testing of pavements. **Journal of the Structural Division**, v. 86, n. 1, p. 1-28, 1960. Proceedings of the American Society of Civil Engineers.

HICKS, R. G.; MONISMITH, C. L. Factors influencing resilient response of granular materials. **Highway Research Record**, n. 345, p. 15-31, 1971.

HONARMAND-EBRAHIMI, Ali. **Regression and Neural Network Modeling of Resilient Modulus Based on Routine Soil Properties and Stress States**. 2006. Dissertation (Doctor of Philosophy) - University of Oklahoma, Graduate College, Norman, Oklahoma.

HUA CUI, GEGE YUAN, NI LIU, MINGUYAN, XU & HUANSHEN SONG (2020): Convolutional neural network for recognizing highway traffic congestion, **Journal of Intelligent Transportation Systems**, DOI: 10.1080/15472450.2020.1742121. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/15472450.2020.1742121>. Acesso em 16 jun. 2022

HUANG, Y. H. **Pavement Analysis and Design**. 2. ed. Estados Unidos da América: Pearson Prentice Hall, 2004.

HVEEM, F. N. Pavement deflections and fatigue failures. **Highway Research Board**, n. 114, p. 43-87, 1955. Washington, DC.

INDIA, G. **Basic Road Statistics of India**. 2015-16. Ministry of Road Transport and Highways: New Delhi, 2018.

IPECE - Instituto de pesquisa e Estratégia Econômica do Ceará, **Características geográficas, recursos naturais e meio ambiente**. 2016.

JACOMINE, P.K.T.; ALMEIDA, J.C. & MEDEIROS, L.A.R. **Levantamento exploratório-reconhecimento de solos do Estado do Ceará**. Recife, 1973. 2v. 830p. DPP, Boletim Técnico, 28. SUDENE, Série Pedologia, 16.

JUNIOR, S. J. D. **O Efeito da Energia de Compactação em Propriedades dos Solos Utilizados na Pavimentação do Estado do Ceará**. (2005) Dissertação de Mestrado, Programa de Mestrado em Engenharia do Transportes, Universidade Federal do Ceará, Fortaleza, CE, 211 fl.

KLINSKY, L. M. G. BARDINI, V. S. S. FABBRI, G. T. P. Efeito da adição de areia de fundição residual e cal a solos argilosos no módulo de resiliência. **Transportes**, v. 22, n. 2(2014), p.1-10.

KOPIER, Alberto A.; SILVA, Victor Navarro A. L. da; OLIVEIRA, Luiz Antônio A. de; LINDEN, Ricardo; SILVA, Luis Renato A. de A.; FONSECA, Bruno L. da C. **Redes Neurais Artificiais e suas aplicações no setor elétrico**. Macaé, 2019.

KOVÁCS, Z. L. **Redes Neurais Artificiais** - Fundamentos e Aplicações. Editora Livraria da Física. 4. edição. São Paulo, 2006.

KROSE, B.; SMAGT, P. van der. An introduction to neural networks. [S.l.]: [s.n.], 1996.

LI, D.; LU, M. **Classical planning model-based approach to automating construction planning on earthwork projects**. Computer-Aided Civil and Infrastructure Engineering, 2018. DOI: 10.1111/mice.12420.

LIMA, C. D. A.; MOTTA, L. M. G. Influência da variação granulométrica de brita graduada simples na deformação permanente. In: ANPET – Congresso de Pesquisa e Ensino em Transportes, 29., 2015, Ouro Preto. **Anais...** Ouro Preto: ANPET, 2015a.

LIMA, C.; MOTTA, L. **Estudo da deformação permanente de uma brita graduada**. XVIII CILA - Congresso Ibero-Latinoamericano do Asfalto: Bariloche, Argentina, nov. 2015. Disponível em: [https://www.researchgate.net/profile/Laura-Motta/publication/301807805\\_ESTUDO\\_DA\\_DEFORMACAO\\_PERMANENTE\\_DE\\_UMA\\_BRITA\\_GRADUADA/links/611d1b1c0c2bfa282a519441/ESTUDO-DA-DEFORMACAO-PERMANENTE-DE-UMA-BRITA-GRADUADA.pdf](https://www.researchgate.net/profile/Laura-Motta/publication/301807805_ESTUDO_DA_DEFORMACAO_PERMANENTE_DE_UMA_BRITA_GRADUADA/links/611d1b1c0c2bfa282a519441/ESTUDO-DA-DEFORMACAO-PERMANENTE-DE-UMA-BRITA-GRADUADA.pdf). Acesso em: 27 abr. 2022.

LIMA, K. D. M. **Estudo de caso: análise qualitativa e quantitativa de material granular para a pavimentação na região de Goiânia**. 2021. 87 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) - Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Campus Goiânia, Goiânia, 2022.

LIMA, M. S. *et al.* Análise Mecânica de Resíduos de Construção e Demolição por meio de ensaios empíricos e mecanísticos. **Revista Conexões – Ciência e Tecnologia**, Fortaleza, v. 12, n. 1, p. 29-37, mar. 2018.

LOBO, A.; ARA, F.; BARÓ, F.; CAMINO, C. Geospatial analysis for conservation: applications with open-source software in the Natural Parks of Barcelona. **Applied Geomatics**, v. 4, n. 2, p. 113-122, 2012. Disponível em: <https://doi.org/10.1007/s12518-012-0079-z>. Acesso em: 03 set. 2023.

LOESCH, C.; SARI, S. T. **Redes neurais artificiais: fundamentos e modelos**. Blumenau: Ed. FURB, 1996.

LUSTOSA, J. P. G. **Caracterização morfológica, micromorfológica e mineralógica de três toposequências no município de Irauçuba-CE e suas relações com o processo de desertificação**. 2004. 162 p. Tese (Doutorado em Geociências) - Programa de Pós-Graduação em Geociências, Universidade Estadual Paulista, Rio Claro, 2004.

MAIA, Camila Lima. **Análise comparativa de módulos de resiliência obtidos com o geogauge para o controle de qualidade de camadas granulares dos pavimentos**. 2016. 149 f. Dissertação (Mestrado em Engenharia de Transportes) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2016.

MARSON, M. **Análise Crítica da Classificação MCT para Solos Tropicais**. p 216. Dissertação de Mestrado. Instituto Tecnológico de Aeronáutica, São José dos Campos, 2004.

MARTINELLI, Edmar. **Extração de conhecimento de Redes Neurais Artificiais**. 1999. 113 f. Dissertação (Mestrado) - Curso de Ciências da Computação e Matemática Computacional, Usp, São Carlos, 1999.

MASCARENHAS, I. M. N. **Caracterização geotécnica de solos na região metropolitana do Cariri/CE para uso em pavimentação**. 2016. 152 f. Dissertação (Mestrado em Engenharia de Transportes) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2016.

MASHAYEKHI, M.; AMINI, A. A.; BEHBAHANI, H.; NOBAKHT, S. Comparison of mechanistic-empirical and empirical flexible pavement design procedures of AASHTO: a case study. In: **5th International Conference Bituminous Mixtures and Pavements**, Thessaloniki, June 2011, pp. 319-328.

MATSUNAGA, V. Y. **Curso de redes neurais utilizando o Matlab**. Belém do Pará, 2012.

MEDINA, J.; PREUSSLER, E. S. Características resilientes de solos em estudos de pavimentos. **Solos e Rochas**, São Paulo, p. 3-26, 1980.

MEDINA, J.; MOTTA, L. M. G. **Mecânica dos Pavimentos**. 3. ed. Rio de Janeiro/RJ: Editora Interciência, 2015.

MEHRPAZHOUH, A.; NASER, S.; TAFRESHI, M.; MIRZABABAEI, M. Impact of repeated loading on mechanical response of a reinforced sand. **Journal of Rock Mechanics and Geotechnical Engineering**, v. 11, n. 4, p. 804-814, 2019. DOI: 10.1016/j.jrmge.2018.12.013.

MIRANDA, F. A.; FREITAS, S. R. C.; FAGGION, P. L. **Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem**. Boletim de Ciências Geodésicas, v.15, n.3, p. 428-443, 2009.

MONTANARI, R.; MARQUES JÚNIOR, J.; CAMPOS, M.C.C.; SOUZA, Z.M. & CAMARGO, L.A. Caracterização mineralógica de Latossolos em diferentes feições do relevo na região de Jaboticabal, SP. **Revista Ciência. Agrônômica.**, 41:191-199, 2010.

MONTEJO, A. **Ingeniería de pavimentos para carreteras**. Bogotá D.C.: Universidad Católica de Colombia, 1998.

MORAIS, E. C. (2010). **Reconhecimento de Padrões e Redes Neurais Artificiais em Predição de Estruturas Secundárias de Proteínas**. Tese apresentada ao programa de pós-graduação em engenharia civil da Universidade Federal do Rio de Janeiro, como requisito parcial à obtenção do título de doutor em engenharia de sistemas e computação, 2010.

MORAIS, E. C. **Reconhecimento de padrões e redes neurais artificiais em predição de estruturas secundárias de proteínas**. 2010. Tese (Doutorado em Engenharia de Sistemas e Computação) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

MORAIS, V. A. **Análise comparativa dos métodos de dimensionamento empírico e empírico-mecânico de pavimentos flexíveis**. 2014. Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Civil da Universidade Federal do Pampa. Alegrete-RS.

MOTA, F.O.B.; OLIVEIRA, J.B. & GEBHARDT, H. Mineralogia de um Argissolo Vermelho-Amarelo eutrófico e de um Planossolo Háptico eutrófico solódico numa topossequência de gnaisses no sertão central do Ceará. **Revista Brasileira de Ciência do Solo**, 26:607-618, 2002.

MOTTA, L. M. G. **Método de dimensionamento de pavimentos flexíveis**: critério de confiabilidade e ensaios de cargas repetidas. 1991. Tese (Doutorado em Engenharia Civil) – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1991.

MOURA, E. **Estudo de deformação permanente em trilha de roda de misturas asfálticas em pista e em laboratório**. 2010. 299 p. Tese (Doutorado em Engenharia de Transportes) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2010.

NAKAHARA, S. M. **Estudo sobre o desempenho de reforços de pavimentos asfálticos em via urbana sujeita a tráfego comercial pesado**. 2005. 300 p. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

NCHRP/TRB (2004) **Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures, Appendix RR: Finite Element Procedures for Flexible Pavement Analysis**, Illinois, USA.

NEVES, C. E. V. **Comportamento de materiais granulares usando o método dos elementos discretos**. 2009. 166 p. Dissertação (Mestrado em Engenharia Civil) – Universidade de Brasília, Brasília, 2009.

NGUYEN, B. T.; MOHAJERANI, A. Resilient modulus of fine-grained soil and a simple testing and calculation method for determining an average resilient modulus value for pavement design. **Transportation Geotechnics**, v.7, p.59-70, 2016.

OLIVEIRA, B. V. B.; LANZA, D. S. B.; MORAES, Á. L.; FAZAN, A. J.; BORGES, R. Estimativa de volume de escavação e de inclinação de taludes de corte utilizando critérios geológicos geotécnicos e ferramenta computacional para estudos de traçados. In: **XII Conferência Brasileira sobre Estabilidade de Encostas**, Florianópolis, Santa Catarina, Brasil, 2017.

OLIVEIRA, D. B. **O uso do resíduo pedra Cariri como material alternativo para aplicação em camadas granulares de pavimentos**. 2016. 111 f. Dissertação (Mestrado em Engenharia de Transportes) – Universidade Federal do Ceará, Fortaleza, 2016.

OLIVEIRA, J. S. **Desenvolvimento e treinamento de redes neurais artificiais para processamento de dados de radiação solar**. 2017. Trabalho de Conclusão de Curso (Graduação em Engenharia de Energia) – Universidade Federal de Santa Catarina, Florianópolis, 2017.

OLIVEIRA, M. A. **Aplicação de redes neurais artificiais na previsão de acidentes rodoviários em pista simples: estudo do trecho da BR-230 pertencente ao estado da Paraíba**. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Universidade Federal de Campina Grande, Campina Grande, 2021.

ONUWA, O.; ISONG, M.; EYO, E.; EYOH, A.; NWANEKEZIE, O.; OLAYINKA, D.N.; UDOUDO, D.O.; OFEM, B. GIS Cellular Automata Using Artificial Neural Network for

Land Use Change Simulation of Lagos, Nigeria. **Journal of Geography and Geology**, v. 4, n. 2, p. 94-101. 2012.

