



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

ANA TÁLIA PINTO GUILHERME

**ANÁLISE COMPARATIVA DE MODELOS PARA PREVISÃO E MAPEAMENTO
DE PROPRIEDADES GEOTÉCNICAS DOS SOLOS DA MICRORREGIÃO DE
MOSSORÓ-RN**

**FORTALEZA
2016**

ANA TÁLIA PINTO GUILHERME

ANÁLISE COMPARATIVA DE MODELOS PARA PREVISÃO E MAPEAMENTO DE
PROPRIEDADES GEOTÉCNICAS DOS SOLOS DA MICRORREGIÃO DE MOSSORÓ-
RN

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Transportes.

Orientador: Prof. Carlos Augusto Uchôa da Silva, D.Eng

Coorientadora: Prof^ª.Suelly Helena de Araújo Barroso, D. Eng

FORTALEZA

2016

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

G974a Guilherme, Ana Tália Pinto.
Análise comparativa de modelos para previsão e mapeamento de propriedades geotécnicas dos solos da microrregião de Mossoró-RN / Ana Tália Pinto Guilherme. – 2016.
139 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2016.

Orientação: Prof. Dr. Carlos Augusto Uchôa da Silva.

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

1. Mapeamento geotécnico. 2. Modelagem. 3. Redes Neurais. 4. Estatística. I. Título.

CDD 388

ANA TÁLIA PINTO GUILHERME

ANÁLISE COMPARATIVA DE MODELOS PARA PREVISÃO E MAPEAMENTO DE
PROPRIEDADES GEOTÉCNICAS DOS SOLOS DA MICRORREGIÃO DE MOSSORÓ-
RN

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Transportes.

Orientador: Prof. Carlos Augusto Uchôa da Silva, D.Eng

Coorientadora: Prof^ª.Suelly Helena de Araújo Barroso, D. Eng

Aprovada em: 22/12/2016

BANCA EXAMINADORA

Prof. Dr. Carlos Augusto Uchôa da Silva (Orientador)
Universidade Federal do Ceará (UFC)

Prof^ª. Dr^ª. Suelly Helena de Araújo Barroso (Coorientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Heber Lacerda de Oliveira
Universidade Federal do Ceará (UFC)

Prof^ª. Dr^ª. Kamilla Lima Vasconcelos
Universidade de São Paulo (USP)

A Deus.

Aos meus pais, Eloi e Elizabete.

AGRADECIMENTOS

A Deus, pois foi pela fé que despejo nele que pude concluir essa etapa da minha vida. E por ele me dar forças e está sempre presente na minha vida.

A meus pais, Eloi Guilherme Lopes e Francisca Elizabete Pinto Guilherme, pelo exemplo de pessoas, por todo amor e dedicação que sempre me deram, por todos os momentos que estiveram ao meu lado, me apoiando e não me deixando desistir dos meus sonhos e desejos. Enfim, pelo incentivo primordial para elaboração desse trabalho.

As minhas irmãs, Lays Lorena Pinto Guilherme, Deize Daiane Pinto Guilherme e Ilana Souza Pinto, pelo carinho e atenção, e por estarem sempre comigo nos momentos mais importantes. Agradeço por acreditarem no meu potencial.

A Alex Medeiros pelo apoio, carinho e por acreditar que eu era capaz de realizar esse trabalho.

As minhas amigas, Ada, Michelle e Savana pelo amizade fortalecida durante o período do mestrado.

Aos meus colegas de turma, em especial a Camila Lima, Daianne Diogénes e Saulo Passos.

Ao amigo Júnior Ribeiro, pela amizade, encorajamento e ajuda técnica e científica para realização deste trabalho.

A Wendel Cabral pela ajuda incansável, principalmente na etapa de aquisição dos projetos rodoviários.

A Júnior Cavalcante pelo suporte técnico necessário para conclusão desse trabalho.

A Ícaro Castro, bolsista de IC, que colaborou para composição do bando de dados.

A todos os professores do Departamento de Transporte – UFC pelos conhecimentos transmitidos.

Ao meu orientador, Prof. Dr. Carlos Augusto Uchôa, e minha coorientadora, Prof. Dr. Suelly Barroso, pela paciência na orientação, ensinamentos e incentivo, que foram de fundamental importância para elaboração deste trabalho.

Aos professores Dr, Francisco Heber e Dr. Kamilla Lima por aceitarem participar da banca examinadora.

Ao LAG e ao GETTEMA pela disposição dos softwares.

Ao programa FUNCAP pelo auxílio fornecido.

RESUMO

A ausência de uma ferramenta adequada de auxílio a futuros projetos rodoviário na Microrregião de Mossoró motivou o interesse de propor alternativas para reconhecimento prévio das características geotécnicas dos solos com fins de pavimentação. Esta pesquisa apresenta, aplica e compara duas técnicas de modelagem destinadas à localização de solos e de suas características geotécnicas, usando como área de estudos a Microrregião de Mossoró – RN. Deseja-se que os modelos resultantes possam auxiliar no processo de tomada de decisão em obras de pavimentação, minimizando os custos e o tempo de realização estudos geotécnicos, sobretudo na fase de pré-projeto. No desenvolvimento dos modelos foi usado Geoprocessamento para composição do banco de dados georreferenciado e as Técnicas Estatísticas de Regressão e Redes Neurais Artificiais para a modelagem. Visando-se alcançar os objetivos propostos foram investigados dados secundários como as variáveis biofísicas (Pedologia, Geologia, Vegetação e Geomorfologia), as variáveis geomorfométricas (elevação declividade, aspecto, iluminação, plano de curvatura, perfil de curvatura, contribuição do fluxo e direção e comprimento de drenagem) e a Localização Geográfica (Coordenadas) para explicar os fenômenos modelados. Essas características foram correlacionadas às variáveis geotécnicas estimadas (classificação AASHTO -*American Association of State Highway and Transportation Officials* e CBR - California Bearing Ratio) através das duas técnicas de modelagem. Ao final, obteve-se R^2 de 76% para modelo estatístico e 91% para o modelo neural para estimação do CBR, já para a Classificação AASHTO, os modelos apresentaram níveis de acertos de 42% para o modelo estatístico e 89% para o modelo neural. Apesar da disparidade do nível de confiança nos modelos de predição das classes de solo, os dois modelos indicaram que o solo A-2-4 é predominante na região. Os índices de correlação para a estimação do CBR foram mais próximos, e foi possível ainda observar que mais de 50% dos solos da região estudada apresentam boa capacidade de aplicação em sub-bases sem necessidade estabilização (valores de CBR maiores de 20%). Adicionalmente, as características geotécnicas estimadas por estes modelos possibilitaram a elaboração de Mapas Geotécnicos, estratificados para previsão dos valores de CBR e Classificação AASHTO.

Palavras-Chave: Modelagem, Mapeamento geotécnico, Redes Neurais, Estatística.

ABSTRACT

The absence of an adequate tool to assist future road projects in the Mossoró Microregion has motivated the interest of proposing alternatives for prior recognition of the geotechnical characteristics of the soils for paving purposes. This research presents, applies and compares two modeling techniques for the location of soils and their geotechnical characteristics, using as study area the Microregion of Mossoró - RN. It is hoped that the resulting models can aid in the decision-making process in paving works, minimizing the costs and the time of performing geotechnical studies, especially in the pre-design phase. In the development of the models was used Geoprocessing for the composition of the georeferenced database and the Regression Statistics Techniques and Artificial Neural Networks for the modeling. In order to reach the proposed objectives, secondary data such as biophysical variables (Pedology, Geology, Vegetation and Geomorphology), geomorphometric variables (slope elevation, aspect, illumination, curvature plane, curvature profile, flow contribution and direction and Length of drainage) and the Geographic Location (Coordinates) to explain the modeled phenomena. These characteristics were correlated to the estimated geotechnical variables (AASHTO - American Association of State Highway and Transportation Officials and CBR - California Bearing Ratio) through the two modeling techniques. At the end of the study, 76% R^2 was obtained for statistical model and 91% for the neural model for CBR estimation, and for AASHTO Classification, the models presented correct levels of 42% for the statistical model and 89% for the model neural. Despite the confidence level disparity in the soil class prediction models, the two models indicated that the A-2-4 soil is predominant in the region. The correlation indexes for the CBR estimation were closer, and it was possible to observe that more than 50% of the soils of the studied region present good subbase capacity without stabilization (CBR values greater than 20%). Additionally, the geotechnical characteristics estimated by these models enabled the elaboration of Geotechnical Maps, stratified to predict the values of CBR and AASHTO Classification.

Keywords: Modeling, Geotechnical Mapping, Neural Networks, Statistics.

LISTA DE FIGURAS

Figura 1 - Estudo de TEN CATEN et al. (2009).....	23
Figura 2 - Estudo de RIBEIRO (2013).....	24
Figura 3 - Componentes de Neurônios Biológico.....	26
Figura 4 - Modelo não linear de neurônio artificial.....	27
Figura 5 - Esquema de uma rede de neurônios.....	28
Figura 6 - Representação dos dados no modo vetor e no modo raster.....	37
Figura 7 - Deformações verificadas em ensaios de cargas repetidas.....	42
Figura 8 - Fluxograma do Método Proposto.....	49
Figura 9 - Fluxograma da Modelagem Neural.....	55
Figura 10 - Fluxograma da Modelagem Estatística.....	57
Figura 11 - Delimitação da Microrregião Mossoroense.....	60
Figura 12 - Malha Rodoviária da Microrregião de Mossoró.....	62
Figura 13 - Geomorfologia da Microrregião de Mossoró.....	63
Figura 14 - Geologia da Microrregião de Mossoró.....	64
Figura 15 - Pedologia da Microrregião de Mossoró.....	65
Figura 16 - Vegetação da Microrregião de Mossoró.....	66
Figura 17 - Distribuição espacial da elevação na região de estudo.....	67
Figura 18 - Declividade da Microrregião de Mossoró.....	68
Figura 19 - Aspecto da Microrregião de Mossoró.....	69
Figura 20 - Iluminação da Microrregião de Mossoró.....	69
Figura 21- Tipo de vertentes em relação ao perfil (a) retilínea, (b) convexa e (c) côncava.....	70
Figura 22 - Perfil de Curvatura da Microrregião de Mossoró.....	70
Figura 23 - Plano de Curvatura da Microrregião de Mossoró.....	71
Figura 24- Determinação da direção do fluxo a partir de seus oito vizinhos.....	72
Figura 25 - Direção de fluxo para a Microrregião de Mossoró.....	72
Figura 26 - Acumulação do fluxo da Microrregião de Mossoró.....	73
Figura 27 - Comprimento do fluxo da Microrregião de Mossoró.....	73
Figura 28- Banco de Dados Espaciais.....	74
Figura 29 - Estratificação do CBR.....	75
Figura 30 - Estratificação da Classificação AASHTO.....	76
Figura 31 - Distribuição Espacial dos Pontos Geotécnico na Pedologia da MM.....	77
Figura 32 - Percentuais das Classes Pedológicas da MM.....	77
Figura 33 - Distribuição Espacial dos Pontos Geotécnico na Geologia da MM.....	78
Figura 34 - Percentuais das Classes Geológicas da MM.....	78
Figura 35 - Distribuição Espacial dos Pontos Geotécnico na Vegetação da MM.....	79
Figura 36 - Percentuais das Classes de Vegetação da MM.....	79
Figura 37 - Distribuição Espacial dos Pontos Geotécnico na Vegetação da MM.....	80
Figura 38 - Percentuais das Classes Geomorfológicas da MM.....	80
Figura 39 - Distribuição Espacial dos Pontos Geotécnico na Elevação da MM.....	81
Figura 40 - Distribuição Espacial dos Pontos Geotécnico na Declividade da MM.....	81
Figura 41 - Distribuição Espacial dos Pontos Geotécnico com o Aspecto da MM.....	82

Figura 42 - Distribuição Espacial dos Pontos Geotécnico na Iluminação da MM.....	82
Figura 43 - Distribuição Espacial dos Pontos Geotécnico no Plano de Curvatura da MM.....	83
Figura 44 - Distribuição Espacial dos Pontos Geotécnico no Perfil de Curvatura da MM.....	83
Figura 45 - Distribuição Espacial dos Pontos Geotécnico na Direção de Fluxo da MM.....	84
Figura 46 - Distribuição Espacial dos Pontos Geotécnico no Fluxo A cumulado da MM.....	84
Figura 47 - Distribuição Espacial dos Pontos Geotécnico no Comprimento de Fluxo da MM85	
Figura 48 - Porcentagem de acertos para o modelo estatístico da Classificação AASHTO	91
Figura 49 - Topologia Adotada para o CBR (15:32:1).....	95
Figura 50 - Topologia Adotada para a Classificação AASHTO (15:50:6)	95
Figura 51 - Desempenho da RNA para predição do CBR.....	96
Figura 52 - Desempenho da RNA para predição da Classificação AASHTO	96
Figura 53 - Correlação entre os dados reais e o de saída para o conjunto de teste.....	97
Figura 54 - Porcentagem de acertos para o modelo neural da Classificação AASHTO	98
Figura 55 - Distribuição Espacial da Classificação AASHTO - Modelo Estatístico	101
Figura 56 - Distribuição Espacial da Classificação AASHTO - Modelo Neural	101
Figura 57 - Percentuais das Classes AASHTO - Modelo Estatístico	102
Figura 58 - Percentuais das Classes AASHTO - Modelo Neural.....	102
Figura 59 - Distribuição Espacial dos Materiais Constituintes - Modelo Estatístico.....	103
Figura 60 - Distribuição Espacial dos Materiais Constituintes - Modelo Neural.....	103
Figura 61- Percentuais dos Materiais Constituintes - Modelo Estatístico.....	104
Figura 62 - Percentuais dos Materiais Constituintes - Modelo Neural.....	104
Figura 63 - Comportamento como Subleito – Modelo Estatístico	105
Figura 64 - Comportamento como Subleito – Modelo Neural.....	105
Figura 65 - Percentuais do comportamento como Subleito – Modelo Estatístico.....	106
Figura 66 - Percentuais do comportamento como Subleito – Modelo Neural	106
Figura 67 - Distribuição Espacial do CBR – Modelo Estatístico	107
Figura 68 - Distribuição Espacial do CBR – Modelo Neural.....	107
Figura 69 - Percentuais dos valores de CBR – Modelo Estatístico	108
Figura 70 - Percentuais dos valores de CBR – Modelo Neural.....	108
Figura 71 - Distribuição Espacial do CBR em função da Aplicação – Modelo Estatístico ...	109
Figura 72 - Distribuição Espacial do CBR em função da Aplicação – Modelo Neural	109
Figura 73 - Percentual do CBR em função da Aplicação – Modelo Estatístico.....	110
Figura 74 - Percentual do CBR em função da Aplicação – Modelo Neural	110

LISTA DE TABELAS

Tabela 1 - Estado da Arte do Mapeamento com RLM.....	22
Tabela 2 - Estado da Arte do Mapeamento com RNA's.....	22
Tabela 3 - Classificação dos grupos de Solo segundo a AASHTO.....	40
Tabela 4 - Variáveis Preditoras	43
Tabela 5 - Exemplo de pré-processamento realizado.....	54
Tabela 6 - Correlação entre classes de declive e classes de relevo	67
Tabela 7 - Correlação das Variáveis.....	86
Tabela 8 - Especificação dos Modelos	87
Tabela 9 - Índice de Correlação dos Modelos de CBR	87
Tabela 10 - Teste de Razão de Verossimilhança (Significância das Variáveis)	88
Tabela 11 - Índice de Correlação dos Modelos da AASHTO	89
Tabela 12 - Principais Modelos de RNAs Testados para predição do CBR	93
Tabela 13 - Principais Modelos de RNAs Testados para predição da AASHTO	93
Tabela 14 - Melhor desempenho para cada modelo de predição do CBR	98
Tabela 15 - Melhor desempenho para cada modelo de predição da AASHTO	99

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Contextualização	15
1.2	Problema de Pesquisa	17
1.3	Justificativa	17
1.4	Questões de Pesquisa	17
1.5	Objetivos	18
1.5.1	<i>Objetivo Geral</i>	18
1.5.2	<i>Objetivos específicos</i>	18
1.6	Estrutura da Dissertação	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Considerações Iniciais	20
2.2	Modelagem Geotécnica	20
2.2.1	<i>Estado da Arte</i>	22
2.2.2	<i>Principais Técnicas de Modelagem Geotécnica de solos para pavimentação</i> ..	25
2.2.2.1	<i>Redes Neurais Artificiais</i>	25
2.2.2.1.1	O Neurônio Biológico	25
2.2.2.1.2	O Neurônio Artificial.....	26
2.2.2.1.3	Arquitetura das RNAs	27
2.2.2.1.4	Topologia da Rede.....	28
2.2.2.1.5	Os Modelos Neurais	29
2.2.2.2	<i>Modelagem Estatística</i>	31
2.2.2.2.1	Regressão Linear	31
2.2.2.2.2	Regressão Logística.....	31
2.2.3	<i>Principais vantagens e desvantagens das técnicas de modelagem usadas</i>	33
2.3	Geoprocessamento	35
2.3.1	<i>Sistema de Informações Geográficas</i>	36
2.3.2	<i>Modelos de Representação de Dados Georeferenciados</i>	36
2.3.3	<i>Álgebra de Mapas</i>	37
2.4	Solos	37
2.4.1	<i>Geotecnia dos solos para Pavimentação</i>	38
2.4.1.1	<i>Características Físicas</i>	38
2.4.1.2	<i>Classificação AASHTO</i>	39