PAPAGIANNAKIS, A. T.; MASAD, E. A. **Pavement design and materials**. New Jersey: J. Wiley, 2008. 542 p.

PATEL, R. S.; DESAI, M. CBR predicted by index properties for alluvial soils of South Gujarat. In: INDIAN GEOTECHNICAL CONFERENCE, 2010, Mumbai. **Proceedings** [...]. Mumbai, 2010. p. 79-82.

PAULA, B. W. de L.; ALENCAR, B. G.; FAVACHO, F. J.; SALES, J. B. M.; BUSELI, A. A. P. T. Caracterização geotécnica de um solo do município de Ourém Pará: utilização como camada de base em rodovias. **Revista de Engenharias e Tecnologia**, v. 14, n. 1, 2022.

PITANGUI, L. C. **Análise comparativa do método do DNER com o método mecanístico-empírico MeDiNa**. 2019. 93 p. Monografia (Especialização em Engenharia Civil e Ambiental) – Universidade de Brasília, Brasília, 2019.

QGIS Development Team. **QGIS Geographic Information System**. Open Source Geospatial Foundation. 2017.

REIS, F. A. G. V. *et al.* **A geologia na construção e desenvolvimento sustentável do Brasil**. 1. ed. São Paulo: Funep, 2019. 180 p.

RIBEIRO, A. J. A. **Um método para localização e estimação das características geotécnicas dos solos da região metropolitana de Fortaleza-CE para fins de pavimentação**. 2013. 141 f. Dissertação (Mestrado em Engenharia de Transportes) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013.

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.

ROCHA, M. L. **Influência dos módulos de resiliência iniciais no procedimento de retroanálise de pavimentos flexíveis**. 2020. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de Juiz de Fora, Juiz de Fora, 2020.

ROCHA, R. S. C. **Patologias de pavimentos asfálticos e suas recuperações: estudo de caso da Avenida Pinto Aguiar**. 2010. Artigo Científico (Graduação em Engenharia Civil) – Universidade Católica do Salvador, Salvador, 2010.

ROSESTENGEL, A. P. do Amaral *et al.* Estudo comparativo entre os métodos de dimensionamento de pavimentos: CBR e medina. **Engenharia Civil: Inovação e tecnologia no contexto da era contemporânea**. Belo Horizonte, MG: Poisson, 2022. p. 8.

RUIZ, C. L. Presentación y comentatio sobre los diagramas Shell 1963 para el diseño de pavimentos flexibles. La Plata: **DVBA, Ministério de Obras Públicas**, Argentina, 1964.

SÁ, I. B.; CUNHA, T. J. F.; TAURA, T. A.; DRUMOND, M. A. Mapeamento da desertificação da mesorregião Sul do Ceará com base na cobertura vegetal e nas classes de solos. **Revista Brasileira de Geografia Física**, Recife-PE, v. 7, n. 3, 572-583, 2014.

SAS, W. GLUCHOWSKI, A. K., GABRYS & SZYMANSKI, A. Application of cyclic CBR test for the estimation of re-silient modulus in the pavement construction. In: **Proceedings of the XVI ECSMGE Geotechnical Engineering for Infrastructure and Development**, 2015, pp. 3747-3752. doi: 10.1680/ecsmge.60678.

SAS, W.; GLUCHOWSKI, A. K.; GABRYS, K.; SZYMANSKI, A. Application of cyclic CBR test for the estimation of resilient modulus in the pavement construction. In: XVI ECSMGE Geotechnical Engineering for Infrastructure and Development, 16., 2015. **Proceedings** [...]. 2015. p. 3747-3752. DOI: 10.1680/ecsmge.60678.

SANTIAGO, L. S. **Contribuições para o Desenvolvimento de um Método Mecânico Empírico de Dimensionamento de Pavimentos Asfálticos**. Tese (Doutorado) - Universidade Federal do Ceará. Fortaleza, 2017.

SANTIAGO, L. S.; SILVA, S. A. T.; SOARES, J. B. Determinação do dano em pavimentos asfálticos por meio da combinação do modelo S-VECD com análises elásticas. **Revista Transportes**, v. 26, p. 31-43, 2018.

SANTIAGO, L. S.; SOARES, J. B. Contribuições ao desenvolvimento do novo método de dimensionamento de pavimentos asfálticos no Brasil. In: XXIX Congresso Nacional de Pesquisa em Transportes da ANPET, 2015, Ouro Preto. **Anais** [...].

SANTIAGO, L. S.; SOARES, J. B. Contribuições ao desenvolvimento do novo método de dimensionamento de pavimentos asfálticos no Brasil. In: CONGRESSO NACIONAL DE PESQUISA EM TRANSPORTES DA ANPET, 29., 2015, Ouro Preto. **Anais** [...]. Ouro Preto: ANPET, 2015.

SANTOS, A. E. M.; SILVA, D. de F. S. da; MENDONÇA, G. A. .; SANTOS, T. V. .; AMARAL, R. R. .; SILVA, L. A. M. . Rockfall index and geological-geotechnical characterization on road slopes: a case study on BR-262. **Research, Society and Development**, [S. l.], v. 9, n. 12, p. e12891210968, 2020. DOI: 10.33448/rsd-v9i12.10968. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/10968>. Acesso em: 26 Set. 2023.

SANTOS, E. F. **Reciclagem de Materiais Fresados de Diferentes Fontes em Misturas Estabilizadas para Uso em Camadas Granulares de Pavimentos**. 2021. Dissertação (Mestrado em Engenharia Civil) Área de Concentração em Construção Civil e Preservação Ambiental, Universidade Federal de Santa Maria (UFSM), Rio Grande do Sul, Santa Maria, 2021.

SANTOS, T.A., PINHEIRO, R.J.B., SPECHT, L.P., et al., Análise do desempenho de subleitos rodoviários à luz de conceitos da Mecânica dos Pavimentos, **Revista Matéria**, v.25, n.3, 2020.

SENÇO, Wlastermiler de. **Manual de Técnicas de Pavimentação**. 2. ed. São Paulo: PINI, 2007.

SHAHIN, M. A., JAKSA, M. B., MAIER, H. R. (2001). **Artificial Neural Network Applications in Geotechnical Engineering**. *Australian Geomechanics* – March 2001.

SHEPHERD, A. Second-order methods for neural networks: Fast and reliable training methods for multi-layer perceptrons. [S.l.]: Springer Science & Business Media, 2012.

SILVA, C. F. S. C. **Reutilização do resíduo oriundo dos serviços de restauração asfáltica como material alternativo em camadas de pavimentos flexíveis**. 2012. Trabalho de Conclusão de Curso (Graduação em Ciências e Engenharias) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2012.

SILVA, L. F. **Pedogênese e classificação de Planossolos em diferentes regiões fisiográficas do Rio Grande do Sul**. Tese (Doutorado) – Universidade federal do Rio Grande do Sul, Faculdade de Agronomia, Programa de Pós-Graduação em Ciência do Solo, Porto Alegre, 2018.

SILVA, P. J. **Classificação geotécnica dos solos da Fazenda Argentina – Campus da UNICAMP, Campinas, SP**. 2018. Trabalho de Conclusão de Curso (Graduação em Geologia) – Instituto de Geociências, Universidade Estadual de Campinas, Campinas, 2018.

SILVA, P. F. A. **Manual de patologia e manutenção de pavimentos**. 1. ed. São Paulo: PINI, 2005.

SILVA, S. A. T.; Vidal, P. J. F.; Holanda, A. S.; Junior, E. P. Análise viscoelástica de pavimentos asfálticos utilizando elementos finitos e infinitos. **Transportes** v. 21, n. 3 (2013) p. 5–13, out. 2013. Disponível em: [www.revistatransportes.org.br/anpet/article/view/676/pdf\\_3](http://www.revistatransportes.org.br/anpet/article/view/676/pdf_3) Acesso em: 28 mar. 2022.

SOARES, J. B.; MATEOS, A.; MOTTA, L. M. G. Aspectos gerais de métodos de dimensionamento de pavimentos asfálticos de vários países e a relação com um novo método brasileiro. **Revista Pavimentação (ABPv)**, p. 20-35, out. 2009.

SOUZA, M. L. **Método de projeto de pavimentos flexíveis**. 3. ed. Rio de Janeiro: IPR, 1981.

SOUZA, R. A. de. **Estudo comparativo dos ensaios de CBR e Mini-CBR para solos de Uberlândia - MG**. 2007. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia Civil, Universidade Federal de Uberlândia, Uberlândia, 2007.

SOUZA, W. M.; RIBEIRO, A. J. A.; DA SILVA, C. A. U. Uma abordagem alternativa para obtenção da classificação de solos da AASHTO usando redes neurais artificiais. **Transportes**, v. 1, n. 1, p. 41-54, abr. 2021. Disponível em: <https://www.revistatransportes.org.br/anpet/article/view/2176/877>. Acesso em: 03 Set. 2023

TARAWNEH, D.; NAZZAL, M. D. Optimization of resilient modulus prediction from FWD results using artificial neural network. **Periodica Polytechnica Civil Engineering**, v. 58, p. 143-154, 2014.

TEODORO, Edivaldo. REDES NEURAIAS. **Network Technologies**, Nova Odessa, v. 1/2, n. 06, p. 57-70, mar. 2003. Disponível em: <http://www.luzimarteixeira.com.br/wp-content/uploads/2009/09/redesneurais.pdf>. Acesso em: 13 maio 202.

UZAN, J. Characterization of granular material. **Transportation Research Record**, n. 102, p. 52-59, 1985.

VASCONCELOS, S. D; BARROSO, S. H. A. Proposição de Modelos de Deformação Permanente para Materiais Naturais e Estabilizados com Cinzas de Carvão para a Região Metropolitana de Fortaleza. In: XXXII Congresso de Ensino e Pesquisa em Transportes, 2018, Gramado. **Anais do XXXII ANPET**, 2018. v. 1. p. 1-4.

VENSON, G. I. **Módulo de Resiliência e vida de fadiga de areia artificialmente cimentada**. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Programa de Pós-Graduação em Engenharia Civil, Porto Alegre, 2015.

WERKMEISTER, S. **Permanent deformation behavior of unbound granular materials in pavement constructions**. 2003. Tese (Doutorado) – Universidade Técnica de Dresden, Dresden, Alemanha, 2003.

WERNECK, Eugenio Paceli *et al.* **Estudo dos solos do entorno da cidade de Rondonópolis/MT com vistas a sua utilização em pavimentação**. 2006.

WILMOT, C. G.; MEI, B. Neural network modeling of highway construction costs. **Journal of Construction Engineering and Management**, v. 131, n. 7, p. 765-772, 2005. Disponível em: [http://dx.doi.org/10.1061/\(ASCE\)0733-9364\(2005\)131:7\(765\)](http://dx.doi.org/10.1061/(ASCE)0733-9364(2005)131:7(765)). Acesso em: 16 jun. 2022.

YU, H.-L.; KU, S.-C.; KOLOVOS, A. A GIS tool for spatiotemporal modeling under a knowledge synthesis framework. **Stochastic Environmental Research and Risk Assessment**, v. 30, n. 2, p. 665-679, 2016. <https://doi.org/10.1007/s00477-015-1078-5>.

ZANETTI, S. S; SOUSA, E. F; CARVALHO, D. F; BERNARDO, S. Estimação da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.12, n.2, p.174–180, 2008 Campina Grande, PB, UAEAg/UFCG. Disponível em: <http://www.agriambi.com.br> Protocolo 037.06 – 04/04/2006. Acesso em 12 de jul. de 2022.

ZEILER, M. D; FERGUS, R. Visualizing and understanding convolutional networks. In: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 2014. **Proceedings [...]**. p. 818-833.

ZHANG, Q.; ZHU, S. Visual interpretability for deep learning: a survey. **Frontiers of Information Technology & Electronic Engineering**, v. 19, n. 1, p. 27-39, 2018. doi:10.1631/FITEE.1700808.