2.4.2	<i>Parâmetros de Resistência</i>	41
2.4.2.1	<i>Califórnia Bearing Ratio (CBR)</i>	41
2.4.2.2	<i>Módulo de Resiliência (MR)</i>	42
2.5	Variáveis Preditoras	43
2.6	Considerações Finais	44
3	MATERIAIS E MÉTODOS	45
3.1	Considerações Iniciais	45
3.2	Materiais	45
3.2.1	<i>Arcgis</i>	45
3.2.2	<i>Autodesk Civil 3D</i>	46
3.2.3	<i>Whitebox GAT</i>	46
3.2.4	<i>Microsofl Excel</i>	47
3.2.5	<i>MATLAB</i>	47
3.2.6	<i>SPSS</i>	48
3.3	Método	48
3.3.1	<i>Pesquisa e Aquisição dos Dados</i>	49
3.3.1.1	<i>Base Cartográfica e Infraestrutura viária</i>	50
3.3.1.2	<i>Informações Geotécnicas</i>	50
3.3.1.3	<i>Variáveis Biofísicas</i>	50
3.3.1.4	<i>Variáveis Geomorfológicas</i>	51
3.3.2	<i>Consolidação do Banco de Dados</i>	51
3.3.2.1	<i>Edição das Bases Cartográficas</i>	51
3.3.2.2	<i>Espacialização dos Dados</i>	51
3.3.2.3	<i>Manipulação dos Dados Espaciais em SIG</i>	52
3.3.3	<i>Pré-processamento dos Dados</i>	53
3.3.4	<i>Processamento dos Dados</i>	54
3.3.4.1	<i>Modelagem Neural</i>	54
3.3.4.2	<i>Modelagem com Regressão</i>	56
3.3.5	<i>Análise dos Resultados</i>	57
3.4	Considerações Finais	58
4	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	59
4.1	Considerações Iniciais	59
4.2	Caracterização da Microrregião de Mossoró	59

4.2.1	<i>Localização</i>	59
4.2.2	<i>Condições Econômicas</i>	61
4.2.3	<i>Infraestrutura Rodoviária</i>	61
4.2.4	<i>Características Físicas</i>	62
4.2.5	<i>Características Geomorfométricas</i>	66
4.3	Análise dos dados de CBR e Classificação AASHTO	74
4.4	Modelagem Estatística	85
4.5	Modelagem Neural	91
4.6	Generalização dos Resultados para a Microrregião de Mossoró	99
4.6.1	<i>Modelagem da Classificação AASHTO</i>	100
4.6.2	<i>Modelagem do CBR (California Bearing Ratio)</i>	106
4.7	Considerações Finais	111
5	CONSIDERAÇÕES FINAIS	113
5.1	Considerações Iniciais	113
5.2	Principais Conclusões	114
5.2.1	<i>Quanto aos Métodos Empregados</i>	114
5.2.2	Quanto às incertezas dos modelos gerados	114
5.2.3	<i>Quanto aos Modelos Proposto Para a Classificação AASHTO</i>	115
5.3.4	<i>Quanto aos Modelos de CBR</i>	116
5.3	Recomendações e Sugestões para Trabalhos Futuros	117
	REFERÊNCIAS	119
	ANEXO I - Resultado da Regressão Linear Múltipla (Software SPSS)	125
	ANEXO II - Resultado da Regressão Logística Múltipla (Software SPSS)	131

1 INTRODUÇÃO

1.1 Contextualização

Para o desenvolvimento de bons projetos e obras de engenharia é imprescindível o conhecimento das diversas variáveis físicas provenientes do meio no qual serão executados. Em projetos rodoviários os estudos geotécnicos e topográficos são fundamentais. A implantação desses devem evitar problemas relacionados à busca e caracterização de materiais, com o intuito principal de impedir o retrabalho e os acidentes geotécnicos, bem como reduzir custos e aumentar a qualidade na elaboração e execução desses projetos. (RIBEIRO *et al.*, 2010)

O propósito de um levantamento de solos pode ser considerado de duas maneiras. O primeiro refere-se à possibilidade de prover aos usuários informações acerca dos solos e das condições da paisagem em algum lugar de interesse, e o segundo é a possibilidade de fornecer dados que poderão ser utilizados para tomada de decisões acerca do planejamento e ocupação do uso do solo (YOUNG, 1976 *apud* NANNI, 1995).

A modelagem e a cartografia geotécnicas podem apoiar o desenvolvimento de projetos de infraestrutura de transportes, conferindo-lhes viabilidade ambiental, com menores custos econômicos, na medida em que permitem tanto o mapeamento de áreas ambientalmente protegidas, quanto a estimação de características e/ou atributos dos solos aptos ao uso em pavimentação.

O dimensionamento de pavimentos necessita de informações sobre o comportamento dos solos que serão aplicados em suas diferentes camadas. Na Engenharia Rodoviária é comum a adoção de um sistema de classificação de solos para prever as suas propriedades. A classificação da AASHTO (*American Association of State Highway and Transportation Officials*) tem sido a mais utilizada para esse fim, embora existam outros métodos também consagrados no Brasil, como, por exemplo, a classificação MCT (Miniatura, Compactado, Tropical) idealizado por NOGAMI e VILLIBOR (1995) para identificar o comportamento laterítico dos solos que não consegue ser previsto adequadamente na classificação AASHTO.

Além das características geotécnicas de classificação, as obras viárias necessitam de informações acerca do comportamento mecânico dos materiais. O CBR (*California Bearing*

Ratio) e o MR (Módulo de Resiliência) são os dois parâmetros de resistência mais usados no Brasil para dimensionar pavimentos. Para se chegar à classificação AASHTO, bem como aos valores de CBR e MR se faz necessário a realização de sondagens e ensaios de laboratório.

MIRANDA (2008) ressalta que em uma obra rodoviária, a Cartografia Geotécnica serve como ferramenta para a caracterização geral do meio físico, permitindo o estabelecimento de critérios mais seguros para a amostragem dos materiais. Adicionalmente, auxilia na avaliação preliminar qualitativa do comportamento mecânico dos solos, para a previsão de riscos ambientais e na identificação dos impactos potenciais das obras. Com isto, o mapeamento permite a adequação do projeto às condicionantes impostas pelo meio físico.

A obtenção de informações e parâmetros geotécnicos acerca dos solos para fins de projetos de pavimentos, geralmente, resulta em elevados custos (sondagens e ensaios de laboratório), bem como demanda tempo maior com coleta e análise dos dados ensaiados. Assim, propõe-se a geração e comparação de modelos dedicados à geração de estimativas de localização e do potencial uso de solos com fins de pavimentação. Foram comparadas as duas principais técnicas preconizadas na literatura para este fim, a saber, modelagem computacional e estatística.

A premissa básica que apoia esta investigação resume-se em que é possível obter estimativas de características geotécnicas de uma determinada região a partir de mapas geotécnicos produzidos por dados secundários, que podem ser oriundos de estudos geotécnicos de projetos viários, e variáveis biofísicas, utilizando técnicas de Geoprocessamento e modelagem computacional. O resultado dessa investigação poderá apoiar o processo da tomada de decisão para os projetos rodoviários, provendo minimização do tempo de execução, custos e impactos ambientais.

De acordo com as características do quadro natural e também do ponto de vista econômico, o IBGE (1990) dividiu o Rio Grande do Norte em microrregiões. A Microrregião Mossoroense é uma dessas regiões e apresenta potencial industrial e natural voltado para a produção de sal, petróleo, calcário e cimento. Além disso, a região possui localização geográfica privilegiada, ficando situada entre duas grandes capitais, Fortaleza-CE e Natal-RN, o que impulsiona os investimentos de Infraestrutura de Transportes e Logística. Diante dessas características a Microrregião de Mossoró (Rio Grande do Norte) foi escolhida para a aplicação deste estudo.

1.2 Problema de Pesquisa

A ausência de uma ferramenta adequada como auxílio a futuros projetos rodoviário que permita estimar a classificação dos solos e seu comportamento mecânico para fins de pavimentação na Microrregião de Mossoró, dificulta o encontro de materiais que atendam as exigências das normas do meio rodoviário, podendo-se conseqüentemente resultar e, pavimentos mais robustos e maiores custos financeiros e ambientais, uma vez que esses fatos implicam ainda num maior tempo de execução da obra.

1.3 Justificativa

Existem regiões onde há dificuldades de encontrar materiais adequados ao uso em projetos rodoviários, gerando problemas relacionados à busca e caracterização de materiais, e progressivamente retrabalho e acidentes geotécnicos, bem como aumento dos custos e diminuição da qualidade na elaboração e execução desses projetos (RIBEIRO *et al.*, 2010). Por isso, esta pesquisa, propõe a comparação entre diferentes técnicas de modelagem dedicadas ao reconhecimento prévio das características físicas dos solos aplicáveis em projetos rodoviários, minimizando a necessidade de viagens de reconhecimento de campo, sondagens, coleta de materiais ou ensaios de laboratório, a fim de reduzir significativamente os custos com levantamentos geotécnicos.

1.4 Questões de Pesquisa

- a) Quais são as técnicas mais adequadas para modelagem de características geotécnicas e quais seus graus de incerteza?
- b) Existem dados secundários que possam ser usados no processo de tomada de decisão quanto ao uso de materiais aplicados em projetos rodoviários e de infraestrutura? Se positivo, quais são esses dados e suas fontes?
- c) Qual é o grau de correlação das variáveis biofísicas disponíveis com as características geotécnicas (classificação AASHTO e CBR)?

- d) A inclusão de variáveis geomorfométricas como preditivas pode melhorar a qualidade dos modelos propostos?
- e) Qual é a técnica de modelagem, entre as estudadas, mais adequada para a predição de variáveis geotécnicas?
- f) Qual é o nível de precisão dos modelos desenvolvidos?

1.5 Objetivos

1.5.1 Objetivo Geral

O principal objetivo deste trabalho é implantar diferentes modelos dedicados à previsão e mapeamento geotécnico dos solos da microrregião de Mossoró-RN para fins de pavimentação e de uma análise comparativa entre esses modelos visando-se determinar tanto a técnica de modelagem mais adequada, quanto as variáveis preditoras mais significativas.

1.5.2 Objetivos específicos

- a) Implementar uma base de dados georreferenciados das informações do meio físico da Microrregião de Mossoró (MM), que venha dar suporte a criação de um modelo de inferência de propriedades geotécnicas;
- b) Extrair informações geotécnicas da Microrregião de Mossoró a partir de levantamentos realizados em projetos rodoviários pré-existentes.
- c) Realizar uma análise estatística dos dados geotécnicos da região de estudo;
- d) Gerar modelos para geração de estimativas de atributos geotécnicos dos solos, a partir de variáveis biofísicas e geomorfométricas;
- e) Comparar diferentes técnicas de modelagem para previsão e mapeamento geotécnico de solos e avaliar qual a melhor técnicas a ser empregada para tal finalidade;
- f) Avaliar a precisão dos modelos gerados.

1.6 Estrutura da Dissertação

A dissertação está dividida em 5 capítulos e 2 anexos.

Além deste capítulo introdutório, o Capítulo 2 destina-se a descrever a fundamentação teórica sobre modelagem geotécnica e características geotécnicas aplicadas na pavimentação. No Capítulo 3 são descritos os materiais e métodos empregados para a geração dos modelos propostos. O Capítulo 4 destina-se a apresentar e discutir os resultados obtidos, mostrando suas principais generalizações. No Capítulo 5 são apresentados as principais conclusões resultantes dos modelos gerados, bem como sugestões e recomendações para trabalhos futuros.

No Anexo I é mostrado o resultado obtido pelo software SPSS para a estimação do CBR para a MM, já no Anexo II é apresentado o resultado obtido pelo software SPSS para a estimação da Classificação AASHTO para a MM.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Considerações Iniciais

Na engenharia é comum a adoção de um sistema de classificação de solos para se prever as suas propriedades. As classificações mais difundidas no Brasil são o Sistema Unificado de Classificação de solos USCS (*Unified Soil Classification System*) e a classificação da AASHTO (*American Association of State Highway and Transportation Officials*) para fins rodoviários, embora existam outros métodos também consagrados no Brasil, como, por exemplo, a classificação MCT (Miniatura, Compactado, Tropical) idealizado por NOGAMI e VILLIBOR (1981).

No Brasil, para o dimensionamento de estruturas de pavimentos, utilizam-se principalmente dois parâmetros de caracterização mecânica como o Índice de Suporte Califórnia (ISC ou CBR em inglês), usado no dimensionamento empírico do DNIT, e o Módulo de Resiliência (MR) usado no dimensionamento mecanístico-empírico.

Para estimar os solos com finalidade de pavimentação da microrregião de Mossoró, este estudo foi subsidiado por informações adquiridas por projetos rodoviários. Buscando prever a classificação geotécnica e o parâmetro de resistência, e ainda com os dados disponíveis, as variáveis preditoras estimadas foram a classificação AASHTO e o valor de CBR.

A classificação AASHTO baseia-se na análise granulométrica por peneiramento e na determinação dos limites de liquidez e de plasticidade para classificar os solos. Já o CBR é a medida de resistência à penetração de uma amostra saturada compactada segundo o método Proctor, o valor da resistência é dado em porcentagem, sendo relacionado ao valor correspondente à penetração em uma amostra de brita graduada de elevada qualidade que foi adotada como padrão de referência.

2.2 Modelagem Geotécnica

A Cartografia Geotécnica é uma representação gráfica, em forma de um mapa ou carta geotécnica, das limitações e potencialidades do meio físico, na qual são avaliados todos os componentes de um ambiente geológico de particular interesse para o planejamento, projeto e construção civil ZUQUETTE (1981).

O mapa geotécnico assume uma conceituação mais abrangente, transformando-se num documento de grande utilidade para um considerável número de aplicações. Dessa forma, a cartografia geotécnica, à medida que engloba cada vez mais aspectos multidisciplinares, pode ser entendida como procedimento necessário à obtenção e à representação gráfica de aspectos do meio físico, baseados em estudos geológicos, pedológicos, geomorfológicos e geotécnicos, visando o estabelecimento de diretrizes para uso e ocupação do solo, estudos ambientais e projetos de engenharia (VALENTE, 1999).

Um mapa geotécnico é representado por um conjunto de unidades geotécnicas que podem ser definidas como uma região formada por perfis de solos que possuem comportamento geotécnico similar frente ao uso e à ocupação do solo (DAVISON DIAS, 1989). O mapeamento geotécnico tem como objetivo fundamental indicar as melhores formas de uso e ocupação do território, proteção dos recursos naturais e previsão de alerta em relação aos riscos naturais e induzidos a partir de interpretação de dados resultantes de estudos e análises do meio físico e de seus componentes considerando, ainda, as potencialidades e limitações do meio biótico e do meio socioeconômico. (PINHO, 2010).

Para MATULA (1974), um bom mapa geotécnico é o modelo mais ilustrativo do ambiente geológico servindo às finalidades de engenharia. O mapa geotécnico é entendido como o principal pré-requisito para uma exploração racional e detalhada, possibilitando generalizar os resultados; podendo ser preparado para as mais diferentes finalidades, desde o planejamento regional e urbano, com os mapas de multifinalidades, até os mapas de finalidade específica. Trata-se de uma técnica, relativamente, de baixo custo e que apresenta resultados bastante satisfatórios.

DAVISON DIAS (1995) desenvolveu uma metodologia para mapeamento geotécnico, onde utiliza ferramentas Cartográficas e de Geoprocessamento para definição de unidades geotécnicas. Esse mapeamento foi realizado a partir do cruzamento de informações pedológicas e geológicas que resultam na idealização de perfis de solos com provável comportamento geotécnico similar. O uso do Geoprocessamento nesta metodologia possibilitou a agregação das informações mapeadas a um banco de dados, de tal modo que esses dados poderão ser utilizados de forma centralizada e integrados a outras características do meio físico.

Mais recentemente RIBEIRO, DA SILVA e BARROSO (2010) utilizaram técnicas de Geoprocessamento e RNAs para estimar e mapear a classificação AASHTO e a Capacidade de Suporte (CBR) dos solos no município de Caucaia-Ceará a partir de dados secundários, como: Geologia, Pedologia, Geomorfologia e Fitofisionomia.

A elaboração de um mapa geotécnico, conforme salienta MORETTI (1989), envolve uma variedade muito ampla de estudos relativos ao meio físico, incluindo a sobreposição de aspectos metodológicos empregados em diversas áreas do conhecimento como a Mecânica dos Solos, a Pedologia e a Geologia, entre outros. O presente trabalho pretende abordar a estimação dos solos da Microrregião de Mossoró com fins para pavimentação associando as características físicas com as geotécnicas.

2.2.1 Estado da Arte

Duas técnicas de modelagem se destacam na literatura consultada. Trabalhos recentes utilizando Regressão Logística Múltipla (RLM) e Redes Neurais (RNA) para o mapeamento de solos podem ser encontrados na literatura. As Tabelas 1 e 2 apresentam um resumo cronológico do histórico de algumas publicações que envolvem essas técnicas

Tabela 1 - Estado da Arte do Mapeamento com RLM

ANO	AUTORES	ÁREA DE ESTUDO	R ² (%)
2003	Bailey	Inglaterra	47 a 65
2003	Hengl e Rossiter	Nordeste da Croácia	45,3
2006	Giasson <i>et al.</i>	Região sul do Brasil	71
2006	Figueiredo	Rio Grande do Sul	31 a 68
2009	Ten Caten <i>et al.</i>	São Pedro do Sul, RS	79,4

Fonte: Autoria Própria

Tabela 2 - Estado da Arte do Mapeamento com RNA's

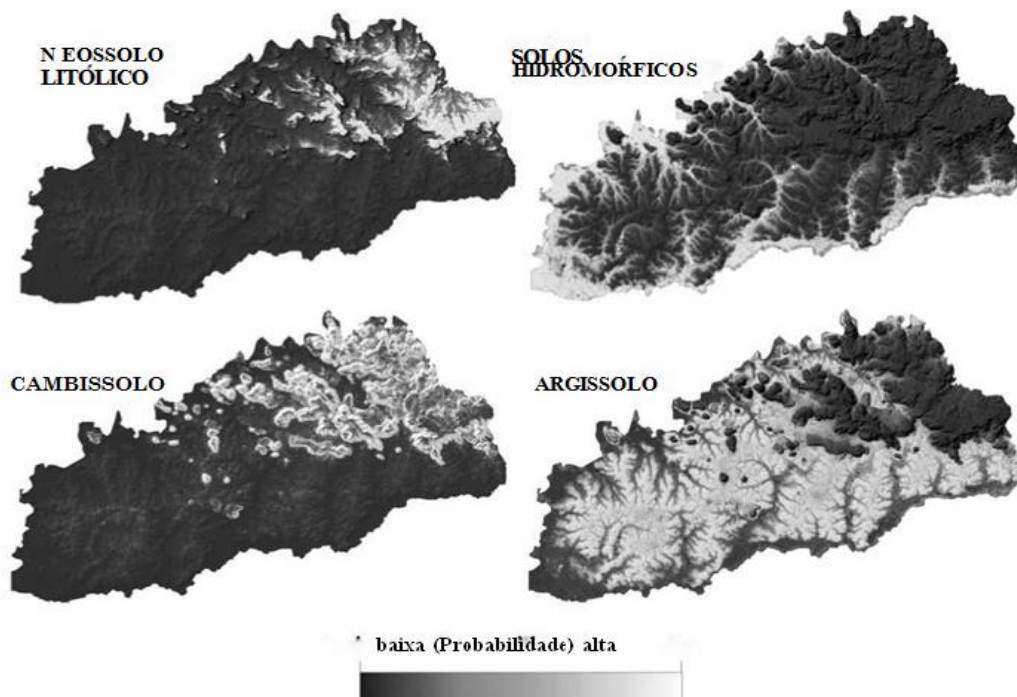
ANO	AUTORES	ÁREA DE ESTUDO	R ² (%)
2000	Zhu	Montana, EUA	77
2006	Chagas	Noroeste do Estado do Rio de Janeiro	70,8
2013	Arruda <i>et al.</i>	Barra Bonita, SP	72,7
2013	Ribeiro	Região metropolitana de Fortaleza, CE	90 a 92

Fonte: Autoria Própria

A maioria dos trabalhos de mapeamento dos solos são voltados para a ciências do solo, mais especificamente para as classificação dos solos. Alguns exemplos do uso das RLM para predição de classes de solos são os estudos de BAILEY *et al.* (2003), os quais utilizaram as RLM para produção de mapas de solo na Inglaterra e observaram que o resultado, em relação com a referência de campo, ficaram entre 47% a 65%. O estudo de HENGL & ROSSITER (2003) apresentou resultado de 45,3% de acurácia global e 42,6% no índice Kappa para mapeamento digital de solos no Nordeste da Croácia com a área de estudo compreendendo 1.062km².

No Brasil, os estudos de GIASSON *et al.* (2006), utilizaram as RLM para produção de mapas de solo na região sul, os resultados chegaram a apresentar até 71% de coincidência com o mapa referência. FIGUEIREDO (2006) comparou o resultado das RLM para predição de classes de solo em três localidades com fisiografia contrastante no Rio Grande do Sul, os resultados variaram de 31% a 68% de coincidência com os mapas originais. O autor concluiu que as RLM têm potencial para produção de mapas pedológicos e que a eficiência do modelo depende da qualidade dos dados utilizados. TEN CATEN *et al.* (2009), fizeram uso das RLM com aplicação de componentes principais para estimativa de solo no Sul do Brasil, afim de diminuir a dimensionalidade das variáveis, com perda irrelevante de informação. O resultado obtido ficou em 79,40% de coincidência com o mapa referência, conforme a Figura 1.

Figura 1 - Estudo de TEN CATEN *et al.* (2009)



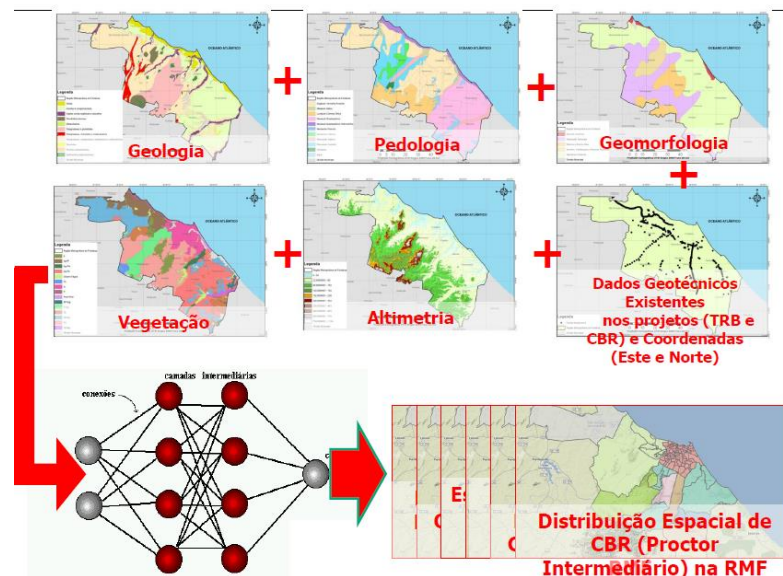
Fonte: TEN CATEN *et al.* (2009)

Giasson *et al.* (2006) verificaram que os atributos do terreno mais recorrentes quando da utilização de regressões logísticas foram ELEV, DIST, IUT, curvaturas e DECL. Todos esses atributos estão relacionados com acúmulo e dinâmica da água.

Com a utilização de uma abordagem de redes neurais Zhu (2000) inferiu corretamente as classes de solo avaliadas em 77% dos locais. Chagas (2006) mostrou que o mapa produzido pela aplicação das RNA's obteve concordância de 70,83%, concluindo que a utilização dos atributos de terreno e dos dados de sensores remotos em uma abordagem por redes neurais pode contribuir para um mapeamento de solos mais científico e confiável. Ainda concluiu que os atributos de terreno derivado do MDE que mais se correlacionaram com a distribuição de solos foram a elevação, declividade, aspecto e plano de curvatura.

Arruda *et al.* (2013) também utilizou com variáveis preditoras os atributos de terreno do MDE e evidenciou exatidão de 72% no mapeamento de solos de Barra Bonita – SP. O trabalho de RIBEIRO (2013) também utilizou técnicas de RNA's, porém o mapeamento de classificação dos solos foi voltado para engenharia, com ênfase em pavimentação. As variáveis preditoras utilizadas foram as variáveis biofísicas (geologia, geomorfologia, vegetação e pedologia) e as coordenadas geográficas, e foi possível mapear essa a classificação TRB (atual AASHTO) com 92,6% de acerto. A Figura 2 mostra as variáveis envolvidas no estudo, bem como o esquema da técnica utilizada. Além dessa classificação, os autores também mapearam a RMF (Região metropolitana de Fortaleza - CE) com valores de resistência de solo, CBR, com 90% de acerto.

Figura 2 - Estudo de RIBEIRO (2013)



Fonte: RIBEIRO (2013)

Para os estudos com redes neurais essa taxa de acerto considera a porcentagem de acertos na fase de teste, pois é onde o modelo é aplicado e depois é verificado a correlação com os dados reais.

Os resultados alcançados nesses trabalhos mostram que a utilização de atributos de terreno e dados biofísicos aliados a uma abordagem por redes neurais ou por Regressão Logística Múltipla pode contribuir grandemente para melhorias da qualidade dos levantamentos dos solos.

2.2.2 Principais Técnicas de Modelagem Geotécnica de solos para pavimentação

2.2.2.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são técnicas de Inteligência Artificial (IA) que tentam reproduzir o funcionamento do cérebro humano em sistemas computacionais de maneira simplificada. Essa técnica vem sendo utilizadas em várias áreas de estudo para resolver diferentes problemas através de aplicações diversas. Alguns dos principais usos são aplicações que trabalham com simulação de dados.


De acordo com HAYKIN (2001) as RNAs são constituídas por neurônios artificiais, projetados para ter um comportamento similar ao neurônio biológico, sendo análogo ao cérebro em dois aspectos principais: o primeiro se refere ao conhecimento que é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. Já o segundo aspecto leva em consideração as forças de conexão entre neurônios, conhecidas como pesos sinápticos, que são utilizadas para armazenar o conhecimento adquirido.

2.2.2.1.1 O Neurônio Biológico

O sistema nervoso humano, é a inspiração das Redes Neurais Artificiais (RNAs), é constituído por células altamente diferenciadas chamadas neurônios, que possuem a habilidade de receber informações de seu próprio corpo celular ou do ambiente externo, integrando a informação e transmitindo-a para outras células. Conforme indica a Figura 3, cada neurônio possui um corpo celular, onde na sua parte interior se encontra a maioria dos

seus orgânulos. Do corpo celular de cada neurônio partem prolongamento que são funcionalmente divididos em dendritos e axônios (Wasserman, 1989 *apud* Chagas, 2006).

Figura 3 - Componentes de Neurônios Biológico



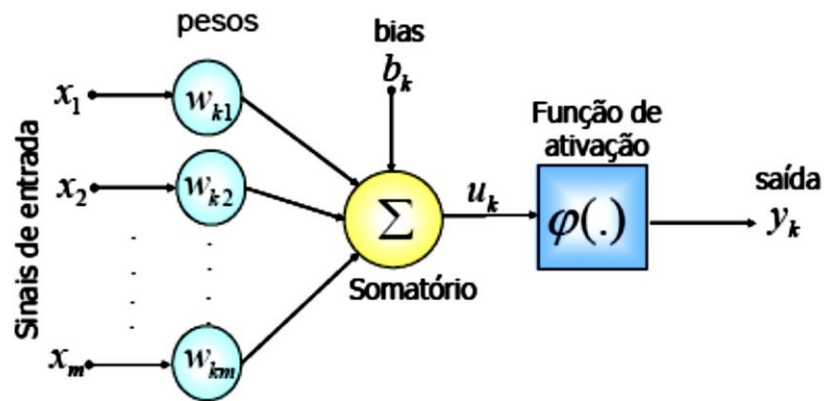
Fonte: Davis (1993) *apud* Fabri *et al*, 2012.

2.2.2.1.2 O Neurônio Artificial

Baseados no paradigma biológico, em 1943, o neuro-anatomista e psiquiatra Warren McCulloch e o matemático Walter Pitts desenvolveram o primeiro modelo artificial de um neurônio biológico. Nessa pesquisa os autores dedicaram-se a descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais. O aprendizado de redes biológicas e artificiais veio a ser objeto de estudo somente alguns anos depois. O primeiro trabalho nesse âmbito foi registrado em 1949 por Donald Hebb, que mostrou como a plasticidade de redes neurais é conseguida através da variação dos pesos de entrada dos nodos. A partir de então outros pesquisadores começaram a desenvolver pesquisas sobre a capacidade de executar determinadas funções conforme pode ser consultado em BRAGA *et al*. (2000).

O modelo matemático que representa o funcionamento de um neurônio biológico de forma artificial é chamado de Perceptron. De acordo com DA SILVA (2003), esse neurônio representa uma aproximação bastante simplificada sob a ótica Neurofisiológica, porém mantém várias características básicas de um neurônio biológico e viabiliza sua implementação computacional. A Figura 4 apresenta o modelo de um neurônio artificial.

Figura 4 - Modelo não linear de neurônio artificial



Fonte: DA SILVA, 2003.

Onde: x_m são as entradas da rede, w_{km} são os pesos, ou pesos sinápticos, associados a cada entrada, b_k é o termo bias, u_k é a combinação linear dos sinais de entrada, $\varphi(\cdot)$ é a função de ativação e y_k é a saída do neurônio.

Pode-se dizer que os pesos contém todo o conhecimento adquirido pela rede neural artificial. Os pesos são os parâmetros ajustáveis e que mudam e se adaptam à medida que o conjunto de treinamento é proposto à rede. Dessa maneira, o processo de aprendizado supervisionado em uma RNA com pesos, resulta em sucessivos ajustes dos pesos sinápticos de tal forma que a saída da rede seja a mais próxima possível da resposta desejada. (DA SILVA, 2003).


Normalmente, a ordem de amplitude normalizada da saída do neurônio está no intervalo $[0, 1]$ ou alternativamente $[-1, 1]$. O modelo neural também possui um termo chamado de bias, aplicado externamente, simbolizado por b_k . O bias (b_k) tem o efeito do acréscimo ou decréscimo da função de ativação na entrada da rede, dependendo se é positiva ou negativa, respectivamente. As regiões de decisão são intervalos fixos onde a resposta desejada pode estar. O bias serve para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento fornecido a ela (DA SILVA, 2003).

2.2.2.1.3 Arquitetura das RNAs

A estrutura das RNAs pode ser constituída por várias unidades de cálculo, onde as informações são processadas paralelamente. Elas dispõem também de unidades de

processamento chamadas de “neurônios”, as quais são conectadas entre si através de ligações que coordena o fluxo da informação pela rede, assim como acontece na rede neural biológica. As unidades de processamento podem ser através das ligações, posicionadas em camadas intermediárias ou camadas ocultas entre a entrada e a saída, como está representado na Figura 5.

Figura 5 - Esquema de uma rede de neurônios



Fonte: FIORINI *et al*, 2011.

2.2.2.1.4 Topologia da Rede

Topologia em RNA significa a quantidade de camadas intermediárias, entradas, saídas, bem como a quantidade de neurônios nessas camadas. Procura-se definir a melhor topologia para determinado problema com a finalidade de obter uma melhor qualidade no resultado do seu treinamento.

DA SILVA (2003) defende que o desempenho da rede está diretamente associado à quantidade das camadas de neurônios, uma vez que uma maior quantidade de camadas aumenta a capacidade de aprendizado, melhorando a precisão com que a rede delimita regiões de decisão. Porém, na prática, aumentar o número de camadas intermediárias, às vezes, se torna inviável devido ao esforço computacional.

Diversos pesquisadores estabelecem critérios matemáticos para determinar uma topologia ótima para o funcionamento da rede, dentre esses estão: HECHT e NIELSEN (1989) que afirmam “com apenas uma camada intermediária na rede neural, já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos”. De acordo com estes autores a camada oculta deve ter por volta de $(2i+1)$ neurônios, onde i é o número de variáveis de entrada.

LIPPMANN (1987) defende que quando houver uma segunda camada intermediária na topologia da rede, ela deve ter o dobro de neurônios da camada de saída. No entanto no

caso de existir apenas uma camada oculta, essa deverá possuir $s(i+1)$ neurônios, onde s é o número de neurônios de saída e i o número de neurônios de entrada.

2.2.2.1.5 Os Modelos Neurais

Há diferentes modelos de RNAs descritos na literatura. Diante desse grande número de possibilidade, o processo de seleção pode parecer uma tarefa difícil, mas é provável que apenas poucos modelos forneçam uma solução excelente (MASTERS, 1994).

Apesar de existirem diversos métodos para o treinamento de redes neurais, eles podem ser divididos em dois paradigmas principais que são os aprendizados: supervisionado e não supervisionado. De acordo com BRAGA *et al.* (2000), o aprendizado supervisionado é o método mais comum no treinamento das RNAs, tanto de neurônios com pesos como de neurônios sem pesos. É chamado de aprendizado supervisionado porque a entrada e a saída desejadas para a rede são fornecidas por um supervisor externo. O objetivo é ajustar os parâmetros da rede, a fim de encontrar uma ligação entre os pares de entrada e saída fornecidos. SILVA *et al.* (2011) afirma que esse treinamento pode ser feito on-line, quando “o conjunto de dados muda continuamente, e a rede deve estar em contínuo processo de adaptação” e/ou off-line quando “os dados do conjunto de treinamento não mudam, e uma vez obtida uma solução para a rede, esta deve permanecer fixa”.

Já no aprendizado não supervisionado não existem pares de entrada e saída, só entradas. A RNA procura “características estatisticamente relevantes” (SILVA *et al.*, 2011) entre os dados apresentados. Tal técnica é aplicável apenas se houver uma grande quantidade de dados. Esta investigação utilizará apenas o método de aprendizado supervisionado.

2.2.2.2 *Perceptron* Multi Camadas (MLP) e o Algoritmo Backpropagation

As RNAs com *perceptrons* de múltiplas camadas (*Multilayer Perceptron* – MLP) consistem no tipo de arquitetura mais comum, sendo em um conjunto de unidades de processamento formada por unidades de entrada, unidades intermediárias (ou camadas escondidas) e camada de saída. “Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para saída” (BOCANEGRA, 2002). Sua aplicação tem sido feita em problemas “envolvendo altos graus de não linearidades” (BOCANEGRA, 2002).

Para RUMELHART *et al.* (1986), as redes de múltiplas camadas são aproximadores universais e seu uso é indicado quando se tem pouco conhecimento e dados insuficientes acerca do relacionamento entre as variáveis independentes e dependentes. A variação da complexidade do modelo MLP pode ser feita variando o número de camadas intermediárias e o número de neurônios em cada camada intermediária.

Os *perceptrons* de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas difíceis, através de seu treinamento de forma supervisionada com um algoritmo popularmente conhecido com algoritmo de retropropagação de erro (*errorback-propagation*). Segundo HAYKIN (2001) este algoritmo é baseado na regra de aprendizagem por correção de erro e funciona basicamente em dois passos através das diferentes camadas da rede: um passo para frente, a *propagação*, e um passo para trás, a *retropropagação*.

(i) no passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Finalmente, um conjunto de saídas é produzido como resposta real da rede. Durante essa etapa os pesos sinápticos da rede são todos fixos;

(ii) no passo para trás, no entanto, os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro. Especificamente a resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Esse sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas – vindo daí o nome de “retropropagação de erro”. Os pesos sinápticos são ajustados para que a resposta real se mova para mais perto da resposta desejada, em um sentido estatístico.

BOCANEGRA (2002) descreve um processo de treinamento em cinco passos:

- a) Apresentar à rede um conjunto de dados com entradas e suas respectivas saídas conhecidas;
- b) Estimar a saída a partir dos dados fornecidos como entrada;
- c) O sinal se propaga pela rede até atingir a saída; é quando os pesos da saída são ajustados;
- d) Ajustar os pesos das camadas intermediárias (os pesos são iniciados com valores aleatórios);
- e) Conferir o erro, que pode ser feito de várias formas. O objetivo principal de tal passo é determinar um critério que o erro deve atingir e, caso o erro não atenda ao critério, o processo é repetido, os pesos das camadas intermediárias são reajustados, novos valores para saídas são estimados e o novo erro é encontrado. Considera-se que o algoritmo está “treinado” quando o erro atende ao critério pré-definido.

2.2.2.2. *Modelagem Estatística*

2.2.2.2.1. Regressão Linear

A análise de regressão é uma técnica estatística que investiga e modela a relação entre variáveis, sendo uma das mais utilizadas na análise de dados. Um dos objetivos dessa análise é estimar os parâmetros desconhecidos do modelo.

A análise de regressão linear estuda a relação entre a variável dependente ou variável resposta (y) e uma ou mais variáveis independentes ou regressoras (x_1, x_2, \dots, x_k). O modelo de Regressão Linear Simples define-se como a relação entre a variável dependente (y) e uma variável independente (x), enquanto no modelo de Regressão Linear múltipla relaciona a variável dependente (y) com várias variáveis independentes (x_1, x_2, \dots, x_k).