## APÊNDICE A - VALORES DE PESOS SINÁPTICOS E BIAS DO MODELO DE CBR

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo C3 de previsão de CBR

	CAMADA DE ENTRADA	1ª CAMADA INTERMEDIÁRIA																	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
X	OT (%)	0,00821	0,0336	0,25361	0,17191	0,05819	0,24398	-0,28063	-0,07689	-0,44922	0,22879	0,28982	-0,15974	0,29874	-0,22679	-0,30649	-0,02807	-0,06714	-0,60141
0,508974	DEN (g/cm3)	0,26529	-0,09916	-0,02303	0,21162	-0,21534	0,23341	0,43723	-0,06145	0,00494	-0,01172	-0,01613	0,13875	-0,07618	-0,27624	-0,23286	0,06248	0,22694	0,34415
0,481579	LL (%)	-0,20622	0,1419	0,04527	0,08025	0,17005	-0,30874	-0,17378	0,20891	-0,22685	0,04788	-0,30226	0,02191	-0,20564	-0,36079	-0,38305	-0,0214	0,07738	-0,14928
0,661575	IP (%)	0,09929	-0,24975	0,09323	-0,13789	-0,19122	-0,20503	-0,19217	0,07585	0,31042	0,1957	0,05886	-0,13191	0,23128	0,38568	-0,11317	-0,01362	0,09745	0,6379
0,676	25,4 (#1")	-0,05383	0,16484	-0,18359	0,18557	-0,02401	0,32237	1,11531	0,30717	-0,32314	-0,12109	-0,29121	-0,74498	0,09274	-0,23026	0,09781	-0,85729	-0,30964	-0,02619
0,79878	9,5 (#3/8")	-0,0374	-0,30004	-0,12074	0,01086	0,07298	-0,05861	0,13451	-0,22831	-0,11361	0,10063	-0,31557	0,3672	-0,10726	-0,03275	0,1614	-0,45536	-0,05153	0,12338
0,607143	4,76 (#4)	-0,18424	-0,30888	0,17813	0,11146	0,09511	0,06473	0,81369	0,23729	-0,07054	-0,05305	0,19933	0,38522	-0,07773	-0,23751	0,17281	0,02798	0,23653	0,11004
0,639157	2 (#10)	0,33052	0,17104	-0,16934	-0,29461	-0,2911	0,09697	0,04304	0,14523	-0,0743	-0,15576	0,10631	-0,00853	0,01231	0,01924	0,22245	-0,09201	-0,1327	0,20511
0,513291	0,42 (#40)	0,02189	-0,00104	0,05624	-0,05761	0,30545	0,04072	-0,41554	-0,05828	0,01921	-0,13312	-0,1572	-0,13451	-0,1774	0,36449	-0,12691	0,06829	0,14169	-0,1571
0,41988	0,074 (#200)	0,042	-0,21921	0,2339	-0,04848	0,31615	-0,07425	0,21401	0,08162	0,32409	-0,31755	0,21157	0,09253	-0,28388	-0,01869	-0,54413	0,24967	-0,10383	0,76505
0,419231	CLAS	-0,15212	-0,23685	-0,20422	0,232	-0,16634	0,1248	0,0913	-0,17821	0,01903	-0,00726	0,06836	0,03855	0,03523	0,02526	0,18044	0,07121	0,12999	-0,36392
0,85	CBR	-0,37459	-0,10057	-0,10799	0,26215	0,41963	0,16011	-2,22617	0,18658	-0,12151	-0,04447	-0,22201	-6,29633	0,38905	-0,15636	0,34314	1,46849	0,25906	0,13438
0,136538	bk	0,33995	0,22859	0,03673	-0,19373	-0,39174	-0,18494	1,16854	0,28356	0,03453	-0,23405	-0,24371	-1,05795	0,04685	-0,07527	-0,53704	-1,06768	0,19117	0,08079
	vk1	-0,088327007	-0,43137	-0,10523	0,445237	-0,00706	0,274014	0,272792	0,78212	-0,50369	-0,34842	-0,6476	-7,55865	0,373605	-0,63713	-0,51923	-0,40348	0,573317	0,582304
	yk1	0,477932593	0,393799	0,473716	0,609506	0,498236	0,568078	0,567778	0,686137	0,376675	0,413765	0,343532	0,000521	0,59233	0,345897	0,373033	0,400476	0,639528	0,641597

		2° CAMADA INTERMEDIÁRIA															
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
yk1	CAMADA DE ENTRADA	1	-0,0153	-0,14969	0,57708	0,18704	-0,37391	0,08044	-0,19531	-0,22104	-0,2951	0,10788	-0,45495	0,37919	0,24438	0,02598	0,06242
0,477932593		2	-0,1913	0,0051	0,25095	0,30701	-0,02655	0,25188	0,15041	0,20134	-0,25761	-0,13721	-0,19383	0,00756	0,18379	0,26091	-0,08852
0,393799312		3	0,14861	0,23081	-0,04225	0,16334	0,06103	-0,07545	-0,03302	-0,11284	-0,27384	-0,02351	-0,20932	0,09839	0,34452	-0,24299	0,02943
0,473715752		4	0,18583	0,12377	0,20832	-0,06041	-0,0507	0,27541	0,11261	-0,32121	-0,00967	-0,07916	0,19187	-0,11561	-0,16743	0,19718	-0,18931
0,609506108		5	0,3395	-0,11386	-0,36964	0,01789	-0,01498	-0,25202	0,22534	-0,15916	0,09921	-0,12691	0,42256	-0,39654	-0,11451	-0,29762	-0,01377
0,498236201		6	0,24448	-0,2754	-0,43885	-0,42405	0,24089	-0,05058	-0,2552	-0,18637	0,04818	-0,07116	0,39676	-0,33131	-0,1982	0,04674	-0,22712
0,568078152		7	-0,50735	0,48547	0,69726	0,88108	-0,14326	0,17479	-0,45891	-0,00915	-0,43004	0,03043	-0,54463	0,15784	0,84008	0,08404	0,46805
0,567778163		8	0,22574	-0,25169	0,27758	-0,02949	0,06354	-0,00903	0,2642	0,00265	0,04207	-0,09542	-0,06807	-0,24569	0,27398	0,02568	-0,11196
0,686136844		9	-0,36313	-0,02882	0,00839	0,33065	0,01434	0,021	-0,27841	0,25904	-0,25478	0,23343	-0,47844	0,21332	0,59403	-0,263	0,22737
0,37667485		10	-0,05102	-0,11999	-0,10163	-0,0082	-0,20556	0,05616	0,18418	-0,21018	-0,02564	-0,24972	-0,28878	0,15592	0,19821	-0,14764	0,18232
0,413764749		11	-0,20482	-0,15151	0,23524	0,02512	0,13638	-0,16954	0,14959	0,11103	-0,35693	0,20545	-0,24508	0,2315	0,25105	-0,1987	0,24594
0,343531613		12	-1,42046	0,87074	1,03994	1,38477	-1,20741	-0,43061	-0,32795	0,52927	-0,53419	0,23981	-0,86816	0,63999	0,35282	-0,15521	0,66897
0,000521305		13	0,10459	-0,15908	-0,02363	0,06365	0,39398	-0,06361	-0,12682	-0,19171	0,31824	-0,02645	0,23871	0,09674	-0,25676	0,11928	-0,03992
0,592329724		14	-0,37109	0,26401	0,49976	0,29437	0,10452	0,13064	-0,27716	-0,15406	-0,08288	0,18359	-0,21406	0,1898	0,50256	0,22925	0,09452
0,345896602		15	0,36587	-0,09103	-0,31554	-0,56119	0,48804	-0,28958	0,29011	0,03529	0,37623	-0,13704	0,25815	-0,12708	-0,20491	-0,23822	-0,25979
0,373032716		16	0,31937	-0,27469	-0,66132	-0,28879	0,3101	0,20193	0,33024	-0,1978	0,47875	-0,32204	0,35388	-0,48041	-0,47151	-0,30423	-0,1807
0,40047636		17	-0,12906	-0,08455	0,14614	-0,32188	0,13209	0,19698	-0,08587	0,1605	-0,18055	0,02213	0,01043	0,1033	-0,32554	-0,07581	0,14729
0,63952817		18	0,49268	-0,40547	-0,43246	-0,30245	0,29254	0,2646	0,29049	0,01631	0,06823	0,13969	0,35809	-0,20419	-0,53902	0,22826	-0,51839
0,641597441		19	-0,37715	0,07818	-0,03627	0,09091	-0,08566	0,13709	0,08436	0,00143	0,21669	-0,27129	-0,37103	0,19079	0,10923	0,18918	0,03895
	vk2	-0,5482	0,24756	-0,11469	0,031202	-0,31919	-0,30637	0,23923	0,534479	0,236686	-0,20093	-0,17691	-0,11987	-0,17492	-0,05746	0,089874	
	yk2	0,366282	0,561576	0,471359	0,5078	0,420872	0,424001	0,559524	0,630527	0,558897	0,449936	0,455889	0,470068	0,456381	0,485639	0,522453	

		3° CAMADA INTERMEDIÁRIA												
		1	1	2	3	4	5	6	7	8	9	10	11	12
yk2	CAMADA DE ENTRADA	1	-0,9705	0,45666	0,12417	-1,48158	0,87821	0,68921	0,32753	-0,97435	0,16306	0,88529	0,43521	-0,49907
0,366282378		2	0,18543	-0,543	-0,20569	0,35583	-0,49148	-0,07597	-0,56379	0,44993	0,09679	-0,47293	0,07048	0,3547
0,561575887		3	0,65021	-0,3086	-0,14441	1,26611	-0,54226	-0,47075	-0,29566	0,4412	-0,03984	-0,5174	0,19647	0,65883
0,471358888		4	0,83409	-0,70127	-0,43646	1,39377	-0,79682	-0,64666	-0,54911	0,67653	-0,4196	-0,77575	-0,0206	0,38551
0,507799911		5	-0,80153	0,53899	-0,0914	-0,74886	0,22335	0,64037	0,34858	-0,59724	0,21377	0,56611	0,09669	-0,32873
0,420872139		6	-0,18624	0,24916	0,23808	0,18284	0,21923	0,18971	0,1929	-0,07372	0,04926	0,2449	0,31653	-0,06265
0,42400121		7	-0,10283	0,42534	0,0153	-0,38474	0,3379	0,34653	0,25823	-0,42187	0,02006	0,24464	0,31315	0,00555
0,559523946		8	0,27646	0,17332	-0,04747	0,25051	-0,30232	0,09875	-0,09468	0,289	-0,00209	-0,10606	-0,04905	0,14775
0,630527147		9	-0,48109	0,01203	-0,07148	-0,90092	0,5151	0,48496	0,46315	-0,19923	0,1265	0,09388	-0,21952	-0,04466
0,55889671		10	0,17248	-0,16541	0,16391	0,4242	-0,09037	0,12923	-0,15993	-0,16851	0,26679	0,0143	-0,19991	0,065
0,449935649		11	-0,55182	0,5041	0,11128	-1,27353	0,61956	0,37861	0,67821	-0,69042	0,2281	0,26883	0,03554	-0,36027
0,455888618		12	0,17537	-0,07005	-0,21123	0,67143	-0,09691	-0,48975	-0,38798	0,35063	0,21056	-0,29362	0,19978	0,14016
0,470067729		13	0,07719	-0,37356	-0,21013	1,02147	-0,46219	-0,37754	-0,29692	0,37317	0,15297	-0,03315	-0,18794	0,45277
0,456380752		14	-0,29736	0,08453	0,30433	0,19791	0,00408	0,00856	-0,12135	-0,26547	-0,04474	-0,0596	0,15642	-0,07993
0,48563867		15	0,15822	-0,33106	-0,24894	0,55346	-0,25933	-0,36596	-0,17093	0,33209	-0,11802	-0,21975	-0,28256	0,23666
0,52245349		16	-0,10095	-0,03303	-0,04408	0,18575	0,0159	-0,25068	0,07953	0,01602	-0,15917	0,15656	0,04882	-0,35514
		vk3	-0,10095	-0,03303	-0,04408	0,18575	0,0159	-0,25068	0,07953	0,01602	-0,15917	0,15656	0,04882	-0,35514
		yk3	0,474784	0,491743	0,488982	0,546304	0,503975	0,437656	0,519872	0,504005	0,460291	0,53906	0,512203	0,412137