Neste estudo tem-se o interesse de avaliar a relação de uma variável de interesse y (variável dependente) com k variáveis x_j (variáveis independentes), $j = 1, 2, \dots, k$. Portanto, um possível modelo matemático para avaliar essa relação pode ser dado por

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i, \quad i = 1, \dots, n \quad (1)$$

em que, n é o número de indivíduos, y_i é a observação da variável dependente para o i -ésimo indivíduo, $x_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ é um vetor de observações das variáveis independentes para o i -ésimo indivíduo, $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_k)$ é um vetor de coeficientes de regressão (parâmetros) e ε_i é um componente de erro aleatório. Assume-se que esses erros são independentes e seguem uma distribuição normal com média zero e variância desconhecida.

2.2.2.2.2. Regressão Logística

Nos casos em que o resultado de uma inferência pode ser dado sob muitas categorias, ou politômica, como é o caso das classes de solo, uma alternativa é trabalhar com modelos logísticos (TEN CATEN *et al.*, 2009). O modelo de regressão logística permite avaliar a probabilidade de ocorrência de uma variável resposta, considerando os valores de uma série de variáveis independentes que podem ser qualitativas ou quantitativas (HENGL *et al.*, 2007). Por ser utilizada mais que uma variável independente, o modelo é considerado múltiplo e, pelo fato de prever mais que duas classes, é considerado multinomial (ou politômico); logo,

o modelo é denominado de regressão logística múltipla multinomial (RLMM), que é uma generalização do modelo logístico simples (COELHO & GIASSON, 2010).

Segundo Chatterjee & Hadi (2006) *apud* Caten (2008), a RLM não possui exigência alguma para sua aplicação no que diz respeito à distribuição das variáveis explicativas, não necessitando possuí distribuição normal, correlação linear, medidas em mesma escala ou homogeneidade de variância. As variáveis explicativas podem ser, ainda, uma mistura de dados contínuos, discretos ou binários.

A aplicação de RLM envolve a função logarítmica ou logit, a qual é definida como a razão entre a probabilidade de o evento ocorrer e a probabilidade de esse evento não ocorrer (odds ou razão de chance). Para as classes de solo, a logit é a função logarítmica da razão entre a probabilidade (p_i) de um pixel ser membro de uma classe de solo “i” e a probabilidade de que ele não seja ($1 - p_i$). Seu valor pode ser determinado por meio da regressão abordada na Equação 1 (CATEN,2008):

$$\text{logit}_i = \ln \frac{p_i}{(1 - p_i)} = a + b_0 + b_1X_1 + b_2X_2 + \dots + b_kX_k \quad (1)$$

A equação demonstra como calcular o logit de uma categoria predita a partir de um conjunto de variáveis ($X_1 \dots k$). O logit é, portanto, o logaritmo natural de uma razão entre probabilidades. O valor de “a” indica o intercepto da regressão e os valores de “b” são os coeficientes de cada variável explicativa (CHATTERJEE & HADI, 2006 *apud* CATEN, 2008).

Devido ser mais fácil de perceber a razão entre probabilidades do que seu logaritmo, a Equação 5 pode ser reescrita conforme exposto na equação (2):

$$\frac{p_i}{(1 - p_i)} = e^{a+b_0+b_1X_1+b_2X_2+\dots+b_kX_k} \quad (2)$$

Quando a variável resposta tem apenas duas alternativas distintas (dicotômica), aplica-se a Regressão Logística Binomial (RLB), da qual a RLM é uma extensão. Na RLB a probabilidade de um evento ocorrer é calculada pelo rearranjo da Equação 3 para:

$$p_i = \frac{e^{a+b_0+b_1X_1+b_2X_2+\dots+b_kX_k}}{1 + e^{a+b_0+b_1X_1+b_2X_2+\dots+b_kX_k}} \quad (3)$$

Mas tratando-se de um conjunto de respostas politômicas (várias classes de solo), faz-se necessário estabelecer uma categoria de referência ou base, da qual, em um primeiro momento, não é calculada a probabilidade de ocorrência. Para as demais se aplica a Equação 4:

$$P_i = \frac{e^{a+b_0+b_1X_1+b_2X_2+\dots+b_kX_k}}{1 + \sum_1^{m-1} (e^{a+b_0+b_1X_1+b_2X_2+\dots+b_kX_k})} \quad (4)$$

Assim tem-se a previsão da probabilidade P_i de que a classe de solo "i" esteja presente em determinado pixel, sendo X_1, X_2, \dots, X_k as variáveis preditoras, pela razão entre o logit de "i" e a soma dos logit de todas as outras classes, exceto da classe tomada como referência, mais um.

A classe de referência, não terá seu logit determinado. Sendo sua probabilidade estimada pela Equação 5:

$$P_i = \frac{1}{1 + \sum_1^{m-1} (e^{a+b_0+b_1X_1+b_2X_2+\dots+b_kX_k})} \quad (5)$$

Todos os valores de "a" e "b" das regressões serão determinados para os parâmetros geotécnicos do solo a partir de dados experimentais.

As regressões lineares selecionam os coeficientes que minimizam o quadrado da distância, já em regressões logísticas os coeficientes são obtidos através de um algoritmo iterativo por verossimilhança, os quais tornam o resultado observado mais provável. O processo iterativo de busca dos melhores parâmetros para as k equações não retorna um coeficiente de determinação (R^2), como nas regressões convencionais, mas modelos passam por um teste de significância. (OHLMACHER; DAVIS, 2003 *apud* CATEN, 2008).

2.2.3. Principais vantagens e desvantagens das técnicas de modelagem usadas

A seleção de variáveis é o princípio para se chegar a um modelo, mas ainda devem ser analisados outros fatores de modo a obter um modelo com boa predição ou que explique bem o relacionamento entre os dados. Os métodos estatísticos têm a vantagem de não necessitar de

grande esforço computacional. Fensterstock (2005) aponta ainda as seguintes vantagens na utilização de técnicas estatísticas multivariadas na construção de modelos:

- a) Modelo gerado leva em consideração a correlação entre as variáveis, identificando relações que não seriam visíveis e eliminando variáveis redundantes.
- b) Consideram as variáveis individual e simultaneamente.
- c) Usuário pode verificar as fontes de erro e otimizar o modelo.

Particularmente no caso da regressão logística, conforme mencionado anteriormente, não se exige distribuição normal das variáveis independentes, diferentemente da análise discriminante, sendo a primeira mais flexível em suas condições de uso. O mesmo autor também identifica as desvantagens desse tipo de técnica:

- a) Em muitos casos, a preparação das variáveis demanda muito tempo.
- b) No caso de muitas variáveis, o analista deve fazer uma pré-seleção das mais importantes, baseando-se em análises separadas.
- c) Alguns modelos resultantes são de difícil implementação.

Dependendo do tipo de problema ao qual são submetidas, as RNAs têm apresentado um desempenho considerado superior aos métodos estatísticos utilizados para o mesmo fim (FALAS, 1995). SUBRAMANIAN *et al.* (1993), por exemplo, desenvolveram uma pesquisa comparativa entre as Redes Neurais e determinados métodos estatísticos de classificação. Concluíram, nas várias circunstâncias estudadas, incluindo pequenos tamanhos de amostras e funções de maior complexidade, que as RNAs apresentaram melhores soluções.

De acordo com Haykin (2001) o uso das redes neurais oferece as seguintes vantagens:

- a) Não-linearidade: um neurônio artificial pode ser linear ou não-linear. A não linearidade é distribuída por toda a rede. Se o mecanismo responsável pela geração do sinal de entrada for inerentemente não linear, a não-linearidade torna-se uma propriedade muito importante.
- b) Adaptabilidade: as redes neurais possuem a capacidade de adaptar seus pesos sinápticos a modificações do meio ambiente. Assim, uma rede neural treinada para operar em um ambiente específico pode ser retreinada para lidar com pequenas alterações nas condições operativas do ambiente.
- c) Resposta a evidências: no contexto de classificação de padrões, uma rede neural pode ser projetada para fornecer informações sobre a confiança ou crença na decisão

tomada, possibilitando rejeitar padrões ambíguos e, por consequência, melhorar o desempenho de classificação da rede.

- d) Informação contextual: O conhecimento é representado pela estrutura e estado de ativação de uma rede neural. Cada neurônio da rede é potencialmente afetado pelas atividades de todos os outros neurônios na rede. Dessa forma, a informação contextual é tratada naturalmente pela rede.

Ambrósio (2002) ressalta que além das inúmeras vantagens supracitadas, existem algumas desvantagens relacionadas à utilização das redes neurais, dentre as quais:

- a) Treinamento demorado: dependendo da aplicação da rede neural, o treinamento pode ser demorado, demorando horas ou mesmo dias.
- b) Resultados desconcertantes: as redes podem chegar a conclusões contrárias às teorias aceitas, onde somente o bom senso do pesquisador poderá solucionar tal problema.
- c) Caixa-preta: não é possível saber o motivo que levou a rede a uma determinada conclusão.
- d) Grande volume de dados: para o correto aprendizado da rede, é necessário um grande volume de dados históricos, o que pode demandar tempo e recursos.
- e) Preparação dos dados: os dados de entrada da rede neural necessitam de tratamento prévio como, por exemplo, a normalização e seleção criteriosa, a fim de obter resultados confiáveis.

2.3 Geoprocessamento

A análise espacial, como a que se propõe utilizar neste trabalho, insere-se no contexto do Geoprocessamento. Para Câmara *et al* (1996), Geoprocessamento representa a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica e que vem influenciando de maneira significativa as áreas de Cartografia, Análise de Recursos Naturais, Transportes, Comunicações, Energia e Planejamento Urbano e Regional. Assim, geoprocessamento pode ser considerado como um conjunto de ferramentas de processamento e descrições de informações geográficas. Entre essas ferramentas podem ser citados os métodos geoestatísticos, as ferramentas de Sistema de Informação Geográfica, os processamentos de imagens e os métodos de interpolação.

2.3.1 Sistema de Informações Geográficas

Um Sistema de Informações Geográficas (SIG) surgiu da necessidade de armazenamento, processamento e visualização de dados espaciais, juntamente com o alto desenvolvimento computacional. Para Câmara (1996), o termo SIG é aplicado para sistemas que realizam o tratamento computacional de dados geográficos. Um SIG armazena a geometria e os atributos dos dados que estão georreferenciados, isto é, representados numa projeção cartográfica na superfície terrestre. Os dados tratados em Geoprocessamento têm como principal característica diversidade de fontes geradoras e de formatos apresentados.

Para CÂMARA *et al.* (1996), o termo SIG é empregado em sistemas que realizam o tratamento computacional de dados geográficos. Difere de um sistema de informação convencional por sua capacidade de armazenar tanto os atributos descritivos, como as geometrias dos diferentes tipos de dados geográficos. Assim, para cada furo (ponto) em um cadastro de sondagens, por exemplo, um SIG guarda, além de informações descritivas como numeração do furo de sondagem e endereço, a informação geométrica a partir das coordenadas geográficas do furo de sondagem. A partir desses conceitos, é possível indicar as principais características do SIG:

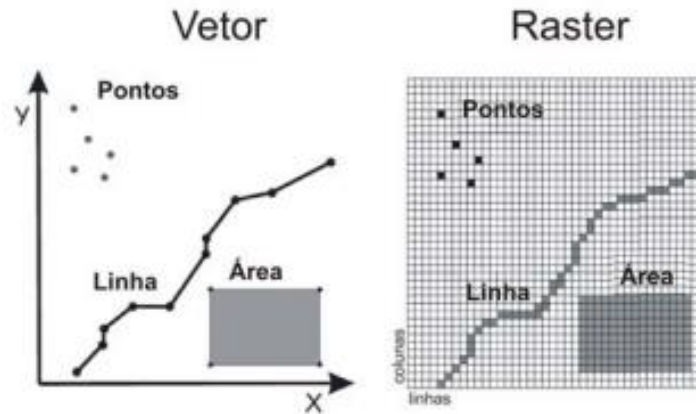
- a) Inserir e integrar, em uma única base de dados, informações espaciais provenientes de meio físico-biótico, de dados censitários, de cadastros urbano e rural, e outras fontes de dados como imagens de satélite, e GPS;
- b) Disponibilizar mecanismos para combinar as várias informações, por meio de algoritmos de manipulação e análise, bem como para consultar, recuperar e visualizar o conteúdo da base de dados geográficos.

2.3.2 Modelos de Representação de Dados Georeferenciados

Segundo ARNOFF, 1995 e BURROUGH e McDONNELL, 1998, existem dois tipos de estrutura de dados gráficos no SIG: estrutura vetorial e raster. Na estrutura vetorial, os objetos do mundo real são representados através de pontos, linhas e polígonos, onde a posição de cada objeto é definida para um sistema de coordenadas. Na estrutura raster o espaço é

divido em células, a posição geográfica do objeto é definida através de linhas e colunas. A Figura 6 orienta quanto aos objetos na representação vetorial e raster.

Figura 6 - Representação dos dados no modo vetor e no modo raster



Fonte: RIBEIRO *et al*, 2006.

2.3.3 Álgebra de Mapas

Segundo Berry (1991) *apud* Barbosa (1997), o conceito de álgebra de mapas ou álgebra de campos pode ser definido como uma extensão da álgebra tradicional, com um conjunto de operadores onde as variáveis manipuladas são campos geográficos. Estes operadores manipulam um, dois ou mais geo-campos, em que cada geo-campo descreve um atributo diferente ou até um mesmo atributo, mas com valores diferentes.

Para TOMLIN (1990), a álgebra de mapas é um processo que decorre de operações primitivas de pontos, vizinhança e regiões sobre diferentes mapas, numa lógica sequencial para interpretar e resolver problemas espaciais. Na estrutura interna desse tipo de representação, cada *grid* categórico tem um valor associado numa tabela (VAT - *Value Attribute Table*), que armazena a base de dados.

2.4 Solos

Para VILLIBOR *et al.* (2000), os solos são materiais naturais não consolidados, constituídos de grãos separáveis por processos mecânicos e hidráulicos, de fácil dispersão em água e que podem ser escavados com equipamentos comuns de terraplenagem (pá carregadeira, motoescavotransportadora, etc).

Segundo JENNY (1941), os fatores de formação dos solos são variáveis independentes, a partir dessa premissa, escreveu a Equação (6) de fatores de formação dos solos:

$$S = f(\text{cl, o, r, p, t...}) \quad (6)$$

Onde: cl = clima, o = organismos, r = relevo, p = material de origem, e t = tempo.

Desta forma os solos são considerados o produto final do intemperismo e sua formação está condicionada a fatores como o tipo de rocha, clima, vegetação, topografia e tempo de intemperismo. O conhecimento desses fatores pode ajudar no entendimento das características e propriedades dos solos ocorrentes em uma dada região (BARROSO, 2002).

2.4.1 Geotecnia dos solos para Pavimentação

2.4.1.1 Características Físicas

Algumas características devem ser investigadas para a previsão do comportamento de um solo. São elas:

a) Análise granulométrica por peneiramento - O tamanho das partículas constituintes de um solo é determinado por meio da granulometria. De acordo com seu tamanho, as partículas de um solo podem ser classificadas segundo a Escala Granulométrica da AASHTO em:

- Pedregulho $\rightarrow 2,0 \text{ mm} < \varphi < 60,0 \text{ mm}$;
- Areia $\rightarrow 0,075 \text{ mm} < \varphi < 2,00 \text{ mm}$;
- Areia grossa $\rightarrow 0,42 \text{ mm} < \varphi < 2,00 \text{ mm}$;
- Areia fina $\rightarrow 0,075 \text{ mm} < \varphi < 0,42 \text{ mm}$;
- Silte $\rightarrow 0,005 \text{ mm} < \varphi < 0,075 \text{ mm}$;
- Argila $\rightarrow \varphi < 0,005 \text{ mm}$;

onde: φ é o diâmetro dos grãos.

b) Limite de Liquidez (LL) - É o teor de umidade que marca a transição do estado plástico ao estado líquido e está relacionado com a capacidade do solo em absorver água;

- c) Limite de Plasticidade (LP) - É o teor de umidade que indica a passagem do estado semi-sólido para o estado plástico;
- d) Índice de Plasticidade (IP) - Mede a plasticidade dos solos, sendo calculado pela diferença entre LL e LP ($IP = LL - LP$). Representa a quantidade de água necessária para que um solo passe do estado plástico ao líquido.

2.4.1.2 Classificação AASHTO

A classificação AASHTO, antes chamada de classificação TRB (*Transportation Research Board*), é resultante de alterações da classificação do *Bureau of Public Roads* (BPR), originalmente apresentada em 1929 (DNER, 1996). A proposta era estabelecer uma hierarquização para os solos do subleito a partir da realização de ensaios simples e realizados de forma corriqueira: a análise granulométrica por peneiramento e a determinação dos limites de liquidez e de plasticidade (CHAVES, 2000).

A classificação da AASHTO tem sido aplicada no reconhecimento de solos para construção de pavimentos rodoviários em todo o mundo. Nesta classificação, os solos são divididos de forma geral, em dois grandes grupos: os materiais granulares (% passante na peneira nº 200 \leq 35%) e os materiais silto-argilosos (% passante na peneira nº 200 $>$ 35%).

Através de uma tabela classificatória, os solos são separados em grupos e subgrupos através de processo de eliminação a partir do lado esquerdo para o lado direito e de cima para baixo da referida tabela. O primeiro grupo, a partir da esquerda e de baixo para cima, com o qual os valores encontrados coincidirem, será a classificação correta. (DNIT, 2006). A Tabela 3 traz a classificação AASHTO (DNIT, 2006).

Tabela 3 - Classificação dos grupos de Solo segundo a AASHTO

Classificação Geral	Materiais Granulares						Materiais Silto - Argilosos							
	35 % (ou menos) passando pela peneira N.º200						Mais de 35 % passando pela peneira N.º200							
Classificação em grupos	A - 1		A - 3		A - 2		A - 4		A - 5		A - 6		A - 7	
	A - 1 - A		A - 1 - B		A - 2 - 4		A - 2 - 5		A - 2 - 6		A - 2 - 7		A - 7 - 5	
													A - 7 - 6	
Granulometria - % passante:														
Peneira N.º 10	50 máx.													
Peneira N.º 40	30 máx.		30 máx.		51 mín.									
Peneira N.º 200	15 máx.		25 máx.		10 máx.		35 máx.		35 máx.		35 máx.		35 máx.	
Características da fração passando na peneira N.º40:														
Limite de Liquidez					40 máx.		41 mín.		40 máx.		41 mín.		40 máx.	
Índice de Plasticidade	6 máx.		6 máx.		N.P.		10 máx.		10 máx.		11 mín.		11 mín.*	
Índice de Grupo	0		0		0		0		0		4 máx.		4 máx.	
											8 máx.		12 máx.	
													16 máx.	
													20 máx.	
Materiais Constituintes	Fragmentos de pedra, pedregulho fino e areia				Pedregulhos ou areias siltosos ou argilosos				Solos Siltosos		Solos Argilosos			
Comportamento como Subleito	Excelente a bom						Sofrível a mau							

*O IP do grupo A - 7 - 5 é igual ou menor do que o LL menos 30.

2.4.2 Parâmetros de Resistência

2.4.2.1 Califórnia Bearing Ratio (CBR)

A partir de um estudo sobre as condições das rodovias no estado da Califórnia foi elaborada metodologia do CBR. Essas rodovias apresentavam sinais de rupturas oriundas de má compactação, excesso de umidade no subleito, espessuras de bases insuficientes e bases com materiais com baixa resistência ao cisalhamento. Daí tornou-se evidente para a Divisão de Rodovias da Califórnia a necessidade de um método de dimensionamento que levasse em consideração essas características que influenciavam no desempenho da estrutura do pavimento, surgindo assim o ensaio CBR (COUTINHO, 2011).

A resistência no ensaio CBR é uma combinação indireta entre a coesão e o ângulo de atrito do material. É expresso em porcentagem, sendo definido como a relação entre a pressão necessária para produzir a penetração de um pistão num corpo-de-prova de solo ou material granular e a pressão necessária para produzir a mesma penetração no material padrão referencial. (BERNUCCI et. al, 2006). O valor dessa relação, expressa em porcentagem, permite determinar por meio de equações empíricas, a espessura de pavimento flexível necessária, em função do tráfego (DNIT, 2006).

O critério básico utilizado no CBR é o de camadas granulares sobre o subleito de maneira a proteger esse de rupturas por cisalhamento. O método consiste basicamente em se obter a espessura da camada granular sobre o subleito conhecendo-se o CBR do subleito. Também se supõe que o material do pavimento que irá proteger o subleito seja suficientemente nobre para suportar as tensões que nele haverão de ser resistidas e dissipadas. Esse método foi baseado em correlações empíricas, mas ainda é bastante difundido. É um ensaio simples e rápido de executar, que pode ser utilizado em materiais argilosos e arenosos. (COUTINHO, 2011).

Este método serviu de referência para o desenvolvimento do método empírico de dimensionamento de pavimentos do DNER – Método do CBR, proposto pelo Eng. Murilo Lopes de Souza em 1966 (última versão revisada e publicada em 1981), que ainda é o mais usado no meio rodoviário devido a sua simples concepção (LEMOS e SANTOS, 2013). O Departamento Nacional de Infraestrutura de Transportes (DNIT) utiliza o valor do CBR para dimensionar pavimentos flexíveis.

2.4.2.2 Módulo de Resiliência (MR)


O módulo de resiliência (M_R) mede a deformação elástica ou recuperável do material que foi solicitado por cargas repetidas. A norma técnica DNIT 134/2010- ME – “Pavimentação - Solos Determinação do módulo de resiliência – Método de ensaio”, atualmente em vigor no Brasil, define ainda o módulo de resiliência como a relação entre a tensão-desvio (σ_d) aplicada repetidamente em uma amostra de solo e a correspondente deformação específica vertical recuperável ou resiliente (ϵ_r) como apresenta a Equação 7.

$$MR = \frac{\sigma_d}{\epsilon_r} \quad (7)$$

Ressalta-se que os materiais de pavimentação não são elásticos, sendo o uso da teoria da elasticidade uma aproximação. Apesar de dependente do tempo e da história de tensões, o comportamento de alguns materiais de pavimentação pode ser aproximado como elástico não-linear (BERNUCCI *et al*, 2006).

Na determinação do módulo de resiliência apenas a parcela da deformação recuperável é considerada (ϵ_e), mas como se observa na Figura 7, ocorrem também deformações plásticas quando se realiza o ensaio de módulo de resiliência. O ensaio é realizado com corpos-de-prova não saturados, geralmente em condições de drenagem livre (SOUZA JÚNIOR, 2011). A Figura 7 apresenta as deformações durante um ensaio de cargas repetidas.

Figura 7 - Deformações verificadas em ensaios de cargas repetidas



Fonte: HUANG, 1933 *apud* SOUZA JÚNIOR, 2011

O método da resiliência é aceito internacionalmente para caracterizar materiais para o projeto de pavimentos e para sua avaliação de desempenho. Há técnicas disponíveis para estimar o módulo de resiliência em campo com testes rápidos e não-destrutivos, como o geogauge (BERNUCCI *et al*, 2006).

2.5 Variáveis Predictoras

Os estudos de mapeamento de solos mostram indícios de possíveis variáveis capazes de estimar características geotécnicas. A Tabela 4 apresenta 15 variáveis que poderão ser utilizadas neste estudo, sua abreviatura, significado físico e unidade do atributo.

Tabela 4 - Variáveis Predictoras

Variáveis Predictoras	Abreviatura	Unidade	Significado Físico
Pedologia	PED	Adm	Estudos da caracterização, gênese e classificação dos solos
Geomorfologia	GEM	Adm	Formas do relevo terrestre
Geologia	GEO	Adm	Formação dos solos
Vegetação	VEG	Adm	Cobertura vegetal e uso do solo
Elevação	ELEV	Metros	Altitude da região. Influencia variáveis meteorológicas como precipitação e temperatura
Declividade	DECL	Graus	Inclinação do terreno. Afeta a velocidade de fluxos superficiais e subsuperficiais, e influencia no conteúdo de água no solo, no potencial de erosão e na formação do solo
Orientação das Vertentes	OV	Graus	Direção da variação de declividade
Iluminação	ILUM	Adm	Representa diferentes exposições da paisagem a energia solar, refletindo em

			condições ambientais distintas
Plano de Curvatura	PLC	Metros ⁻¹	Indica a concentração ou dispersão da água sob o relevo, assim como, as posições de topo e depressão na paisagem
Perfil de Curvatura	PFC	Metros ⁻¹	Importante para a velocidade da água, e processos de transporte de sedimento. Irá indicar as superfícies côncavas e convexas na paisagem
Fluxo Acumulado	FA	Metros ²	Áreas de drenagem acumulada sobre uma superfície
Direção de Fluxo	DF	Graus	Direção de maior declividade
Comprimento do Fluxo	CF	Metros	Representa os comprimentos acumulados no percurso da drenagem (distância do pixel em questão ao exutório)
Norte	N	Metros	Posicionamento Geográfico da coordenada norte-sul
Este	E	Metros	Posicionamento Geográfico da coordenada leste-oeste

Fonte: Autoria Própria

2.6 Considerações Finais

Diversos são os trabalhos que vem utilizando com sucesso técnicas de Cartografia, Geoprocessamento, Inteligência Artificial e Estatística para realizar mapeamentos e modelagem de solos para diferentes aplicações nos campos da Geotecnia, Agronomia e Pavimentação.

Este estudo irá utilizar essas técnicas para modelar o comportamento geotécnico de interesse à pavimentação para a Microrregião de Mossoró, no estado do Rio Grande do Norte. O próximo capítulo apresentará como a metodologia empregada para a realização do presente trabalho.

3 MATERIAIS E MÉTODOS

3.1 Considerações Iniciais

Esta pesquisa foi motivada pelo uso de variáveis secundárias e disponíveis na rede de internet ou arquivada nos órgãos responsáveis (IBGE, MMA, CPRM, DNIT, DNER). O incremento desses atributos aliados a técnicas de geoprocessamento e modelagem estatística e neural pode ser de grande contribuição na geração de métodos de predição ou estimação de características geotécnicas do meio rodoviário.

3.2 Materiais

Os materiais utilizados para elaborar esta investigação são basicamente dados correspondentes a imagens em formato vetorial das variáveis biofísicas e em formato matricial das variáveis geomorfométricas. Usou-se ainda dados geotécnicos, advindos de projetos rodoviários, geograficamente espacializados e aplicativos computacionais, os quais serão descritos a seguir.

Para realização de todas as operações espaciais de georreferenciamento, população do banco de dados, cruzamento de informações, produção de mapas, dentre outras foram utilizados os seguintes aplicativos computacionais: Excel, Civil 3D e ArcGIS. O Excel foi utilizado ainda na etapa de pré-processamento dos dados, anterior à modelagem neural, assim como para a análise de resultados após a obtenção das estimativas neurais. O MATLAB foi utilizado para o treinamento e teste nas redes neurais. O SIG Whitebox GAT foi utilizado para extração dos atributos geomorfométricos. Para os resultados estatísticos de regressão foi usado o *software* SPSS.

3.2.1 Arcgis

O Arcgis, desenvolvido pela ESRI (*Environmental Systems Research Institute*), é um Sistema de Informações Geográficas que combina os procedimentos de visualização, exploração e análise de informação espacial. Atualmente é o principal SIG

do mercado mundial, possuindo uma variedade de recursos para manipulação dos mais variados dados geograficamente posicionáveis. Para esta investigação utilizou-se a versão 10.1 do ArcGIS, disponível no LAG/UFC (Laboratório de Geomática Aplicada), bem como suas extensões para análise espacial. Neste trabalho o ArcGIS foi utilizado para gerar mapas temáticos, manipular os dados espaciais e para a álgebra de mapas.

3.2.2 Autodesk Civil 3D

O Autodesk Civil 3D 2010, desenvolvido pela Autodesk, e disponível no GTTEMA (Grupo de Pesquisa em Transporte, Trânsito e Meio Ambiente) da UFC (Universidade Federal do Ceará), é um sistema CAD (Desenho Assistido por Computador). É um *software* de documentação e projeto de Engenharia, usado para fazer análise geoespacial, identificar a melhor localização para projetos, definir traçado, localizar pontos de estudos, realizar cálculos dinâmicos de trabalhos de terraplanagem, bem como de visualização em 3D para melhor compreender os impactos do projeto no meio ambiente. Nesta proposta metodológica este programa foi utilizado para espacializar pontos oriundos do estaqueamento dos estudos geotécnicos previamente realizados para projeto e construção de rodovias existentes na área de estudo.

3.2.3 Whitebox GAT

O Whitebox *Geospatial Analysis Tools* (GAT) é um sistema de informação geográfica e pacote de *software* de sensoriamento remoto desenvolvido pelo Centro de Pesquisas do Departamento de Geografia da Universidade de Guelph (Canadá) que destina-se a análise geoespacial avançada e visualização de dados em ambientes de pesquisa. Ele foi escolhido para este trabalho por oferecer uma interface gráfica de fácil manuseio, e ainda possuir a filosofia de *software* livre. Utilizou-se a versão 3.3 por ser a mais atualizada e disponível. O programa foi aplicado com o intuito de extrair os atributos geomorfométricos.

3.2.4 *Microsoft Excel*

O MS-Excel 2010® é um software desenvolvido pela Microsoft® para a elaboração de planilhas eletrônicas e que possui recursos para cálculo de funções matemáticas básicas e avançadas, cálculos financeiros e estatísticos. Nesta investigação, ele foi utilizado para importar ao SIG dados geotécnicos com coordenadas conhecidas, no pré-processamento dos dados para a modelagem, onde os dados foram organizados em tabelas, além da análise dos dados após a saída da rede neural adotada.

3.2.5 *MATLAB*

O MATLAB (MATrix LABoratory) 2009 desenvolvido pela Mathworks, e disponível no GTTMA da UFC, é um software interativo de alto desempenho voltado para o cálculo numérico, que integra análise numérica, cálculo com matrizes, processamento de sinais e construção de gráficos em ambiente fácil de usar. O MATLAB é um sistema cujo elemento básico de informação é uma matriz que não requer dimensionamento. Esse sistema permite a resolução de muitos problemas numéricos em apenas uma fração do tempo. Além disso, os problemas e soluções são expressos apenas como eles são escritos matematicamente, ao contrário da programação tradicional.

Esse aplicativo foi utilizado para o treinamento da proposta de RNA deste trabalho, o mesmo foi escolhido por possuir uma interface gráfica de treinamento de redes neurais artificiais. Essa interface deixa transparecer também seu código fonte, o que permite a implementação de outros recursos nesta mesma ferramenta. Além disso, o MATLAB é capaz de suportar os mais diversos tipos de algoritmos de treinamento de redes neurais, o que permite a execução de uma extensa árvore de testes na tentativa de se definir o modelo neural (topologia, algoritmo e parâmetros) mais adequado.

3.2.6 SPSS

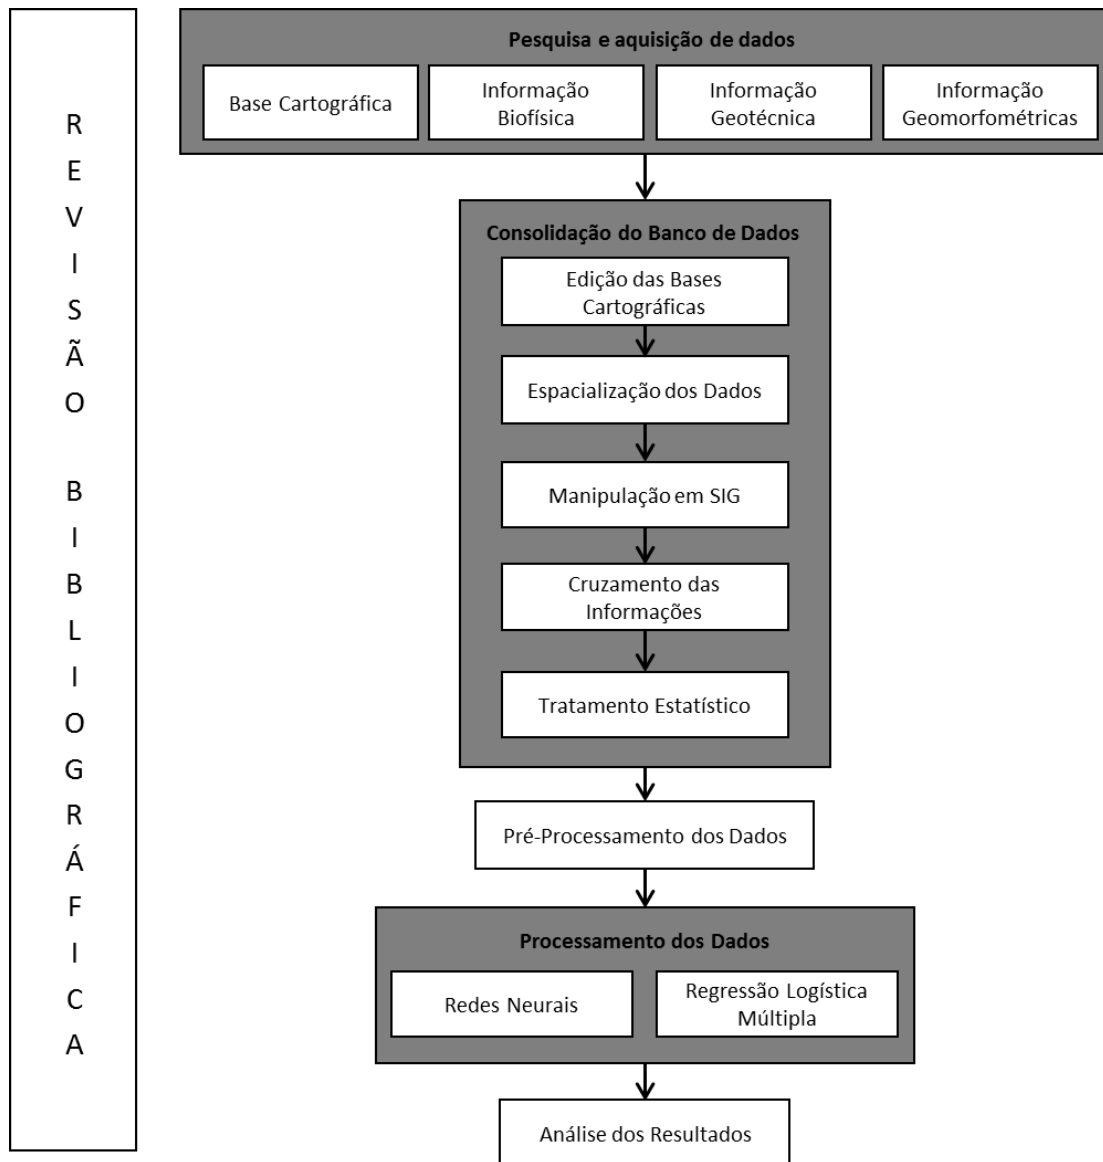
O *Statistical Package for Social Sciences* (SPSS) é um software estatístico que permite executar cálculos estatísticos complexos e visualizar, em poucos segundos, os resultados. Esta aplicação torna a análise estatística de dados acessível para o utilizador casual e conveniente para o utilizador mais experiente (PEREIRA, 2006).

O SPSS é utilizado pelas mais diversas áreas científicas: Saúde, Ciências Sociais e Humanas, Educação, Tecnologias, Direito e Economia. A maior vantagem de se utilizar um programa como o SPSS consiste em poder analisar dados quantitativos de muitas formas diferentes e bastante rápido, a partir do momento em que se adquire domínio sobre o programa. Este aplicativo é apropriado para elaboração de análise estatística de matrizes de dados. Permite gerar relatórios tabulados, gráficos e dispersões de distribuições utilizadas na realização de análises descritivas e de correlação entre variáveis.

3.3 Método

A metodologia adotada neste trabalho está resumidamente apresentada no fluxograma da Figura 8 que ilustra as etapas metodológicas aqui adotadas.