		4° CAMADA INTERMEDIÁRIA									
		1	1	2	3	4	5	6	7	8	9
yk3	CAMADA DE ENTRADA	1	0,88848	0,35627	0,88023	0,23254	0,77337	-0,46495	-1,07211	-0,58288	0,66781
0,474783911		2	-0,50119	-0,67969	-0,31354	-0,58869	-0,76432	0,21947	0,56223	0,66873	-0,51826
0,491743251		3	-0,11214	-0,12695	-0,09613	-0,24422	-0,38336	0,12559	0,12616	0,36706	-0,38587
0,488981784		4	1,17212	1,00064	1,20319	0,64602	1,73056	-0,28734	-1,51994	-0,69546	0,66209
0,546304439		5	-0,77186	-0,74778	-0,92446	-0,77747	-0,92879	0,19902	1,02794	0,50426	-0,73625
0,503974916		6	-0,64493	-0,57038	-0,8947	-0,6195	-0,98252	0,30605	0,37968	0,68648	-0,3678
0,437656135		7	-0,78172	-0,62585	-0,38257	-0,40443	-0,50918	0,27388	0,81024	0,67672	-0,13354
0,519872027		8	0,75949	0,91414	1,0128	0,69181	0,89442	-0,20238	-0,53074	-0,64468	0,15308
0,504004914		9	-0,1057	0,08137	-0,06092	-0,27256	-0,36563	-0,01988	0,12716	0,31635	-0,41537
0,4602913		10	-0,78811	-0,7877	-0,81794	-0,27507	-0,73007	0,13294	0,9122	0,55044	-0,24918
0,539060249		11	-0,33199	-0,0829	-0,45295	-0,14431	0,20168	0,19093	0,22627	0,18891	0,03183
0,512202576		12	0,40261	0,31301	0,17533	0,23025	0,67688	0,07173	-0,6595	-0,19073	0,39212
0,412136542		13	-0,21854	-0,24543	-0,31141	0,02929	-0,01503	0,00841	0,24093	0,02219	-0,29327
	vk4	-0,21854	-0,24543	-0,31141	0,02929	-0,01503	0,00841	0,24093	0,02219	-0,29327	
	yk4	0,445581	0,438949	0,422771	0,507322	0,496243	0,502102	0,559943	0,505547	0,427204	

5° CAMADA INTERMEDIÁRIA		
	yk4	-2,35628
	0,445581413	-1,85906
	0,43894865	-2,51218
	0,422770611	-1,17992
	0,507321977	-3,15993
	0,496242571	1,18451
	0,502102488	4,25382
	0,55994282	2,65579
	0,505547272	-0,9911
	0,427203506	2,11378
	vk5	2,515317217
<b>Valor Final de Saída</b>	<b>yk5</b>	<b>0,925208662</b>

QR CODE para acesso a planilha com os pesos e bias do modelo C3, no qual obteve maior valor de correlação para CBR.



## APÊNDICE B – VALORES DE PESOS SINÁPTICOS E BIAS DOS MODELOS DE MR

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo M1 de previsão de MR

		1° CAMADA INTERMEDIÁRIA																	
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
X	CAMADA DE ENTRADA	<b>OT (%)</b>	1,87241	1,1051	0,8478	-1,7085	1,5838	-0,26264	0,29996	0,06527	-5,56531	0,09204	-0,31047	1,19135	-2,35711	2,36724	0,52956	0,49113	-0,31407
0,35		<b>DEN (g/cm3)</b>	-1,8862	-0,8481	0,6047	-0,0466	-2,8745	0,90023	0,64036	0,51782	0,71683	-1,22493	-0,41961	7,47249	-1,82661	1,99562	-1,63599	0,17071	0,11841
0,811		<b>CBR (%)</b>	-1,0339	-0,5935	-0,4146	3,9925	-0,6187	-6,47718	0,08878	-0,88503	3,36059	1,11394	-0,46614	-2,51668	1,77868	-1,04234	0,50104	-0,36123	1,12877
0,58		<b>EXP (%)</b>	-1,7649	1,0162	-0,7033	-1,4867	0,7290	-0,97152	-0,03441	1,47639	-3,16540	1,39985	0,20109	-3,96829	2,67490	-0,88563	0,40417	0,85850	0,41536
0,15		<b>LL (%)</b>	0,6676	2,3901	-1,8859	-2,4995	0,4143	-6,05252	-0,10635	-1,23219	2,06719	-0,03980	0,12380	1,08848	1,09538	-1,69990	0,42042	-0,95646	-0,75371
0,15		<b>IP (%)</b>	-0,74184	-0,2548	0,9522	2,0377	0,3569	-3,18217	-0,44342	-0,59452	1,06607	-1,88783	-0,52286	0,27640	-0,23584	-1,89653	1,01549	-1,74355	-1,27028
0,15		<b>25,4</b>	-3,70128	-0,5365	0,1938	-5,0945	1,8739	-1,03142	0,75161	0,64339	1,10940	0,06081	-0,67275	4,72567	-2,30478	-2,69998	0,54104	-0,37741	0,88163
0,43		<b>9,5</b>	0,0348	-1,0745	-0,7805	4,1914	-0,2498	-1,46885	-0,36805	-0,12516	0,68788	-0,47135	-0,58220	-2,65875	0,11739	-0,22542	-0,33923	-0,33837	-0,00168
0,34		<b>4,76</b>	-1,7846	1,0466	2,3185	0,2001	-1,2247	1,64930	2,38586	-1,15427	-3,10833	-0,23589	-0,34594	-1,76001	-0,12095	-1,36085	-0,80079	-1,84698	-1,35199
0,42		<b>2</b>	-2,6704	-0,5797	-1,1508	2,5737	0,0516	-0,44912	-1,38860	0,24943	-3,63842	-0,67260	-0,15917	-1,13916	-0,55759	-0,25391	-0,09363	-1,20064	-1,35592
0,41		<b>0,42</b>	-1,0471	0,4345	1,1041	0,6450	2,6483	-0,65313	-4,78402	0,49379	6,29564	0,65604	-0,09298	-1,03495	0,75358	-3,61794	0,52229	-0,21312	0,00287
0,26		<b>0,074</b>	-1,7618	-1,8549	2,3242	7,3285	-1,6401	2,37260	0,05330	-1,76918	-0,79734	-0,15740	-0,12059	1,15741	1,16383	5,80765	-1,07824	-1,72451	-2,38402
0,18		<b>σ3</b>	0,4772	0,5009	0,4376	0,3935	-0,5021	0,13191	0,64167	0,98238	0,06326	0,75831	-0,13064	0,19402	0,39230	0,13008	-0,16819	-1,91595	-0,13967
0,15		<b>σd</b>	2,0395	-3,4873	2,7859	0,2259	-1,8107	0,46818	-11,02348	1,21921	-0,72754	-0,12254	-0,57593	0,32697	0,44823	1,13190	-1,44434	1,36958	2,51878
0,18		<b>Class</b>	-1,1223	0,2083	-0,9472	-1,4337	0,0323	0,18965	-0,18424	-2,49997	0,29093	-0,54828	0,11291	-0,13144	0,25740	0,09068	0,74155	0,82044	0,67240
0,15		<b>bk</b>	1,8848	-0,8826	-0,5956	-1,9300	-0,03936	1,35135	-0,06872	-0,63167	-2,33829	-0,20894	-0,35111	-4,83435	0,58137	-0,74856	-0,66825	0,62801	-0,06130
		<b>v1</b>	-5,66828	0,605611	18,69383	-7,38356	1,693716	26,0365	6,791998	0,59752	-22,6443	2,852266	0,214648	-11,5983	1,435882	1,0066	0,588803	-2,28578	-3,55848
	<b>y1</b>	0,003442	0,646939	1	0,000621	0,844712	1	0,998879	0,645089	1,46E-10	0,945436	0,553457	9,18E-06	0,807816	0,732354	0,64309	0,092307	0,027693	

2° CAMADA INTERMEDIÁRIA																
y1		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0,0034	1	0,49326	0,15962	0,41920	0,25639	-0,31732	-0,27636	0,12723	-4,110650	-0,008370	0,975000	0,266460	-0,329470	-0,798640	0,184830	-0,774280
0,64	2	0,06858	-0,49539	-0,17014	-0,20212	-0,11557	0,31765	-0,36295	2,738950	-0,242330	0,470820	-0,179770	0,466030	0,595360	-0,120250	0,199810
0,99	3	-0,71085	-2,70801	-1,17181	-0,46637	-0,21557	0,63577	-0,72547	2,183490	-0,514920	-2,845480	-0,428490	0,546280	0,684770	-0,498830	0,806280
0,0006	4	0,22379	2,42302	0,41356	-0,21139	-0,44104	-0,24008	0,12484	-0,952770	0,249570	4,368820	-0,079590	-0,450590	-0,876070	-0,138710	0,256210
0,844	5	0,75072	0,64921	1,01251	0,32034	-0,31285	-0,73842	0,42657	-1,280590	0,074930	1,145450	0,192180	-0,354680	-0,522040	-0,019220	-0,478320
0,99	6	1,45240	2,43231	1,78191	0,42517	-0,02823	-1,58391	0,71635	-2,688080	0,364920	2,552910	0,298390	-1,072900	-0,939770	0,042610	-1,587710
0,99	7	-0,69840	-0,77276	-0,61568	-0,00544	-0,19164	1,02786	-0,31560	5,312650	-0,213840	-1,263740	-0,130830	0,449890	1,048430	-0,039870	1,481720
0,64	8	-0,79819	-0,63220	-0,90475	-0,11200	0,03457	0,60327	-0,30953	-1,849020	-0,498390	-2,323190	-0,101830	0,321590	-0,019290	-0,269650	-0,201890
1,46E-10	9	-2,09424	-2,56580	-2,42776	-0,61523	0,01113	1,66569	-1,11402	2,429730	-0,665360	-2,527750	-0,123530	1,270540	1,689350	-0,441610	1,230050
0,94	10	0,25947	-0,04780	0,80089	0,12205	-0,20091	-0,56627	-0,15653	-1,221680	0,050190	-0,436650	-0,210600	-0,421860	-0,651630	-0,214510	-0,769440
0,55	11	0,18295	-0,02219	0,02872	0,21383	0,11026	-0,02550	-0,130610	0,153690	0,224960	0,275970	-0,210180	-0,261050	-0,201060	-0,187000	0,088550
9,18E-06	12	0,71309	0,34620	0,95347	-0,09759	-0,45468	-1,05401	0,137740	-4,289710	-0,004910	-0,302570	-0,097750	-0,402200	-0,373090	0,187570	-1,801880
0,8	13	0,23291	1,04777	0,01748	-0,06183	-0,40382	-0,23557	0,109100	-2,803090	0,132160	1,071730	-0,308150	-0,363460	-0,209020	-0,163170	-1,040480
0,73	14	-0,32913	-1,46779	-0,62822	-0,22011	-0,26848	1,06827	-0,167440	2,682830	-0,623940	-2,893880	0,158320	0,657910	0,802880	-0,062010	1,360900
0,64	15	0,74700	0,28760	0,52089	0,07071	0,18932	-0,46198	0,432360	-0,508110	0,365290	0,762390	-0,152130	-0,473660	-0,538080	-0,036470	-0,776890
0,09	16	0,66624	-0,29334	0,86889	0,32508	-0,23384	-0,88589	0,535580	-2,023580	0,320380	-1,289370	0,109080	-0,871260	-1,167980	0,175840	-1,157250
0,02	17	0,57501	0,18234	0,95252	0,02755	-0,27192	-0,89975	0,027000	-2,227300	0,302460	-1,243910	-0,051190	-0,278640	-0,826140	-0,018780	-1,188540
	18	-0,20430	-0,65816	0,16838	-0,42114	-0,14393	-0,38792	-0,073140	0,923430	-0,466100	-0,402880	-0,387800	-0,227890	0,026640	-0,240730	-0,375700
	v2	-0,2043	-0,65816	0,16838	-0,42114	-0,14393	-0,38792	-0,07314	0,92343	-0,4661	-0,40288	-0,3878	-0,22789	0,02664	-0,24073	-0,3757
	y2	0,449101911	0,341153	0,541995825	0,396244	0,464079	0,404218	0,481723	0,71574	0,38554	0,400621	0,404247	0,443273	0,50666	0,440106	0,407164