Figura 8 - Fluxograma do Método Proposto



Fonte: Autoria própria

3.3.1 Pesquisa e Aquisição dos Dados

Esta etapa consistiu na investigação e seleção dos dados (base cartográfica, informações biofísica, geomorfométricas e geotécnicas) que irão alimentar o banco de dados. Para isso foram realizadas pesquisas junto às instituições detentoras (IBGE, MMA, CPRM, DNIT, DNER) das informações gerais da área em questão (a microrregião de Mossoró/RN), tais órgãos estão especificados mais a frente. Nestas pesquisas obteve-se parte das informações em meio digital e parte analógico (impresso).

3.3.1.1 Base Cartográfica e Infraestrutura viária

Através do endereço eletrônico do IBGE (Instituto Brasileiro de Geografia e Estatística) obteve-se a base cartográfica do Estado do Rio Grande do Norte, em formato vetorial (*shapefile*), onde, em ambiente SIG, foi possível delimitar a área requerida por meio da ferramenta *clip* do Arc Toolbox do Arcgis. A infraestrutura viária foi oriunda do DNIT (Departamento Nacional de Infraestrutura de Transportes), em grandeza nacional, e por meio da mesma ferramenta de corte obtiveram-se as vias da região de estudos.

3.3.1.2 Informações Geotécnicas

As informações geotécnicas foram adquiridas através dos estudos geotécnicos dos Projetos Rodoviários do DNIT, DER-RN (Departamento de Edificações, Rodovias e Transportes do Rio Grande do Norte) e de algumas empresas privadas. Tais informações correspondem às características a serem previstas como CBR, classificação AASHTO e umidade ótimas referentes aos pontos de subleitos e de jazidas de empréstimos que representam o solo natural.

3.3.1.3 Variáveis Biofísicas

Para obtenção dos mapas temáticos necessários, realizaram-se pesquisas junto às instituições detentoras das informações gerais da área em questão, os órgãos foram: CPRM (Companhia de Pesquisa de Recursos Minerais), MMA (Ministério do Meio Ambiente), IBAMA (Instituto Brasileiro do Meio Ambiente) e EMBRAPA (Empresa Brasileira de Pesquisas Agropecuárias). As informações biofísicas (Pedologia, Geologia, Vegetação, Geomorfologia) da área estudada foram adquiridas em formato digital, porém estas foram em escala estadual. Para facilitar a visualização da área de interesse, a mesma foi delimitada através do ArcGIS utilizando a operação espacial *clip*, que corta a área desejada a partir de um vetor, reduzindo os arquivos aos limites da área de estudo.

3.3.1.4 Variáveis Geomorfométricas

Para a derivação dos atributos do terreno a serem utilizadas no estudo foi utilizado o MDE (Modelo Digital de Elevação) oriundo da técnica de Sensoriamento Remoto por Radar. As informações do SRTM (*Shuttle Radar Topography Mission*) foram baixadas na resolução de 30m do sítio na internet <http://earthexplorer.usgs.gov>. A variável representando a elevação foi extraída diretamente do Modelo Digital de Elevação (MDE). As demais informações foram derivadas do MDE pelo aplicativo WhiteBoxGAT. O Modelo Digital de Elevação também foi obtido em cartas geográficas mais abrangentes, onde o limite territorial da área de estudo foi delimitada também pela ferramenta “clip” do Arcgis.

3.3.2 Consolidação do Banco de Dados

3.3.2.1 Edição das Bases Cartográficas

As informações biofísicas (Pedologia, Geologia, Vegetação, Geomorfologia e Climatologia) e Rodovias da área estudada foram adquiridas em formato digital, porém estas foram obtidas para todo o estado. Para facilitar o trabalho, a área de interesse foi delimitada através do ArcGIS utilizando a operação espacial “clip” que corta a área desejada a partir de um vetor, reduzindo os arquivos aos limites da área de estudo. Os atributos geomorfométricos forma obtidos em cartas cartográficas que abrangem uma região além da área de estudo. Como essas cartas foram obtidas em formato raster, utilizou-se também no ArcGis a função *Extraction byMask* para recorte da área requerida.

3.3.2.2 Espacialização dos Dados

A espacialização dos dados foram em relação aos pontos geotécnicos adquiridos. Os estudos geotécnicos foram adquiridos em formato analógico ou digital. Alguns projetos dispunham das coordenadas geográficas de cada ponto estudado, nesse caso foi construída uma planilha através do Excel com as coordenadas e as informações

referentes, e em seguida exportada para o Arcgis. Outros projetos geotécnicos não possuíam um georreferenciamento dos pontos, mas possuíam uma referência das estacas em relação ao eixo estradal. Nesses casos foi executado, a partir do software Autodesk Civil 3D, o estaqueamento das rodovias, podendo assim obter as coordenadas associadas a cada ponto, que na sequência foram exportados para o ambiente SIG onde foram inseridas as características geotécnicas atribuídas a cada ponto, pela tabela de atributos, consolidando-se assim um banco de dados geotécnicos georreferenciado, composto por 1630 pontos advindos de 10 projetos rodoviários.

3.3.2.3 Manipulação dos Dados Espaciais em SIG

Os dados espaciais obtidos foram adquiridos em diversos formatos, sendo necessário realizar uma manipulação para promover a uniformização, de modo que todos os dados tivessem o mesmo formato, mesmo sistema de coordenadas, mesmo sistema de referência e restritos à área de estudo, neste caso, o limite da Microrregião de Mossoró. Todos os dados, gerados como descrito acima, foram exportados como pontos em formato vetorial (*shapefile*), padrão do ArcGIS, onde foram alocados para o sistema referência SAD 69 (*South American Datum 1969*), sistema de projeção cartográfica UTM (*Universal Transversa de Mercator*), Fuso UTM 24 Sul.

3.3.2.4 Cruzamento das Informações

Esta etapa refere-se à manipulação das representações cujo domínio é comum, ou seja, os planos de informação compreendem a mesma região geográfica. Como o presente trabalho trata da determinação de um modelo para a predição de prováveis classes de solo em uma região geográfica, o projeto envolve a realização de uma sequência de operações algébricas com os diversos planos de informação, essas operações são realizadas com recursos acessados através de um SIG.

Após a uniformização cartográfica dos dados, foram selecionados os mapas Biofísicos (Pedologia, Geologia, Vegetação, Geomorfologia), os Mapas Geomofométricos (Elevação, declividade, aspecto, iluminação, plano de curvatura, perfil de curvatura, direção de fluxo, acumulação e comprimento de fluxo) e a base Cartográfica Geotécnica. Esses mapas foram cruzados com a finalidade de cada ponto

com classificação geotécnica estivesse associado espacialmente às variáveis biofísicas e geomorfológicas. Para execução dessa operação utilizou-se a função “*SpatialJoin*” do ArcGIS, que cruzou os dados e formou uma única camada raster que contém todas as informações necessárias para a modelagem. Posteriormente, estes arquivos em formato matricial foram transformados em formato .xlsx para serem pré-processados no Excel.

3.3.2.5 Tratamento Estatístico dos Dados

Nesta etapa foi realizada amostragem espacial dos pontos em relação à área de estudo, com intuito de verificar sua representatividade, bem como sua distribuição qualitativa. Também foi analisada estatisticamente a correlação entre as variáveis, com a finalidade de filtrar, dentre as disponíveis, quais as variáveis biofísicas devem ser usadas na modelagem proposta.

3.3.3 *Pré-processamento dos Dados*

Nesta etapa os dados em formato .xlsx oriundos do cruzamento espacial das informações biofísicas e geomorfológicas com a classificação geotécnica dos pontos, foram submetidos a um pré-processamento para se adequar às restrições impostas pela modelagem. O pré-processamento dos dados foi dividido em três partes descritas a seguir:

- a) Numerização dos dados: a numerização consistiu em atribuir um valor decimal aos dados que tinham valores alfanuméricos.
- b) Dummyzação: essa etapa consistiu em organizar os dados de saída da rede neural de maneira que as informações numéricas passassem a corresponder aos valores 0 e 1. Isso foi necessário para a modelagem da classificação AASHTO. A Tabela 5 apresenta um exemplo do pré-processamento com variáveis *Dummy* (Dummyzação).

Tabela 5 - Exemplo de pré-processamento realizado.

Dados Nominais	Numerizado	Dummy
A (a1, a2, a3)	A (1, 2, 3)	A(001, 010, 100)
B (b1, b2, b3, b4)	B (1, 2, 3, 4)	B(0001, 0010, 0100, 1000)
C (c1, c2, c3, c4, c5)	C (1, 2, 3, 4, 5)	C(00001, 00010, 00100, 01000, 10000)

c) Normalização dos dados: a normalização consistiu em transformar os valores decimais para valores compreendidos entre 0 e 1 e -1 a 1, a primeira para a função logarítmica e a outra para a função tangente. Para isso foi utilizada a Equação 8:

$$y = \frac{(x - x_{min})(d_2 - d_1)}{(x_{max} - x_{min})} + d_1 \quad (8)$$

Onde:

y = Valor normalizado;

x = Valor a ser normalizado;

[x_{máx} , x_{min}] = variação do valor de x

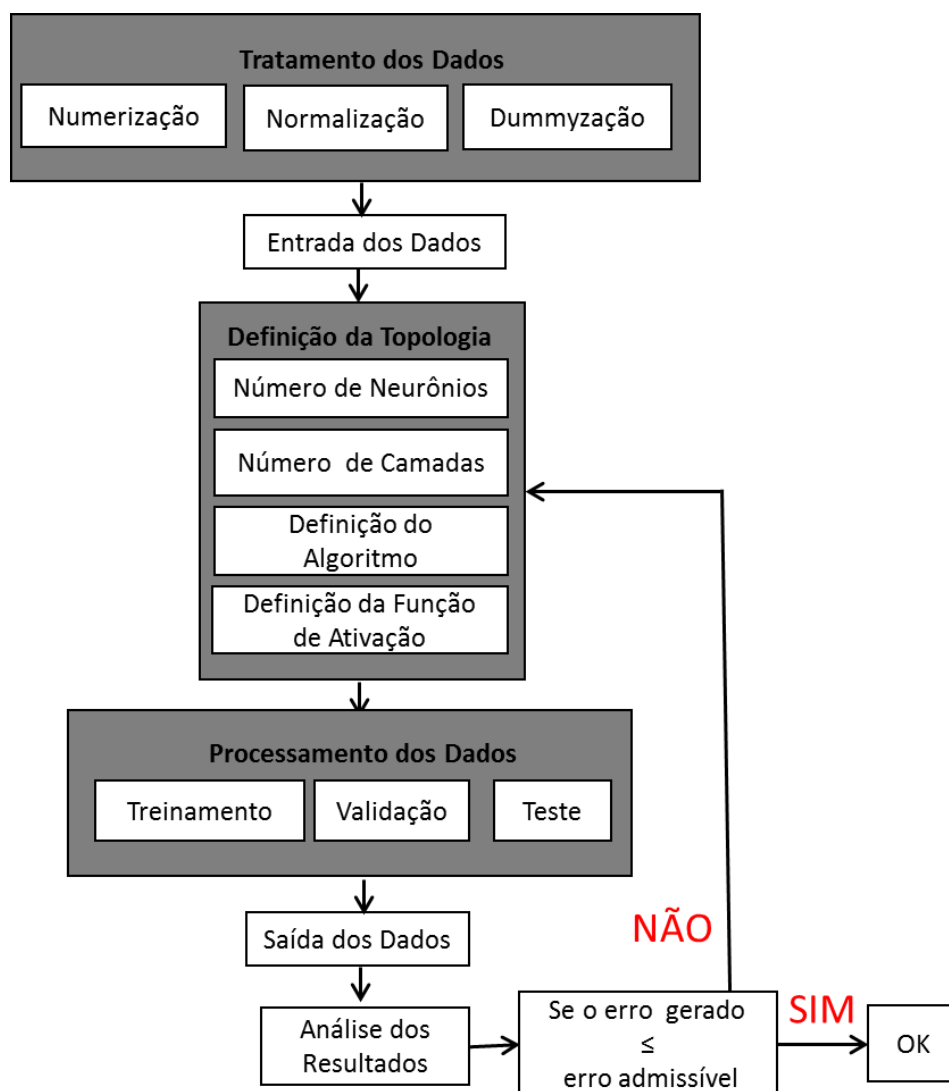
[d₂ , d₁] = limite ao qual o valor x será reduzido

3.3.4 Processamento dos Dados

3.3.4.1 Modelagem Neural

O procedimento a ser executado para se alcançar um modelo neural deve ser seguido pelos seguintes passos determinados pelo Fluxograma da Figura 9.

Figura 9 - Fluxograma da Modelagem Neural



Fonte: Autoria própria

Os dados de entrada no programa em questão devem ser tratados de modo que as variáveis nominais sejam representadas por números, e ainda sejam normalizadas. As variáveis de saída que for categórica devem ser dummyzadas de maneira a garantir um saída que permita prever as chances de ocorrência de cada grupo.

Após a definição dos conjuntos de dados, foi realizado o treinamento das RNAs, que consiste em “ensinar” a rede a resolver um conjunto de padrões de saídas associados aos dados de entrada. Com a finalidade de encontrar a melhor topologia que se ajustasse ao fenômeno estudado, pretende-se testar diversos algoritmos, assim como realizar variação de seus parâmetros: número de camadas intermediárias, quantidade de

neurônios em cada camada, taxa de aprendizagem, número de épocas de treinamento e outros. Assim, será elaborada uma árvore de testes que nada mais é que desenvolver uma bateria de testes no NNTOOL (Neural Network Tool) buscando encontrar uma arquitetura mais adequada para o problema em questão, ou seja, aquela na qual os erros dos estimados para o conjunto de testes seja menor quando comparado aos valores reais.

O processamento de dados em uma Rede Neural Artificial é resumido em três fases, treinamento, validação e teste. Para isso, RIBEIRO *et al.* (2010) recomenda utilizar um módulo de ferramentas denominado *Toolboxes*, e dentro dele, mais especificamente o *Neural Network Tool*, ou simplesmente *NNTOOL* que é uma interface gráfica que possibilita a construção de diferentes topologias, com variações de algoritmos e parâmetros de treinamento de RNAs no aplicativo MatLab.

Os dados disponíveis para realizar a modelagem devem ser divididos em três conjuntos, como ditos anteriormente, sendo 70% utilizado para treinamento, 15% para validação e 15% para teste. Esses conjuntos de dados devem ser ainda selecionados aleatoriamente e sem repetição. Os dados de entrada da rede são as variáveis biofísicas: Pedologia, Geologia, Vegetação e Geomorfologia, as variáveis Geomorfométricas: Elevação, Declividade, Iluminação, Aspecto, Plano de curvatura e perfil de curvatura, e ainda as coordenadas Este e Norte, e os possíveis dados de saída da rede são: classificação geotécnica AASHTO, CBR, umidade ótima e massa específica aparente seca máxima.

Os parâmetros envolvidos em um algoritmo de RNA permitem uma grande variação nas possibilidades de treinamento. Assim, torna-se quase inviável testar todas as possibilidades com variações diferentes nos parâmetros. Então, para este trabalho espera-se realizar um conjunto de variações até chegar aos parâmetros que melhor se adaptem aos dados, ou seja, os parâmetros que possibilitaram uma taxa de acerto maior.

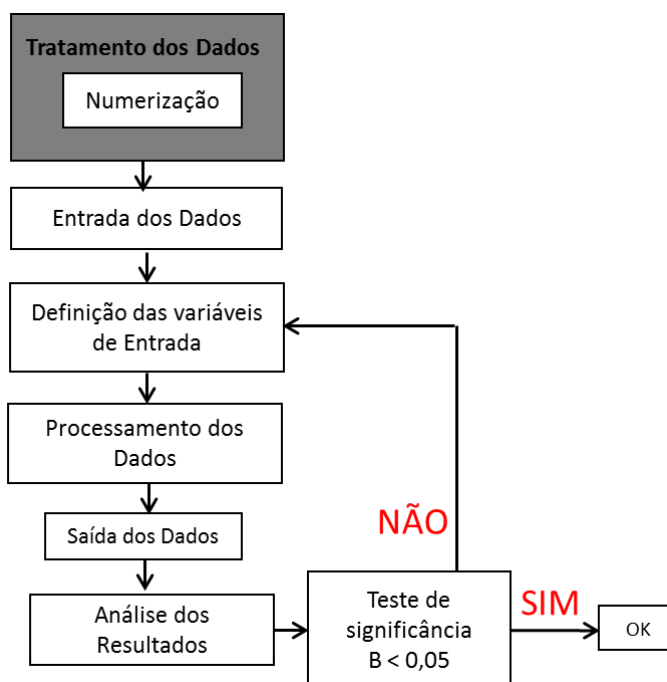
3.3.4.2 Modelagem com Regressão

A execução da análise estatística, isto é, a determinação dos parâmetros desconhecidos α , β_i da Equação 5, pode ser efetuada em qualquer pacote estatístico

tradicional, como o SPSS, SAS, WEKA, Statistica, etc. Pela disponibilidade, optou-se por utilizar neste estudo para a realização dos procedimentos de Regressão Logística Multipla Multinomial o SPSS (*StatisticalPackage for Social Sciences*).

Assim como nas RNAs, também aqui será realizada uma série de modelos de regressão, onde serão adicionadas ou retiradas algumas variáveis predictoras do modelo, a fim de se obter um modelo com uma melhor significância. O procedimento a ser seguido nessa etapa mostra-se resumidamente na Figura 10.

Figura 10 - Fluxograma da Modelagem Estatística



Fonte: Autoria própria

3.3.5 Análise dos Resultados

Compreende a última fase metodológica, na qual após as modelagens executadas será feita uma análise comparativa a fim de se obter o modelo mais adequado, tanto quanto à eficiência quanto pela praticidade. Os resultados obtidos pela RNA e pela RLM serão exportados para o Excel, desnormalizados e desnumerizados, caso necessite, para assim realizar-se a análise dos resultados, através da acurácia dos diferentes modelos. Foi considerado o cálculo das taxas de acerto e da geração de gráficos comparativos entre as saídas reais e as saídas estimadas nos modelos

produzidos pelas diferentes técnicas de modelagem, qual sejam, RNA e RLM, com dados inéditos para validação dos modelos.

3.4 Considerações Finais

A metodologia apresentada neste capítulo deve ser aplicada para a criação de modelos de previsão de parâmetros geotécnicos de interesse a pavimentação com estimativas de CBR e Classificação AASHTO.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

4.1 Considerações Iniciais

Atualmente as pesquisas relacionadas ao mapeamento dos solos estão sendo direcionadas para o estudo de novas técnicas que se baseiam nos conhecimentos disponíveis em sistemas de informações geográficas, sensoriamento remoto, geoestatística, entre outros, visando melhorias no processo de reconhecimento e mapeamento dos solos (CHAGAS, 2006).

A proposta deste estudo refere-se a avaliar a eficiência da utilização de atributos do terreno, derivados de um modelo digital de elevação (MDE), variáveis biofísicas e estudo geotécnico, aliados aos usos de ferramentas como Redes Neurais e Regressões Logística Múltipla de modo a obter modelos de levantamento de solos com fins de pavimentação. Embora a abordagem da investigação vise o uso de novas tecnologias, os modelos a serem gerados fundamentam-se na equação dos fatores de formação do solo, onde uma vez conhecida as relações entre solos e seus respectivos ambientes, seja possível inferir os solos de uma determinada área.

4.2 Caracterização da Microrregião de Mossoró

4.2.1 Localização

De acordo com o Instituto de Desenvolvimento Sustentável e Meio Ambiente do Rio Grande do Norte (IDEMA), o Estado do Rio Grande do Norte localiza-se na esquina do continente sul-americano, ocupando posição privilegiada em termos de localização estratégica, pois se trata do Estado brasileiro que fica mais próximo dos continentes africano e europeu. Com uma extensão de 53.077,3 km², o Estado ocupa 3,41% de área da Região Nordeste e cerca de 0,62% do território nacional. Limita-se com o Estado do Ceará a Oeste, ao Sul com o Estado da Paraíba, e a Leste e ao Norte com o Oceano Atlântico. Além disso, está localizado perto de capitais importantes dos Estados do Nordeste, como Pernambuco, Ceará e Paraíba.

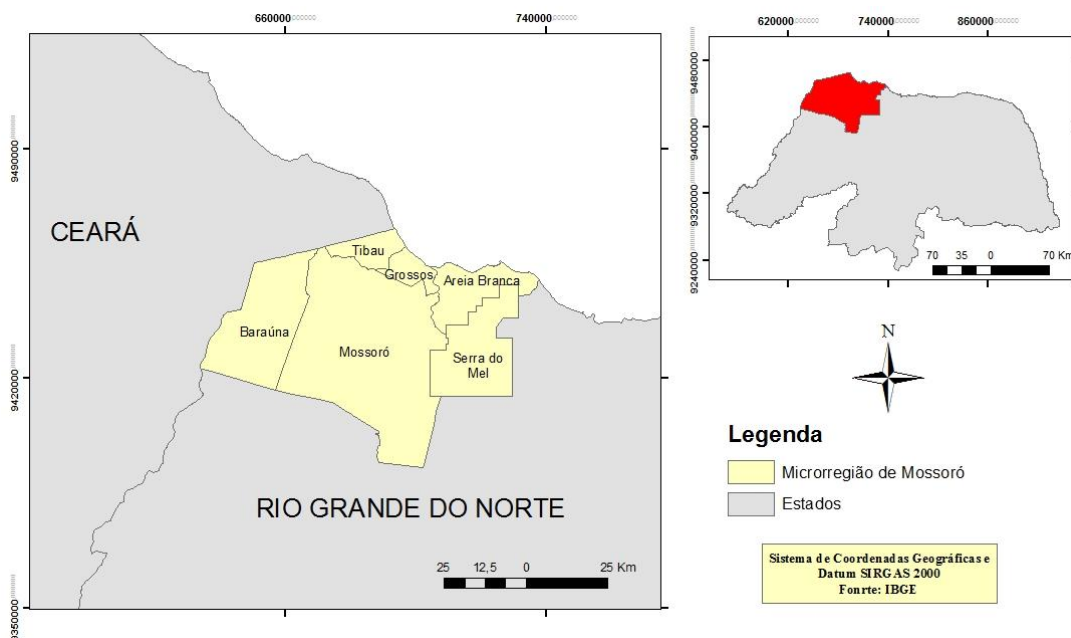
Mesmo tratando-se de um espaço relativamente pequeno, se comparado a outros Estados brasileiros, o Estado apresenta variada e complexa diversidade regional que

pode ser agrupada através de critérios como as diferentes paisagens do seu quadro natural, da sua economia e até mesmo os interesses de órgãos públicos para a organização sistemática de suas ações sobre o território estadual.

Politicamente, o estado está dividido em 167 municípios. Ainda segundo o IDEMA no ano de 1970, o IBGE estabeleceu critérios para a divisão do Estado em 10 Microrregiões Homogêneas. Essa nova regionalização procurou agrupar em pequenas regiões os municípios que apresentavam semelhanças e certa homogeneidade não só no quadro natural, mas também do ponto de vista econômico. Uma delas é a Microrregião Salineira Norte-Riograndense que corresponde aos tradicionais municípios da região produtora de sal, como Mossoró, Areia Branca e Macau, estendendo-se desde Baraúna até Guamaré.

As regiões supracitadas foram divididas ainda de acordo com as características das potencialidades locais, onde se destaca dentre elas a Microrregião Mossoroense, formada pela união de seis municípios, Mossoró, Baraúna, Tibau, Grossos, Areia Branca e Serra do Mel. Conforme mostra na Figura 11.

Figura 11 - Delimitação da Microrregião Mossoroense



Fonte: Adaptada do IBGE, 2016

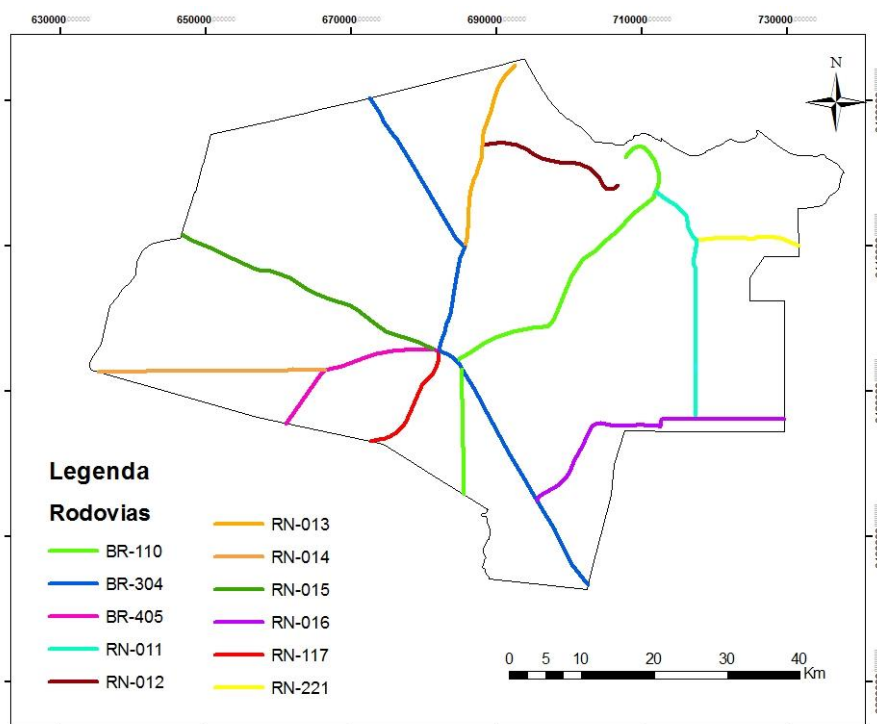
4.2.2 Condições Econômicas

A principal potencialidade do segmento Econômico da Microrregião de Mossoró (MM) é a Indústria, onde são produzidos principalmente: cimento, minerais metálicos, movelaria, indústria química, vestuário, calçados, tecidos, produtos alimentícios, rações, indústria mecânica, cerâmica fina e sal. Os principais produtos agrícolas da região são relacionados à fruticultura irrigada (melão, manga, melancia e caju), além de culturas alimentares como o milho e o feijão. Adicionalmente, ocorre ainda a caprino/ovinocultura, a apicultura e a pecuária leiteira e de corte. Os principais produtos ligados à atividade mineral são petróleo, gás, calcário e água mineral. O turismo também representa uma forte atividade desenvolvida na região (sol e mar, cultura, negócios e eventos).

4.2.3 Infraestrutura Rodoviária

As rodovias federais e estaduais na região estudada são em geral usadas para fins distintos, tais como: indústria, turismo, agricultura e acesso a localidades. O sistema rodoviário federal, dentro da Microrregião de Mossoró (MM), é realizado através da BR-110, BR-304 e a BR-405. As rodovias estaduais que cortam a MM são a RN-011, RN-012, RN-013, RN-014, RN-015, RN-016, RN-117 e a RN-221. A Figura 12 apresenta a malha rodoviária da MM elaborada pela autora do presente trabalho a partir do uso do Arcgis.

Figura 12 - Malha Rodoviária da Microrregião de Mossoró



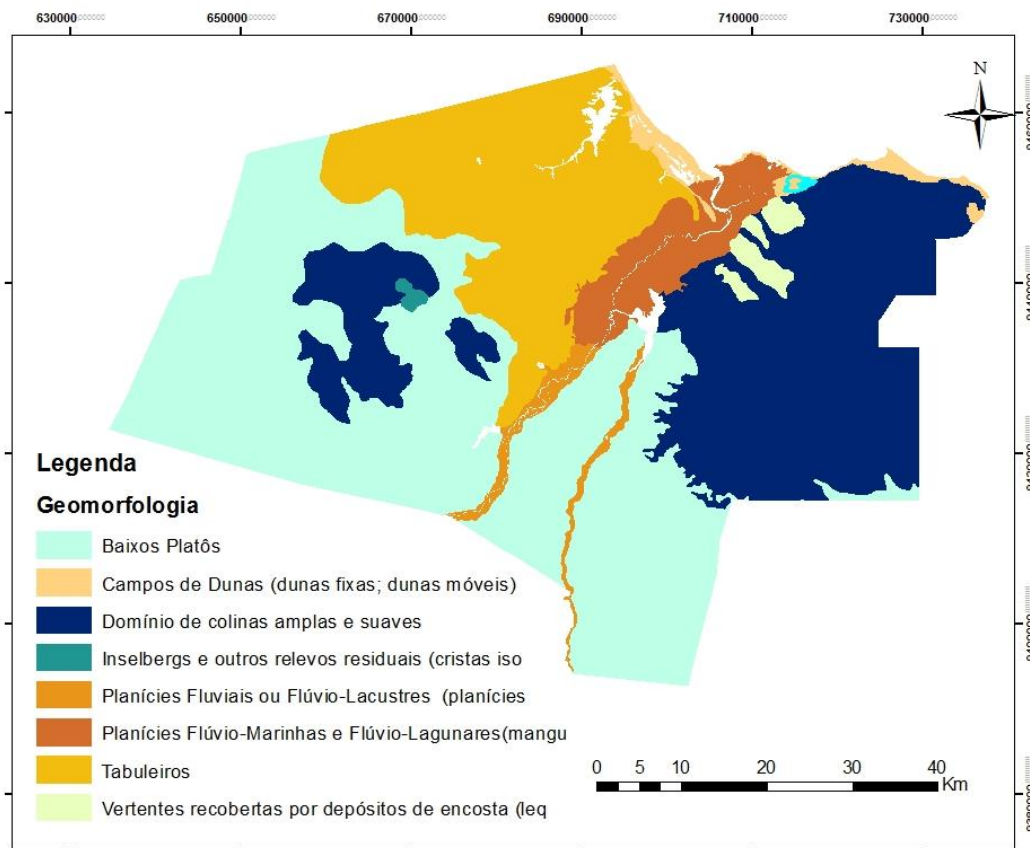
Fonte: Autoria própria

4.2.4 Características Físicas

A microrregião de Mossoró apresenta uma grande variedade de formas de relevo. A evolução do relevo desse território foi condicionada por um conjunto de fatores, tais como a estrutura geológica, a evolução morfoclimática e os processos atuais que interferiram na geomorfogênese, resultando em diversificada variedade de paisagens.

Para melhor ilustração do relevo da MM, elaborou-se a Figura 13 usando a ferramenta clip do Arcgis. Esta Figura mostra a geomorfologia da região de estudo, onde se observa a predominância de Baixos Platôs que consistem em relevos de degradação, com superfícies ligeiramente mais elevadas que os terrenos adjacentes. Essas rochas sedimentares, além de desenvolverem solos férteis, apresentam elevado potencial hidrogeológico, o que garante disponibilidade de água subterrânea abundante, armazenada em aquíferos confinados em região de escassez de água superficial. A região também representa uma unidade geotectônica com expressivas reservas de petróleo.

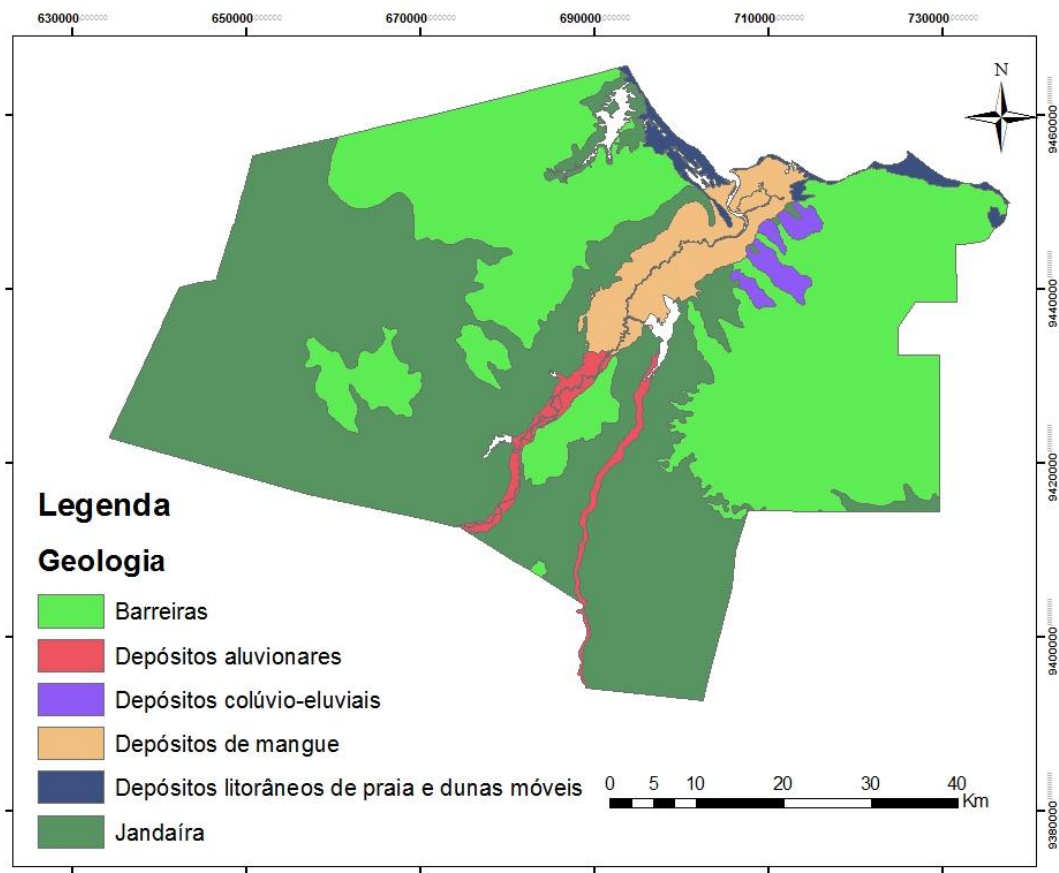
Figura 13 - Geomorfologia da Microrregião de Mossoró



Fonte: Autoria própria

O estudo da geologia associado a outras ciências torna-se preponderante para a explicação da formação dos solos. Sabe-se que um mesmo tipo de rocha, submetido a diferentes condições climáticas, pode originar solos diferentes e rochas diferentes, mas quando sujeitas às mesmas condições climáticas, podem originar solos idênticos. Para o presente estudo, elaborou-se a Figura 14 que ilustra a litologia da Microrregião de Mossoró, com auxílio do SIG de uso deste trabalho, o Arcgis. A Geologia (Figura 9) da Microrregião de Mossoró segundo a classificação Litológica compreende principalmente pela Formação Jandaíra e Barreiras, mas também há composições de depósitos aluvionares, depósitos colúvio-eluviais, depósitos de mangu e depósitos litorâneos.

Figura 14 - Geologia da Microrregião de Mossoró



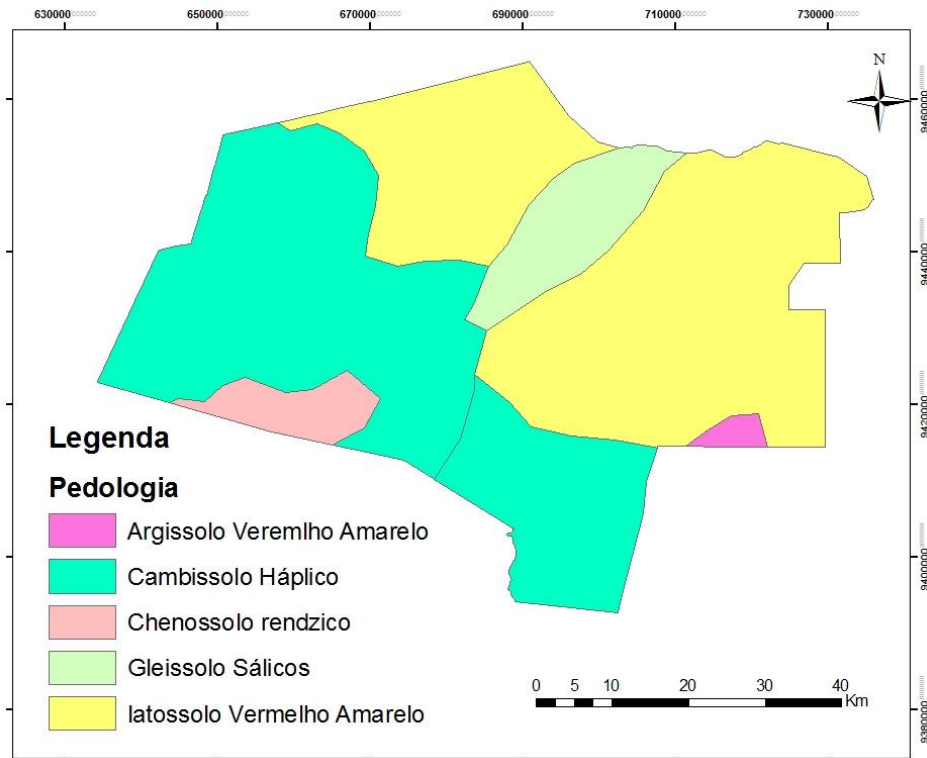
Fonte: Autoria própria

O estudo pedológico, ou seja, estudos de caracterização, gênese e classificação dos solos, é uma das maneiras mais eficientes de interpretar as informações de solo de qualquer limitação geográfica. O domínio do conhecimento, advindo da Pedologia, e o exercício da prática de se identificar e levantar pedologicamente o perfil de solo pode contribuir para a melhoria do entendimento do material em estudo e das previsões de comportamento destes solos para utilização em obras de engenharia. A utilização das informações da Pedologia através dos mapas pedológicos se mostra muito útil, por exemplo, no estudo geotécnico preliminar de obras viárias (GODOY e BERNUCCI, 2000 *apud* MARANGON, 2004). Sendo assim, a autora do presente trabalho também elaborou o mapa pedológico da Microrregião de Mossoró (ver Figura 15).