y2	3° CAMADA INTERMEDIÁRIA										
		1	2	3	4	5	6	7	8	9	10
0,449101911	1	-0,843380	0,223610	0,003210	0,001560	-1,443780	0,064350	-0,920950	-0,327170	-0,520660	-1,499940
0,341153063	2	-1,475060	1,028810	0,724770	0,047000	-1,995910	-0,006410	-1,295810	-0,029660	-1,394350	-1,986920
0,541995825	3	-0,786950	0,237220	0,330720	-0,171410	-2,089960	-0,022150	-1,157580	-0,278040	-0,665630	-1,597250
0,39624399	4	-0,393140	-0,076090	0,197740	0,180150	-0,522980	0,195880	0,055710	0,049710	-0,377160	-0,338990
0,464079489	5	-0,272660	-0,254070	-0,221300	-0,211440	0,157370	-0,230510	0,092150	0,077000	0,181070	0,176500
0,404218118	6	0,981290	-0,420370	-0,032590	-0,313590	1,888050	0,295100	0,440160	0,285180	0,513390	1,194180
0,481723147	7	-0,631880	0,028560	0,266640	0,228240	-0,815320	-0,091650	-0,257750	-0,240070	-0,258960	-0,690580
0,715740476	8	2,381660	-0,648780	-0,324060	-0,498870	5,678680	0,021990	2,348160	0,436090	1,980050	4,801040
0,385539736	9	-0,355500	-0,080820	-0,085300	0,216140	-0,625530	0,217430	-0,341350	-0,091260	-0,511040	-0,326400
0,400620586	10	-1,998530	1,420510	1,308330	0,106510	-2,338530	0,541560	-1,808590	-0,279240	-1,747780	-2,423700
0,404247018	11	-0,020910	0,245420	-0,102440	-0,072740	-0,240840	-0,218100	-0,232170	0,074300	-0,081640	-0,047210
0,443272793	12	0,760120	0,016380	-0,234720	-0,026460	1,188800	-0,219630	0,487120	-0,185230	0,725270	0,745610
0,506659606	13	0,458930	-0,313820	-0,290800	-0,137260	1,662940	-0,058690	0,758670	-0,164050	0,645330	1,338360
0,440106462	14	-0,216530	0,276740	-0,041550	0,213560	-0,141470	-0,145480	0,166980	-0,134830	-0,236040	-0,294050
0,407164422	15	0,972440	-0,135740	-0,124660	-0,091920	2,031490	0,055780	0,634410	-0,260730	0,361640	1,817920
	16	0,038930	0,042680	0,129500	0,129370	-0,415730	-0,104590	0,020030	-0,302630	-0,060450	-0,028350
	v3	0,03893	0,04268	0,1295	0,12937	-0,41573	-0,10459	0,02003	-0,30263	-0,06045	-0,02835
	y3	0,509731	0,510668	0,53233	0,532297	0,397539	0,473876	0,505007	0,424915	0,484892	0,492913

		4° CAMADA INTERMEDIÁRIA									
			1	2	3	4	5	6	7	8	9
y3	CAMADA DE ENTRADA	1	-0,407760	-1,576460	1,369800	-0,487300	-1,063520	-0,090650	-1,204900	-0,866060	-0,842710
0,509731271		2	-0,175080	1,427530	-1,221190	-0,188210	1,270400	-0,346760	1,083400	0,063360	-0,101060
0,510668381		3	-0,024370	0,932850	-1,201330	-0,389060	1,005140	-0,015250	1,116600	0,222790	0,370910
0,532329831		4	0,286800	0,603010	-0,318570	0,125810	0,266570	-0,181860	0,536900	-0,191230	-0,514710
0,532297467		5	-0,456410	-2,605480	3,303000	-0,883240	-2,415830	-0,415670	-2,272020	-0,857330	-0,950820
0,397538974		6	-0,214350	0,615490	-0,740620	0,017790	0,163990	-0,337500	0,300010	-0,115830	-0,332070
0,47387631		7	-0,394100	-1,476160	1,146970	-0,522110	-1,169410	-0,183780	-1,289600	-0,371210	-0,622640
0,505007333		8	-0,219400	0,108760	-0,230690	-0,337410	-0,091680	-0,195050	0,016970	-0,263580	-0,050030
0,424914684		9	0,009260	-1,267810	1,045160	-0,211530	-1,173040	-0,360720	-1,028780	-0,453970	-0,488320
0,4848921		10	-0,147670	-2,549530	2,599150	-0,428780	-2,303890	-0,278430	-1,641680	-1,013770	-0,939840
0,492912975		11	-0,369750	1,389410	-1,507870	-0,410430	1,573730	-0,127240	1,164000	-0,293670	0,075480
	v4		-0,36975	1,38941	-1,50787	-0,41043	1,57373	-0,12724	1,164	-0,29367	0,07548
	y4		0,408601	0,800498	0,181255	0,398809	0,828315	0,468233	0,762059	0,427106	0,518861

5° CAMADA INTERMEDIÁRIA		
		CAMADA DE SAÍDA
y4	1	0,544750
0,408601432	2	-2,544900
0,800498036	3	5,025490
0,181254674	4	-0,025810
0,39880902	5	-2,208620
0,828314699	6	0,462140
0,468232848	7	-1,816490
0,762058776	8	-0,438720
0,427105629	9	-0,576360
0,518861046	10	4,051860
	v5	4,05186
<b>Valor Final de Saída</b>	<b>y5</b>	<b>0,982907244</b>

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo M2 de previsão de MR.

		1° CAMADA INTERMEDIÁRIA															
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
X	CAMADA DE ENTRADA	<b>CBR (%)</b>	-0,07597	-0,65187	1,17608	0,09583	-0,76582	-0,00013	0,02224	0,0877	-0,08786	1,71223	-0,2123	-0,03127	0,02737	0,23428	0,02693
0,811111		<b>DEN (g/cm3)</b>	0,00158	0,44801	0,43373	0,26742	-0,41242	0,02123	0,01806	0,14869	0,08877	-1,67381	-0,24178	-0,10501	-0,10083	0,24666	-4,77089
0,589564		<b>25,4</b>	0,12758	0,90722	0,71017	0,51532	-0,17709	-0,38803	-0,05089	-0,00406	0,07354	1,83391	0,00078	-0,20868	1,15771	0,30327	0,14096
0,43		<b>9,5</b>	-0,11928	0,65371	-0,83118	0,90016	0,58927	-0,25994	0,47808	0,33831	0,27697	-2,14159	0,35618	0,61538	0,40039	-0,99238	0,90941
0,348333		<b>4,76</b>	-0,04848	-0,01232	-0,88776	0,34938	0,59286	0,25685	0,21762	-0,03593	0,09486	-1,30981	0,37639	0,52831	0,11997	-0,83224	0,21123
0,428205		<b>2</b>	0,2602	0,38336	-0,66382	0,56924	0,31925	-0,30382	0,29968	-0,19869	-0,13097	-1,50506	-0,04549	0,44826	-0,09007	-0,80256	0,78366
0,414634		<b>0,42</b>	0,39186	-0,43249	-0,75826	0,31432	0,91628	0,08081	-0,016	-0,05705	-0,17097	-0,55008	-0,08967	-0,08654	0,2994	-0,5511	1,88994
0,262		<b>0,074</b>	-0,03994	-0,03357	-0,48785	0,33803	-0,12499	-0,2315	0,07775	-0,01028	0,35086	-1,22674	0,54399	0,43067	0,30751	-0,29712	1,21366
0,181818		<b>σ3</b>	0,10804	0,62343	-0,68861	-0,53277	0,32633	0,47072	-0,13839	0,08061	0,32121	0,87022	0,08174	0,13133	-0,58963	-0,87196	0,57764
0,15		<b>σd</b>	0,19069	2,89682	-0,42527	0,67759	0,38035	-0,0156	0,32482	-0,23962	0,15444	-1,18875	0,17665	0,28826	-0,16047	-0,02195	-0,39917
0,15		<b>Class</b>	0,14571	-0,91668	-0,23552	-0,07819	0,38049	0,31594	-0,38208	0,13933	-0,09783	0,74234	0,27482	0,30885	-0,28778	-0,23479	0,19372
0,145597		<b>bk</b>	0,20177	0,20375	0,4509	0,43236	-0,16485	-0,44932	0,10819	-0,2281	0,1061	-0,3466	-0,0955	-0,24453	0,52141	0,12226	-0,69506
		v1	-0,9717	5,086066	2,219345	0,102278	-2,21786	-1,51699	1,599918	-0,59859	0,891306	-2,63146	-1,1618	-2,28947	2,037991	2,525358	-3,62795
		y1	0,274542	0,993856	0,901973	0,525547	0,098158	0,179905	0,832007	0,354666	0,70916	0,067141	0,238341	0,091999	0,884728	0,925901	0,025883

y1	2° CAMADA INTERMEDIÁRIA								
		1	2	3	4	5	6	7	
0,274541834	CAMADA DE ENTRADA	1	-0,08725	0,36237	0,02959	-0,12303	0,05263	-0,05696	-0,04974
0,993855691		2	-0,72733	-0,95774	-0,63791	-1,28106	-1,19111	-0,85945	0,36664
0,90197334		3	-0,36513	-0,78371	-0,22096	-1,2817	-1,23037	-1,25818	0,44577
0,525547249		4	-0,35478	-0,24949	-0,10429	0,06199	-0,02576	-0,2057	0,05357
0,098158331		5	0,58645	0,81258	-0,02383	0,42161	0,73062	0,73291	-0,30572
0,179905118		6	-0,04509	-0,00351	0,15288	0,29217	0,06363	0,10613	0,26038
0,832006945		7	0,03707	-0,16654	-0,17839	0,44174	0,03733	0,29577	-0,28814
0,354666259		8	0,07248	0,08728	-0,14713	0,04637	0,10047	-0,0082	0,11708
0,709159669		9	-0,24814	0,23526	-0,13096	0,129	0,19288	0,12968	0,06431
0,067141051		10	1,13111	1,41238	0,66811	1,51019	1,64998	1,24151	0,07294
0,23834086		11	0,06125	0,3319	-0,1391	0,5427	0,434	0,34209	-0,24319
0,091999225		12	0,19957	0,44507	-0,15577	0,73572	0,69682	0,687	0,16286
0,88472849		13	0,06374	-0,12625	-0,35345	-0,46749	-0,43817	-0,10994	0,01491
0,925900518		14	-0,3452	-0,78558	-0,33121	-0,8009	-1,15419	-0,61731	0,10705
0,025882893		15	-0,49806	-1,19793	-0,64425	-1,70542	-1,24859	-1,39647	-0,00948
		16	-0,2178	-0,21398	0,1317	0,21008	0,25824	-0,16404	0,11313
	v2		-0,2178	-0,21398	0,1317	0,21008	0,25824	-0,16404	0,11313
	y2		0,445764	0,446708	0,532877	0,552328	0,564204	0,459082	0,528252

		3° CAMADA INTERMEDIÁRIA					
			1	2	3	4	5
y2	CAMADA DE ENTRADA	1	-0,45802	-0,68459	-0,63783	-0,49445	0,14835
0,445764228		2	-0,5372	-1,08008	-1,24111	-1,06438	0,33385
0,446708186		3	-0,3412	-0,09409	-0,23627	-0,48613	0,09831
0,532877492		4	-0,93407	-0,97015	-1,62438	-1,49928	0,49821
0,552327691		5	-0,53348	-1,39632	-1,65104	-1,40005	0,37049
0,564203596		6	-0,81627	-0,80092	-1,46538	-1,16168	-0,04908
0,459081715		7	-0,07857	0,24713	0,90825	0,60684	-0,12713
0,528252374		8	0,11193	0,83154	1,44203	1,21482	-0,14455
	v3		0,11193	0,83154	1,44203	1,21482	-0,14455
	y3		0,527953	0,69668	0,808769	0,771151	0,463925

		CAMADA DE SAÍDA
y3	1	-1,23881
0,5	2	-2,20643
0,5	3	-3,35788
0,5	4	-2,86263
0,5	5	1,10565
0,5	6	2,69661
	vk	2,69661
<b>Valor Final de Saída</b>	<b>yk</b>	<b>0,936826311</b>

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo M3 de previsão de MR.

1° CAMADA INTERMEDIÁRIA																
X		1	2	3	4	5	6	7	8	9	10	11	12	13	14	
	CAMADA DE ENTRADA	<b>OT (%)</b>	-3,00045	1,98624	1,18913	0,10141	1,51069	0,32793	0,94975	-0,49408	0,6587	-4,30489	-6,94128	3,40832	-6,25446	-0,39742
0,357		<b>DEN (g/cm3)</b>	1,49786	4,21632	2,8264	1,00368	0,91719	0,05433	-1,0413	1,02981	8,5755	3,04512	-7,25801	-1,48257	-6,57009	0,16369
0,811		<b>25,4</b>	-0,39968	-0,49804	-3,88264	-1,78909	-5,6893	-0,1254	0,04556	-0,51724	-3,30155	-1,42562	-0,34457	1,52948	-0,57597	-0,69877
0,43		<b>9,5</b>	2,77322	-2,50367	1,47082	-0,5172	6,93382	0,21768	1,00389	0,46801	-0,29465	-1,61888	0,9016	0,20071	3,36151	-1,74587
0,348		<b>4,76</b>	-2,99587	-3,43027	-1,08438	-1,05396	-0,29073	-0,26438	-0,77631	-1,11842	0,8064	0,81372	1,69627	-1,4121	1,66993	3,47993
0,428		<b>2</b>	-2,99651	-1,32941	-0,86844	-0,86115	-1,59224	-0,85177	-1,10423	-1,22987	0,13631	-0,61498	-2,88585	-3,17827	4,43632	0,11247
0,414		<b>0,42</b>	3,32045	-2,51395	1,0882	0,40562	1,22403	0,78319	1,486	0,04368	-1,28917	-1,65565	5,97742	-0,85257	1,50192	-4,93405
0,262		<b>0,074</b>	3,20212	-1,16594	-1,70279	-0,61924	2,89413	0,07954	0,06715	0,38726	-0,47213	-7,80623	-6,86273	-0,27751	-6,29094	1,17634
0,181		<b><math>\sigma_3</math></b>	0,02903	0,19035	-0,2993	1,25378	-0,2202	-0,33907	1,25936	0,35783	0,00132	0,07171	-0,19664	-0,02963	-0,12993	0,90891
0,15		<b><math>\sigma_d</math></b>	-0,07594	-0,22001	-1,29926	-0,05832	-0,2066	-0,44219	4,09345	0,78252	-1,99002	-0,79365	0,5947	1,15597	-0,0307	-13,1518
0,185		<b>bk</b>	-1,92826	-0,25729	0,8352	0,15398	1,60643	0,15388	0,4998	0,08566	-2,89164	3,33562	6,29309	1,11984	1,60884	0,49407
		v1	6,388809	-15,9011	19,09755	-0,45018	44,14125	5,490564	13,5039	5,437403	-11,2326	45,27542	83,15606	27,99539	48,31431	-5,87359
	y1	0,998323	1,24E-07	1	0,389318	1	0,995891	0,999999	0,995668	1,32E-05	1	1	1	1	0,002805	

		2° CAMADA DE ENTRADA					
			1	2	3	4	5
y1	CAMADA DE ENTRADA	1	0,71365	0,11271	3,19415	-3,73077	0,62433
0,998322563		2	-0,11163	-0,40418	-4,55964	3,61005	-0,40259
1,24E-07		3	0,73017	0,38061	2,79567	-3,23351	0,10012
0,999999995		4	0,28412	0,48636	1,66045	0,49044	0,65402
0,389318118		5	-2,00647	-1,60143	-5,04735	2,39769	-1,99329
1		6	-0,05431	-0,36314	0,68181	-0,64213	-0,21336
0,995891434		7	1,12668	0,70634	2,59761	0,15438	0,95191
0,999998634		8	0,72835	0,55097	0,87375	0,34986	0,78358
0,995668082		9	0,9863	0,35838	-2,3182	2,47922	1,16572
1,32E-05		10	0,21517	-0,23634	4,02319	-2,01019	-0,32768
1		11	-1,91981	-1,07651	-3,60579	1,87086	-1,33329
1		12	0,81628	0,49387	2,81854	-1,35369	0,61029
1		13	0,61097	0,28773	3,65052	-4,01994	-0,062
1		14	1,51298	0,89864	6,32967	-2,46795	0,60775
0,002804867		15	-0,68654	-0,11126	-1,05888	0,59204	-0,65477
	v2		-0,68654	-0,11126	-1,05888	0,59204	-0,65477
	y2		0,334803	0,472214	0,257524	0,643833	0,341915

3° CAMADA DE ENTRADA					
y2	CAMADA DE ENTRADA	1	1	2	3
			0,334803209	-2,01793	-1,31276
0,472213658		2	-0,88423	-1,0833	-0,90847
0,257523546		3	-10,6881	0,24978	-1,26555
0,643833079		4	8,9084	0,09827	-0,15258
0,341915435		5	-0,99913	-1,80466	-1,38346
		6	2,83617	0,89077	-0,5642
	v3	2,83617	0,89077	-0,5642	
	y3	0,944599	0,709049	0,362576	

		CAMADA DE SAÍDA
y3	1	-7,24326
0,944599374	2	-2,19183
0,709049048	3	-1,31139
0,362576219	4	6,60006
	vk	6,60006
<b>Valor Final da Saída</b>	<b>yk</b>	<b>0,998641561</b>

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo M4 de previsão de MR.

1ª CAMADA INTERMEDIÁRIA																	
X		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
	CAMADA DE ENTRADA	<b>OT (%)</b>	0,56138	0,09207	0,24617	-5,02372	-0,2378	1,05734	-3,87776	1,02964	-2,826	-1,71115	-0,35665	2,0476	-2,51271	-1,88146	-3,93713
0,357		<b>DEN (g/cm3)</b>	-0,59044	-0,4575	0,17855	2,14126	2,90999	10,23178	5,19213	-1,22862	4,88336	-6,99171	0,2082	-5,18326	1,45463	-0,51287	-4,70161
0,811		<b>9,5</b>	-0,58746	2,28033	-8,04364	0,49973	-3,62671	-3,96245	-3,83729	1,51628	0,07371	0,4596	-1,10708	0,46167	-1,51886	-1,5927	-5,58777
0,348		<b>2</b>	-0,60101	-2,11221	-0,24981	-2,55472	-5,17656	-2,695	-5,83541	0,72536	-2,72205	3,03614	-0,77752	-0,68127	0,50535	1,58177	-3,62767
0,414		<b>0,074</b>	-0,60596	2,53472	-0,80659	1,45754	2,17596	1,68719	-7,41097	3,16944	9,89718	6,92547	0,89388	-1,99084	1,59692	-3,53824	-8,46229
0,181		<b>σ3</b>	-0,83114	0,92272	0,0461	0,0154	0,55892	0,12579	0,51304	-0,48849	0,12442	0,12195	0,60633	-0,4431	2,13854	0,24036	-0,12325
0,439		<b>σd</b>	-3,14293	-0,29533	1,73772	0,32443	0,24391	0,04348	0,07135	-1,80206	0,09779	0,60187	-2,76692	-1,10473	-13,3023	-4,93714	0,42987
0,357		<b>bk</b>	1,09636	0,02795	4,78458	-0,59438	-3,12215	-1,84666	7,0339	-0,65379	-4,71974	-1,25891	-0,10339	2,82319	-0,36277	1,70027	12,87513
		v1	1,09636	0,02795	4,78458	-0,59438	-3,12215	-1,84666	7,0339	-0,65379	-4,71974	-1,25891	-0,10339	2,82319	-0,36277	1,70027	12,87513
		y1	0,749577	0,506987	0,991712	0,355631	0,042203	0,136266	0,999119	0,342136	0,008839	0,221162	0,474176	0,943916	0,410289	0,84557	0,999997

Yk1	2° CAMADA INTERMEDIÁRIA						
		1	2	3	4	5	
0,749577458	CAMADA DE ENTRADA	1	1,94369	0,07457	2,40168	0,60623	0,54076
0,506987045		2	1,91957	1,16073	-0,59185	0,23611	1,34424
0,991711638		3	1,80095	2,12594	1,13438	0,5551	2,89388
0,355630511		4	3,95663	0,25999	0,20556	0,43989	2,22163
0,04220278		5	4,94647	-0,35341	1,02173	2,04447	1,79989
0,136265528		6	-1,55781	-2,07952	-3,74382	-4,51343	-3,03731
0,999119289		7	0,47912	1,09826	7,69442	0,10289	-2,4577
0,342135978		8	0,62143	2,69334	0,27505	-0,22835	1,51096
0,008838678		9	3,11946	-4,33335	-2,44378	-5,53296	-2,25619
0,221161587		10	-4,59094	-2,83877	-3,42683	-1,13116	1,74069
0,4741755		11	1,8429	0,89878	0,45518	0,44834	-0,48861
0,943916179		12	0,99662	-0,74091	0,40178	0,51545	-4,42953
0,410289193		13	1,65016	6,20369	0,16409	2,06313	-0,53372
0,845569995		14	-3,40546	-1,65542	0,97308	-1,71027	-1,68188
0,999997439		15	-7,21581	-0,43641	2,05952	-2,93428	2,50761
		16	-0,50784	-2,38043	-2,07048	0,14406	0,11644
	vk2	-3,0262	-1,44586	4,839238	-7,69872	0,044201	
	yk2	0,046256	0,19064	0,992149	0,000453	0,511049	

		3° CAMADA DE ENTRADA					
yk2	CAMADA DE ENTRADA		1	2	3	4	5
		0,046256032	1	-2,37912	-3,01858	-2,07615	-4,94772
0,190640239		2	-2,05502	-1,35633	-1,70366	-4,39962	-1,02859
0,992149043		3	-1,80795	-0,15585	0,03972	-3,72205	-0,72523
0,000453204		4	-2,36917	-1,66722	-1,536	-3,76593	-1,60597
0,511048503		5	-2,95103	-2,20769	-2,29656	-1,68403	-2,46875
		6	3,81506	1,29981	0,65264	6,53715	1,24392
	vk3	0,010293	-0,38201	-0,90312	0,914387	-1,01524	
	yk3	0,502573	0,405643	0,288409	0,713897	0,265955	

		CAMADA DE SAÍDA
yk3	1	-4,47285
0,502573178	2	-3,41657
0,405642853	3	-2,86255
0,288409323	4	-7,39483
0,713897123	5	-2,88424
0,265955432	6	9,77108
	vk4	9,77108
<b>Valor Final de Saída</b>	<b>yk4</b>	<b>0,999942925</b>

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo M5 de previsão de MR.

		1ª CAMADA INTERMEDIÁRIA															
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
X	CAMADA DE ENTRADA	<b>OT (%)</b>	3,7611	-0,70184	-0,5940	-0,607720	-0,116450	-0,5639900	-4,0995800	-1,3552800	7,0712000	-4,0060100	1,6663800	0,3384200	2,8435500	-3,6829500	12,0105300
0,357813		<b>DEN (g/cm3)</b>	-3,7644	4,62145	1,6056	2,138910	1,075650	0,6169100	1,5594400	5,3256900	-4,4758600	3,8734300	-0,2656200	-0,2091300	-0,2392100	-0,8111600	-3,9371200
0,811111		<b>CBR (%)</b>	16,1136	-4,77507	13,62588	-0,020180	2,136270	0,0704500	2,3259700	-5,1394300	-6,7237400	0,7759300	-0,6655200	0,4390500	-4,3994700	2,2078900	-1,8325100
0,589564		<b>EXP (%)</b>	-5,3240	-1,96674	-0,24597	4,073470	-4,595490	0,1728000	0,4220400	-2,6406500	-8,9970100	-2,6710700	-3,7690700	-3,5835800	8,3635000	1,0799100	-1,1563900
0,15		<b>Class</b>	-14,6658	-0,81152	0,25792	-0,286570	2,0567000	0,5046500	-2,4644300	3,3897500	3,1778400	-0,5019700	-0,6261800	1,6117100	0,3639400	-0,0426400	3,0733700
0,15		<b><math>\sigma_3</math></b>	-0,31246	0,3372	0,064	-1,287640	-0,2018000	-1,0354200	-0,1138700	0,7963300	-0,1310400	1,2145800	0,0415200	0,3135800	0,1000400	2,0535600	0,1450400
0,15		<b><math>\sigma_d</math></b>	0,6949	2,2811	0,359590	-2,497970	2,6965300	11,5784100	-0,4407300	0,2663800	-0,4146800	-1,3049900	0,8239300	-4,2217800	2,4383200	0,6661800	-0,1844400
0,185806		<b>bk</b>	3,22677	-1,06596	-3,277600	0,175060	-0,2784100	-0,0891600	-1,5361900	-2,6511000	1,7437600	-1,0224200	-0,5712000	-0,6062100	0,3801700	-1,2579300	-5,5202500
		vk1	8,103009	-0,32612	5,92372	1,591359	1,90180515	2,34859292	-0,7722118	-1,5650255	-4,2901553	0,6071789	-1,0827313	-1,42907248	0,38700641	-1,3445785	-5,2215237
		yk1	0,999697	0,419186	0,997332	0,830807	0,8700957	0,91282232	0,3160008	0,1729267	0,01351757	0,647297	0,25298949	0,193243244	0,59556185	0,20675813	0,0053701

		2° CAMADA INTERMEDIÁRIA											
		1	2	3	4	5	6	7	8	9	10	11	
yk1	CAMADA DE ENTRADA	1	1,3656400	5,2951500	-1,9799000	-0,4071000	-2,0626600	-1,43417	-0,363690	-2,63705	-0,99883	-1,854230	8,591280
0,999697464		2	-0,5814200	-1,5860600	-0,5561700	-0,7163100	1,5825700	0,61899	-1,01084	-1,32429	-0,68873	-0,564150	-4,609790
0,419185901		3	-2,3639500	-7,2618800	1,4699800	6,2142600	3,0764100	0,686330	0,3949	2,27065	-1,01307	-1,135530	-0,318260
0,997331908		4	1,3376300	0,5737100	-1,8628800	-0,4516200	-1,41573	-2,37916	-0,07825	1,95126	-2,16857	1,517490	-2,080090
0,830807158		5	0,5488500	2,8228700	-2,2066800	-0,9179300	-0,46883	0,61009	-0,69072	-0,72001	-0,37389	-0,295040	0,064940
0,870095696		6	-1,9606600	-2,1012400	3,9776400	-0,3881300	2,63639	0,11105	-0,53263	2,12175	-0,240610	1,273570	-3,079520
0,912822321		7	1,8416400	1,7759800	-1,1753800	-0,7998200	-2,17012	0,31309	-0,94652	0,36483	-1,002520	2,330350	-1,040570
0,316000844		8	1,2006200	-1,7250800	-2,7206000	-5,3039900	-0,92260	-0,90996	-1,41971	-0,99672	-0,324440	0,995440	-0,491330
0,172926703		9	-1,4077200	-1,1495300	3,1469500	2,3861800	1,98943	3,67877	1,40519	-0,15168	3,796530	-0,262070	-5,889140
0,013517568		10	1,6411800	2,0644800	-1,6562900	-0,2734800	-1,94557	2,95512	-0,50203	-2,15453	0,321720	-0,242320	-2,490330
0,647297003		11	-1,0321000	0,3667700	0,4981300	0,1308200	1,02696	1,01518	0,538550	-0,25724	1,781190	-2,065390	-2,611350
0,252989486		12	-0,5390700	0,3590800	-1,3490000	0,2169300	0,93094	0,719850	1,65024	0,117000	2,504980	-2,189330	-3,162080
0,193243244		13	0,1539800	2,1725800	-1,5737700	-1,4164500	-0,68765	-1,54614	-0,63533	-2,473880	-0,230370	-1,138630	3,320270
0,595561845		14	-0,1443900	0,3980200	0,0150500	0,5988300	-0,22582	0,054710	-0,631930	1,195990	-1,333680	2,931140	0,626060
0,206758128		15	-0,0202600	9,29907	0,5506700	-1,8643800	0,47014	-3,90174	-1,19197	-1,92631	-0,652110	-1,551340	1,305560
0,005370102		16	-0,2834000	-0,1751900	-0,4408300	1,1200000	-0,03097	0,65984	0,00893	0,09215	0,228240	0,110650	-1,806240
	vk2	2,7072065	9,66439342	-6,02046749	1,99103114	-4,11131389	-3,7531268	-1,15592753	-4,800425	-4,1526438	-4,160727	16,027555	
	yk2	0,9374505	0,9999365	0,00242265	0,87985219	0,01612205	0,02290728	0,239408062	0,00815913	0,0154794	0,0153567	0,9999999	

		3° CAMADA INTERMEDIÁRIA									
		1	2	3	4	5	6	7	8	9	
yk2	CAMADA DE ENTRADA	1	0,651780	-0,353460	-0,217980	-0,6851900	0,2585300	1,3544500	0,7252200	1,9728200	3,1232000
0,937450545		2	4,397450	0,854900	0,833690	-3,4104600	1,1213000	2,0664800	5,6055400	4,3649500	4,2492100
0,999936499		3	-0,995410	-0,567680	-0,780130	3,5068900	-0,8357700	-0,4584800	-1,7507400	-1,3962800	-3,3154000
0,002422651		4	-2,815570	-1,092090	-1,2307100	3,1101700	-1,6061400	0,9916300	-3,6799500	-3,7551700	-3,1773000
0,879852185		5	-1,210180	-0,394500	-0,6170600	0,4457600	-0,9824100	-0,3029300	-0,8350300	-2,2205100	-4,2201400
0,016122051		6	-0,829380	-0,720750	-0,7390600	-1,7249300	-1,0106500	-0,8461000	-4,1668600	-0,1831100	-1,3509200
0,02290728		7	-0,842550	-0,407600	-0,6354500	-1,0613500	-0,7377200	-1,0468800	-1,8872100	-1,1227300	-1,1008000
0,239408062		8	0,358730	-0,672280	-0,4437700	3,3722900	-0,4484500	-0,1384700	-3,0068000	-0,2912200	-0,0146200
0,008159131		9	-0,339710	-0,311040	-0,5392500	-2,3448400	-0,4241800	-2,1759600	-3,4389800	-0,1851500	-2,3402300
0,015479414		10	-0,079860	-0,021430	-0,5176000	3,5355400	-0,4290600	2,1868100	2,0914000	0,7986500	2,2397200
0,015356705		11	-0,269080	0,180490	0,2209400	0,0480800	-0,1117900	1,5310100	10,1580100	-1,1284000	-1,4607100
0,999999891		12	0,008180	-0,778630	-0,7713700	-0,8385100	-0,4908500	0,1711600	0,6861100	0,6455600	-0,1193000
	vk3	0,00818	-0,77863	-0,77137	-0,83851	-0,49085	0,17116	0,68611	0,64556	-0,1193	
	yk3	0,502045	0,31461523	0,31618282	0,30184869	0,37969335	0,54268584	0,665101019	0,65600922	0,4702103	

		4° CAMADA INTERMEDIÁRIA					
			1	2	3	4	5
yk3	CAMADA DE ENTRADA	1	-0,9387800	-1,3675600	2,3907100	-1,0075000	-0,0403800
0,502044989		2	-0,0228900	0,0270200	0,2734500	-0,0720400	-0,3553900
0,314615228		3	-0,3640600	-0,1713300	0,0296700	-0,3321800	-0,2671400
0,316182822		4	5,8838900	0,1065000	6,3417300	0,1006200	1,0897100
0,301848688		5	-0,5611800	-0,4162500	0,6593800	-0,2612400	-0,0821800
0,37969335		6	3,1567100	0,3011500	3,2361800	0,2647800	0,0868100
0,542685841		7	-8,2829100	0,7311900	0,3556800	-0,5127300	-0,6580500
0,665101019		8	-3,0005300	-0,3269900	2,7724700	-0,4892900	-0,5685300
0,656009222		9	-5,8581800	-0,0941000	0,3544000	-0,0698500	-0,2334400
0,470210323		10	4,3896400	1,6955800	-2,5154600	0,9175300	-0,4638400
		vk4	2,4875313	1,68688369	7,0383948	0,12736805	-0,55698526
		yk4	0,9232631	0,8438139	0,99912324	0,53179904	0,3642453

		CAMADA DE SAÍDA
yk4	1	-5,2341900
0,923263079	2	2,8172700
0,843813895	3	-4,9764100
0,999123235	4	1,1157200
0,531799036	5	-0,6600300
0,364245298	6	5,8293500
	vk5	-1,245053671
<b>Valor Final de Saída</b>	<b>yk5</b>	<b>0,223557546</b>

Valores dos pesos sinápticos e dos limiares (bk) entre a camada de entrada e a primeira camada intermediária do modelo M6 de previsão de MR.

		1° CAMADA INTERMEDIÁRIA															
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
X	CAMADA DE ENTRADA	<b>OT (%)</b>	-0,44233	-0,15154	-0,10113	-0,06014	0,17237	-3,98864	-2,08628	0,57138	-0,48228	0,06649	1,26806	-0,50578	-0,20158	0,04143	-0,1371
0,15		<b>DEN (g/cm3)</b>	1,37502	-0,09895	0,1704	-0,27137	-0,26079	1,03206	1,45549	0,39166	0,31266	0,53493	2,13458	0,58621	0,04986	-0,34549	-0,10462
0,15		<b>CBR (%)</b>	-1,27171	0,09337	0,11841	0,21254	-0,06863	-2,49954	0,00111	0,36972	0,15869	0,76282	0,33678	0,38246	0,07106	0,26402	0,87964
0,15		<b>EXP (%)</b>	-1,00863	-0,24625	0,23894	0,21142	0,11983	0,06548	0,22129	-0,09705	0,16852	0,18481	0,07814	0,40251	0,16075	-0,47663	0,03523
0,15		<b>25,4</b>	2,2018	-0,52929	-0,31319	-0,11714	-0,38279	1,50548	-1,95992	-0,44062	-0,30913	-0,0337	-0,13296	-0,12131	-0,49782	0,07503	0,95358
0,15		<b>9,5</b>	-1,37128	-0,37353	-0,22683	-0,28867	-0,83095	0,74668	0,82684	-0,73462	0,61715	0,43351	-1,65692	0,73756	-0,09615	-0,5424	0,17428
0,15		<b>4,76</b>	-2,24464	-0,06852	0,11661	-0,10976	-0,46724	0,32512	-0,248	0,14721	-0,30034	0,47282	0,31894	-0,07952	-0,10686	-0,06729	-0,18017
0,15		<b>2</b>	-1,40229	-0,20309	-0,24611	-0,09032	-0,43334	-1,16106	-0,13495	-0,56596	-0,1077	0,45037	-0,81371	0,07848	-0,41694	-0,23388	-0,1943
0,15		<b>0,42</b>	0,49357	-0,06524	0,02306	-0,10713	-0,85384	2,23534	-0,22564	-0,95982	0,05188	0,69233	-1,61514	-0,04872	-0,24749	-0,04963	0,25719
0,15		<b>0,074</b>	0,34461	-0,08707	-0,05836	-0,09455	0,38289	-2,17967	-1,3877	0,74456	-0,07837	-0,55632	2,25583	-0,43921	-0,23956	0,12628	0,01534
0,15		<b>σ3</b>	-0,03767	0,08353	-0,1331	-0,12284	0,02171	0,02047	0,52267	-0,91415	0,38164	-0,3248	0,33814	1,1251	-0,01435	0,21954	0,57082
0,15		<b>σd</b>	0,07839	-0,21575	-0,23651	-0,25837	0,08471	-0,14914	0,08786	-0,40101	-0,06767	-0,31827	-0,2342	-0,10446	-0,08508	-0,02373	3,53663
0,15		<b>Class</b>	2,53768	0,34041	-0,14929	0,00432	0,18665	0,88309	-0,07624	0,28187	-0,30775	-0,44412	0,70967	-0,81936	0,16268	-0,11023	0,41259
0,15		<b>bk</b>	-0,44922	0,11758	-0,29745	0,15192	0,13918	-0,58514	-0,24773	-0,12381	-0,2624	0,42678	-0,53987	0,00926	0,1785	-0,29651	-0,15411
			vk1	-6,12609	-0,13946	-1,03639	0,461818	-0,13476	-2,79435	-3,39886	-2,6504	-0,35025	-0,57225	-6,64368	0,144827	-0,31403	0,097257
		yk1	0,00218	0,465192	0,261846	0,613445	0,466362	0,057631	0,032331	0,065964	0,413323	0,360718	0,001301	0,536144	0,42213	0,524295	0,690941

		2° CAMADA INTERMEDIÁRIA														
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	
yk1	CAMADA DE ENTRADA	1	-0,26203	-1,58023	-0,01167	-0,30025	-1,12685	-0,54539	-0,41647	0,59485	1,0372	-1,21444	0,68659	0,94168	-0,56131	1,53587
0,0021803		2	-0,25008	0,28446	0,24747	0,16457	0,26147	0,28766	-0,03905	-0,12275	-0,27009	-0,19352	-0,07232	0,07452	-0,05708	0,22893
0,4651921		3	0,02528	0,00135	0,1905	0,22523	0,12065	-0,08005	0,01187	-0,12092	0,09727	0,21021	0,16682	0,20294	0,29989	0,2393
0,2618463		4	-0,11078	-0,23415	-0,16514	0,01011	-0,08791	0,00498	-0,25019	-0,19853	-0,11706	0,138	-0,08094	0,07771	0,0223	-0,15297
0,6134454		5	-0,02779	0,34204	0,08767	-0,06178	0,3877	-0,1107	0,24816	0,0409	-0,37598	0,3248	-0,117	-0,58461	0,39228	-0,54017
0,4663619		6	0,02585	1,59471	0,09797	0,25761	1,108	0,33801	-0,01959	-0,58025	-1,04059	1,20991	-0,92087	-0,38504	0,82714	-1,43168
0,0576305		7	-0,29381	-1,41647	0,40936	0,10036	-0,88754	-0,35745	-0,10569	0,27944	0,95132	-0,54991	0,80411	0,76747	-0,34978	1,01979
0,032331		8	0,13884	0,54078	-0,26075	-0,2128	0,75021	0,29868	0,34087	-0,38722	-0,60232	0,44358	-0,60859	-0,25025	0,14473	-0,2894
0,0659645		9	0,26458	-0,15584	0,27564	0,01691	-0,54835	-0,11058	0,10478	0,05663	0,25324	-0,08177	0,20078	0,17713	-0,41855	0,44276
0,4133228		10	-0,0681	-0,77547	0,15718	-0,21578	-0,55053	-0,34781	0,08485	0,36185	0,48231	-0,72463	0,3836	0,22489	-0,44499	0,4348
0,3607178		11	0,35678	1,47451	-0,51675	0,29282	1,18778	0,41315	0,07763	-0,55256	-0,81497	1,04402	-0,89196	-0,89082	0,6257	-1,29091
0,0013005		12	-0,16047	-0,93168	0,17406	0,09577	-0,39202	0,12323	-0,37273	-0,08236	0,51187	-0,49653	0,32089	0,40513	-0,40164	0,39034
0,5361436		13	-0,16537	-0,22804	-0,03202	0,26344	0,09655	0,32869	-0,22612	-0,00288	-0,16784	-0,12756	0,13635	-0,28638	0,2709	0,16245
0,4221302		14	0,02245	0,25917	0,07166	0,23557	0,13064	-0,12783	-0,14418	0,02175	0,14924	0,25267	-0,10012	-0,26883	0,27961	-0,22472
0,5242952		15	-0,12038	1,05891	-0,22008	-0,00898	0,74564	0,11081	0,03584	-0,37426	-0,83701	0,7133	-0,86684	-0,41735	0,23771	-1,38264
0,6909412		16	-0,25186	0,01642	-0,24309	-0,05529	-0,49865	-0,21028	0,10604	-0,04805	0,08362	-0,05015	0,17975	-0,16622	-0,18738	0,23351
	vk2	-0,25186	0,01642	-0,24309	-0,05529	-0,49865	-0,21028	0,10604	-0,04805	0,08362	-0,05015	0,17975	-0,16622	-0,18738	0,23351	
	yk2	0,437366	0,504105	0,439525	0,486181	0,377858	0,447623	0,526485	0,48799	0,520893	0,487465	0,544817	0,45854	0,453292	0,558114	

		3° CAMADA INTERMEDIÁRIA													
		1	2	3	4	5	6	7	8	9	10	11	12	13	
yk2	CAMADA DE ENTRADA	1	-0,14605	0,19451	-0,08345	0,11254	-0,02484	0,26124	0,03702	0,23382	0,18759	-0,25617	0,42002	-0,21911	-0,08536
0,4373657		2	1,21824	0,04266	0,12156	1,3095	-1,633	-0,01172	-0,50025	1,6488	0,09261	-0,18041	1,0791	0,02781	-0,61389
0,5041049		3	-0,39201	-0,2037	0,20156	-0,33868	0,45677	0,02533	0,107	-0,10586	-0,08866	-0,11251	0,05526	0,2366	0,28426
0,439525		4	0,00505	0,26017	0,20043	0,10628	-0,13584	-0,2399	0,09305	0,25798	-0,06263	-0,22453	-0,09518	0,1481	0,20634
0,486181		5	0,57558	0,00933	0,37229	0,85832	-1,42141	0,025	-0,62881	1,27871	-0,35585	-0,22386	0,49408	-0,08603	-0,10597
0,377858		6	0,02058	0,23709	-0,12124	0,14346	-0,52315	-0,16932	0,02611	0,48962	-0,20968	-0,20317	0,22095	-0,11374	-0,23557
0,4476229		7	0,29505	0,14688	0,28457	-0,15472	-0,01744	-0,20522	-0,07124	0,15081	-0,23111	-0,29775	0,25663	-0,26867	0,07627
0,5264852		8	-0,2318	-0,11756	-0,3666	-0,60728	0,29176	-0,03551	0,46012	-0,76738	-0,10738	0,21431	-0,39617	0,14695	-0,10758
0,4879898		9	-0,76273	0,22443	0,08426	-0,96227	1,03386	0,11178	0,2274	-1,34102	0,40182	0,54663	-0,559	-0,04839	0,3467
0,5208928		10	0,72226	0,20897	0,00852	0,99463	-0,9459	-0,29898	-0,6481	1,12402	-0,39499	-0,16389	0,6589	-0,20743	-0,31595
0,4874651		11	-0,65313	0,36134	0,00441	-0,82786	1,07854	0,01504	0,5282	-1,07485	0,22665	0,12366	-0,50225	-0,14226	-0,08707
0,5448169		12	-0,5972	0,19309	-0,35415	-0,32685	1,01096	0,03812	0,55842	-0,88805	0,21783	0,31312	-0,62272	0,01935	-0,00364
0,4585404		13	0,57504	-0,14376	0,18638	0,47015	-0,63537	0,13643	-0,39788	0,63061	0,00982	-0,38104	0,12702	-0,36636	-0,05211
0,4532916		14	-1,0116	0,19946	-0,0526	-1,09583	1,63598	0,17146	0,63903	-1,65954	-0,06027	0,35696	-0,86287	0,26566	0,58159
0,5581137		15	-0,01119	0,17278	0,15236	-0,08434	0,24077	0,23466	-0,15742	-0,42805	0,20449	-0,01493	-0,27915	0,15647	-0,10996
	vk3	-0,01119	0,17278	0,15236	-0,08434	0,24077	0,23466	-0,15742	-0,42805	0,20449	-0,01493	-0,27915	0,15647	-0,10996	
	yk3	0,497203	0,543088	0,538016	0,478927	0,559903	0,558397	0,460726	0,394592	0,550945	0,496268	0,430662	0,539038	0,472538	

		4° CAMADA DE ENTRADA											
		1	1	2	3	4	5	6	7	8	9	10	11
yk3	CAMADA DE ENTRADA		-0,7052	-1,1325	0,45882	-0,18511	0,08281	-0,55308	-0,47746	-0,12747	0,24829	0,7964	-1,15687
0,4972025		2	0,07862	0,05259	0,04566	0,18068	0,01472	0,15027	0,3446	-0,03126	0,14374	-0,13016	-0,00889
0,5430879		3	0,04127	-0,03315	0,23889	0,03564	0,20898	-0,26994	-0,24423	-0,19307	0,05473	0,12573	-0,11614
0,5380165		4	-0,87911	-1,09554	0,26411	-0,42911	-0,04274	-1,04839	-0,87524	-0,05343	-0,24688	0,82972	-1,05281
0,4789275		5	1,19368	1,54803	-0,44668	0,47064	0,05523	1,34151	1,30525	0,17486	0,01849	-1,18109	1,60714
0,5599034		6	0,0555	0,1253	-0,12526	-0,16754	0,02531	-0,02156	0,19396	-0,24748	0,1542	0,08279	0,33404
0,5583973		7	0,20839	1,01976	-0,3185	-0,06977	0,13384	0,76342	0,41272	-0,25121	0,13579	-0,7294	0,35581
0,4607261		8	-1,15513	-1,75469	0,44562	-0,53701	0,37262	-1,10251	-1,20448	-0,16269	0,0323	1,16117	-1,68319
0,3945921		9	0,13255	0,18789	-0,03034	-0,24335	0,25346	0,39558	0,14074	-0,029	-0,15671	-0,05407	0,36854
0,5509451		10	0,19409	0,40485	0,12053	0,2859	-0,08625	0,0194	0,39274	0,13697	-0,05635	-0,47977	0,58972
0,4962676		11	-0,25382	-0,89803	0,10173	-0,0679	0,28626	-0,79948	-0,70368	0,23871	-0,08264	0,48467	-1,02065
0,4306622		12	-0,05303	0,31274	0,08148	-0,23958	-0,15788	0,10653	-0,02835	-0,13755	-0,0587	-0,31449	0,28667
0,5390379		13	-0,05853	0,66526	-0,30483	0,15472	0,18983	0,3233	0,04345	0,2166	-0,26249	-0,07784	0,58498
0,4725377		14	0,12573	0,04998	0,05577	-0,13909	0,23174	-0,08483	-0,13594	0,13862	0,01871	0,10746	0,19973
	vk4	-2,0564	-2,86676	1,074971	-1,18691	1,050388	-2,38494	-2,27889	-0,23079	-0,0381	2,200888	-2,72881	
	yk4	0,113408	0,053821	0,745541	0,233813	0,740849	0,084328	0,092886	0,442556	0,490476	0,900329	0,061295	

		5° CAMADA INTERMEDIÁRIA									
		CAMADA DE ENTRADA	1	2	3	4	5	6	7	8	
yk4			1	0,49786	-0,57971	-0,47487	-0,69337	-0,30478	-0,53967	-1,15916	0,46457
0,1134075			2	0,78435	-1,5124	-0,64922	-0,70786	-0,9713	-0,67428	-1,71689	0,36776
0,0538212			3	-0,1945	0,9296	0,06663	0,49095	-0,02185	-0,18655	0,50415	-0,00323
0,745541			4	0,44967	-0,32149	-0,30579	-0,13471	-0,2911	-0,4543	-0,11968	-0,02875
0,2338126			5	0,1467	0,43685	0,04295	-0,27305	0,2517	-0,12336	0,58021	0,07624
0,7408494			6	0,53453	-1,0755	-0,32413	-0,54288	-0,70721	-0,49295	-1,33097	0,2174
0,0843283			7	0,55855	-1,03138	-0,37247	-0,58186	-0,29418	-0,24258	-1,28733	0,32169
0,0928863			8	-0,11169	0,19384	-0,07392	-0,05939	-0,05987	-0,2917	0,05849	0,23814
0,4425565			9	-0,19275	0,03771	-0,17779	0,20876	-0,2588	0,13676	0,24696	0,07309
0,4904755			10	-0,50953	1,40207	0,23755	0,49469	0,49493	0,08669	1,68941	-0,3136
0,9003292			11	0,92624	-1,39999	-0,51873	-0,92495	-0,78081	-0,29337	-1,72572	0,12527
0,0612949		12	0,00233	0,33237	-0,33345	-0,02955	-0,08328	-0,24033	0,76225	0,32706	
	vk5		-0,27916	2,221051	-0,41202	0,350927	0,089344	-0,74057	2,646564	0,361679	
	yk5		0,430659	0,902124	0,398429	0,586842	0,522321	0,32288	0,933799	0,589447	

		CAMADA DE SAÍDA
yk5	1	2,43767
0,4306591	2	-2,36213
0,902124	3	-0,68162
0,3984286	4	-1,21727
0,5868423	5	-1,1172
0,5223212	6	-0,67627
0,3228802	7	-2,90055
0,9337989	8	1,36578
0,5894469	9	2,15072
	vk6	-2,621698989
<b>Valor Final</b>	<b>yk6</b>	<b>0,067754899</b>

QR CODE para acesso a planilha com os pesos e bias de todos os modelos de MR, separados individualmente