Na microrregião de Mossoró a diversidade pedológica é bem ampla, podendo-se encontrar solos que apresentam comportamentos pedológicos bem distintos, são estes:

Argissolo Vermelho Amarelo, Cambissolo Háptico, Chenossolo Rendzico, Gleissolo Sáfico e Latossolo Vermelho-Amarelo.

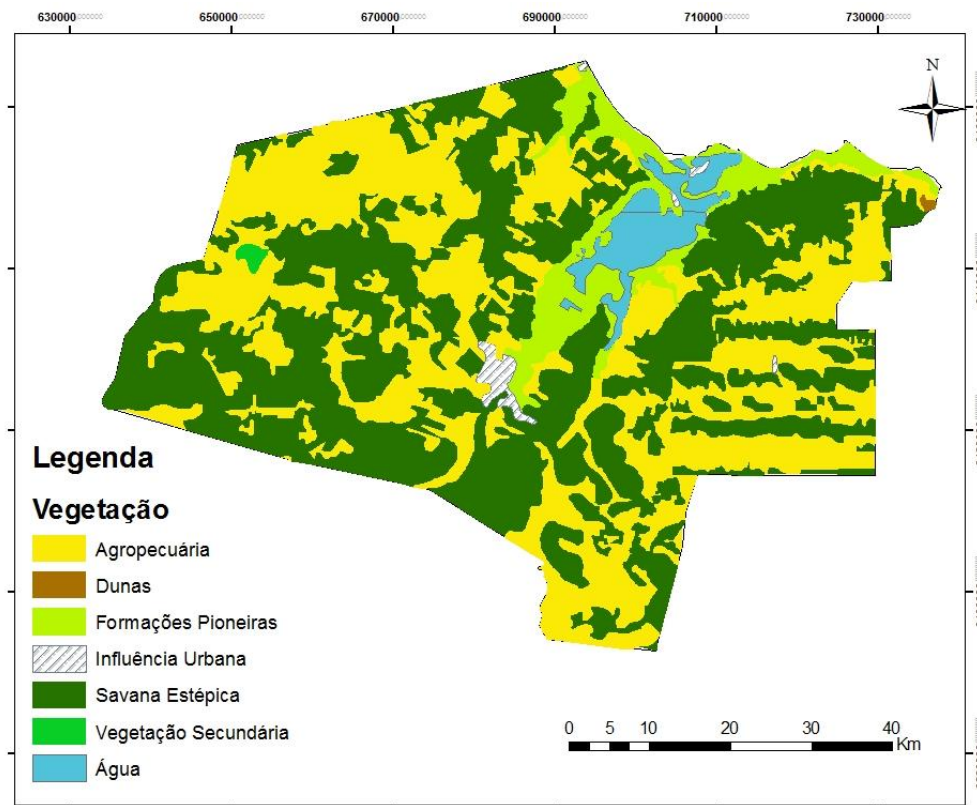
Figura 15 - Pedologia da Microrregião de Mossoró



Fonte: Autoria própria

No ano de 2006, o Ministério do Meio Ambiente (MMA) realizou um levantamento da cobertura vegetal e do uso do solo do bioma caatinga, através do PROBIO - Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira. A Microrregião de Mossoró por fazer parte do bioma caatinga, teve a vegetação do seu território totalmente caracterizada. Os estudos identificaram que sua paisagem vegetacional é composta por: Formação Pioneira, Formação Pioneira, Savana Estépica, Vegetação Secundária, Dunas e Áreas modificadas pela ação antrópica (Agropecuária e Influencia Urbana). A Figura 16 ilustra a vegetação que ocorre na MM

Figura 16 - Vegetação da Microrregião de Mossoró

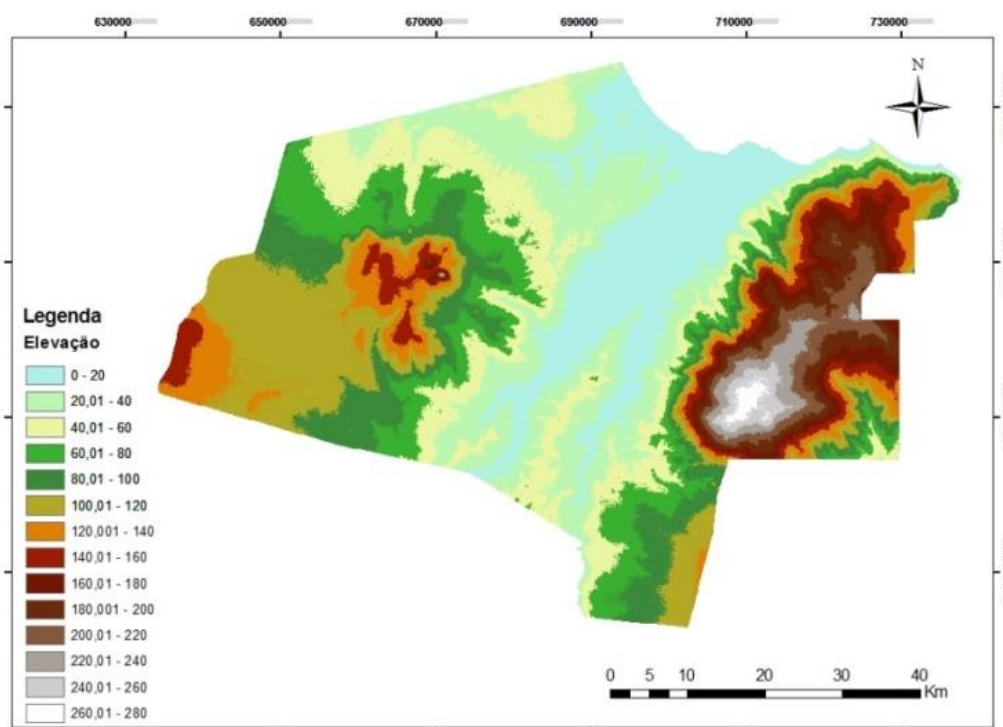


Fonte: Autoria própria

4.2.5 Características Geomorfológicas

O modelo digital de Elevação da Microrregião de Mossoró pode ser visto na Figura 17. A variável representando a elevação foi obtida diretamente do MDE/SRTM. Foi realizado o procedimento *FillSinks* (ArcGIS) para correção de informações espúrias (picos anômalos e pontos ou áreas com ausência de dados). A microrregião de Mossoró possui uma diferença de elevação de aproximadamente 280 m. Esta diferença pode estar condicionando variáveis meteorológicas como precipitação e temperatura, as quais por sua vez irão se refletir na alteração diferenciada do material de origem, e por consequência, na formação do solo.

Figura 17 - Distribuição espacial da elevação na região de estudo



Fonte: Autoria Própria

Para GALLANT & WILSON (2000), a declividade é um das características topográficas mais importantes no controle de processos pedológicos, pois influencia diretamente na velocidade do fluxo superficial e sub-superficial de água, logo, influencia no teor da água do solo e no potencial dos processos deposicionais. A declividade pode ser definida com a inclinação oriunda da diferença de elevação entre as células, representada no formato digital na resolução de uma grade regular. O plano de informação de declividade foi classificado de acordo com sua correspondência com o tipo de relevo proposto pela Sociedade Brasileira de Ciência do Solo e EMBRAPA Solos (2006), conforme especificado na Tabela 6.

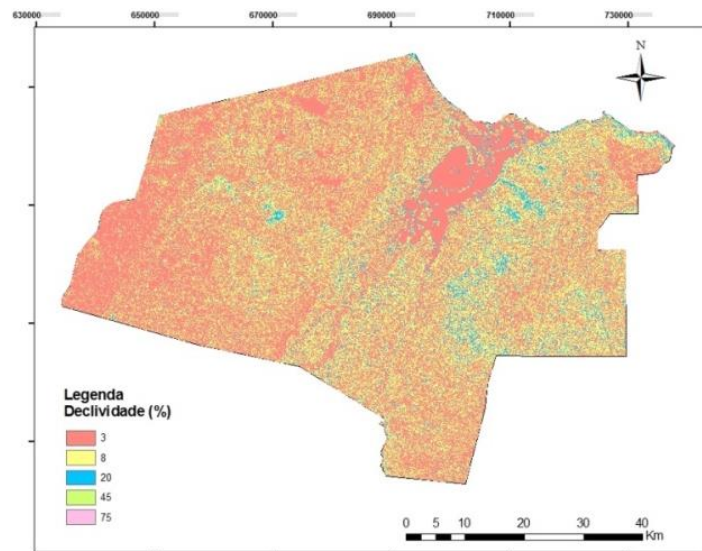
Tabela 6 - Correlação entre classes de declive e classes de relevo

Classes de Declive (%)	Classes de Relevo
0 – 3	Plano
3 – 8	Suave Ondulado
8 – 20	Ondulado
20 -45	Forte Ondulado
45 – 75	Montanhoso
> 75	Escarpado

Fonte: Sociedade Brasileira de Ciências do Solo e EMBRAPA Solos (2006)

Na Figura 18 estão representadas as classes de declividade e sua distribuição espacial na Microrregião de Mossoró. Quando comparadas as declividade e áreas ocupadas, pode-se concluir que a maior parte da área tem declividade entre 0 e 20%, mas o intervalo de 0 a 3% prevalece, podendo classificar a área como plana, de acordo com a classe de relevo.

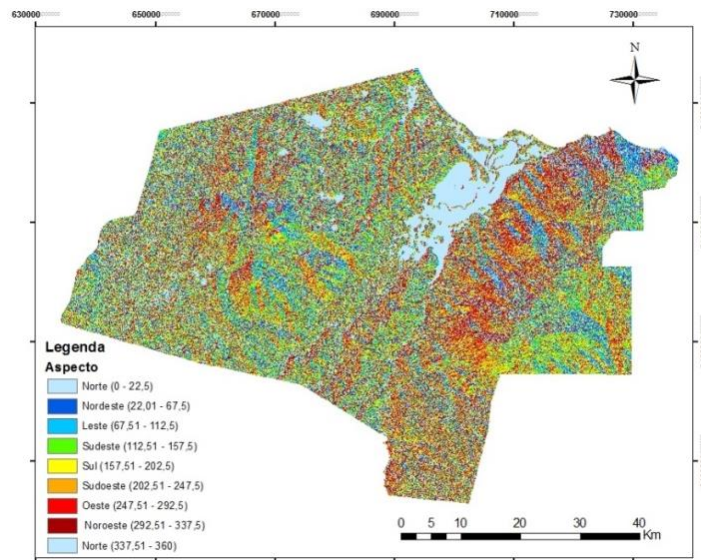
Figura 18 - Declividade da Microrregião de Mossoró



Fonte: Autoria própria

O aspecto ou orientação das vertentes identifica o sentido mais íngreme da declividade de cada célula e de sua vizinhança, ou seja o sentido da inclinação. É medido no sentido horário e em graus de 0 (exatamente norte) a 360°. O valor de cada célula em um conjunto indica o sentido da inclinação que a célula se encontra. Para MOORE *et al.* (1993), a orientação das vertentes tem relação direta com a evapotranspiração, insolação, teor de água no solo e, conseqüentemente, com os atributos do solo. A Figura 19 exibe uma imagem em formato raster do atributo aspecto para a área de estudo.

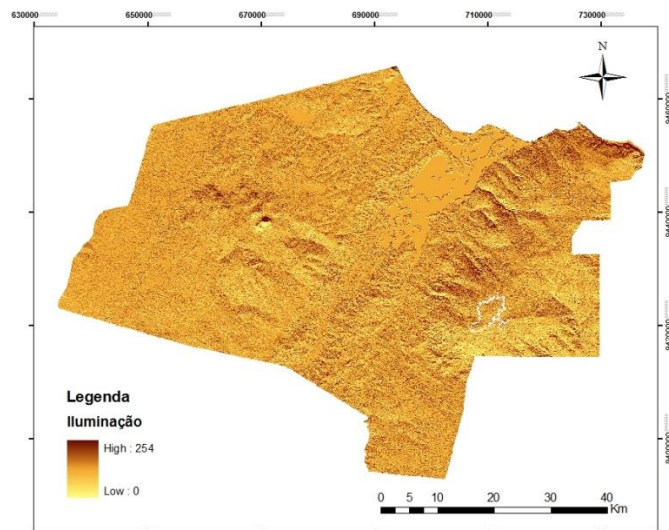
Figura 19 - Aspecto da Microrregião de Mossoró



Fonte: Autoria própria

A iluminação representa diferentes exposições da paisagem a energia solar, refletindo em condições ambientais distintas. A iluminação hipotética da superfície foi obtida pela função Hillshade no Arcgis, usando com dados de entrada o azimute, a altitude e o MDE, e gerando como saída um valor adimensional. Seguindo as recomendações de CATEN (2008) foi utilizado azimute de 0° e inclinação solar de 60°. O azimute é a direção angular do sol e a altitude é a inclinação ou ângulo de iluminação acima do horizonte. A distribuição espacial da iluminação da área estudada pode ser vista na Figura 20.


Figura 20 - Iluminação da Microrregião de Mossoró



Fonte: Autoria própria

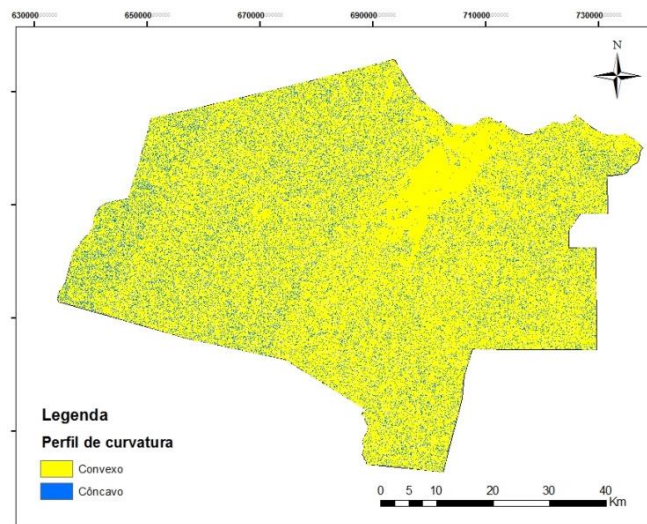
Para SIRTOLI (2008), o plano e o perfil de curvatura representam as formas do relevo, sendo importantes atributos na distinção de unidades pedológicas. O perfil de curvatura tem importância na aceleração ou desaceleração do fluxo de água em uma encosta, logo, tem influência direta na formação do solo. A classificação das vertentes em relação ao perfil é analisada de acordo com seu valor de curvatura e teoricamente, vertentes retilíneas têm valor de curvatura nulo, vertentes côncavas os têm positivos e convexas têm curvatura negativa (VALERIANO, 2003). Porém, vertentes com valores nulos são muito raras na natureza. A Figura 21 apresenta uma ilustração das três classes de vertentes analisadas em perfil e a Figura 22 ilustra a classificação do perfil de curvatura para a área de estudo.

Figura 21- Tipo de vertentes em relação ao perfil (a) retilínea, (b) convexa e (c) côncava



Fonte: Schmidt, 2004

Figura 22 - Perfil de Curvatura da Microrregião de Mossoró

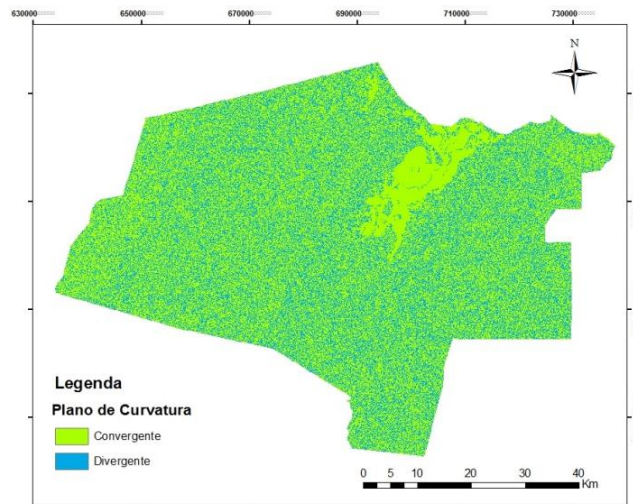


Fonte: Autoria própria

O plano de curvatura pode ser convergente, divergente ou reto e também tem influência na acumulação da umidade e do fluxo da água superficial e sub-superficial do terreno. A classificação da curvatura planar das vertentes, em ambiente SIG, é analisada

de acordo com o seu histograma de frequência que indica o valor da referida curvatura. Semelhante ao perfil, os valores nulos correspondem à inexistência de curvatura em vertentes planas. Já os valores positivos representam curvatura divergente e os valores negativos correspondem à curvatura convergente. A Figura 23 representa a classificação da curvatura planar para a região de estudo.

Figura 23 - Plano de Curvatura da Microrregião de Mossoró




Fonte: Autoria própria

A rede de drenagem mostra-se eficiente na determinação das classes pedológica. Para este estudo foram extraídos alguns atributos que contribuem para a drenagem da região a fim de observar os efeitos na modelagem espacial de solos para pavimentação.

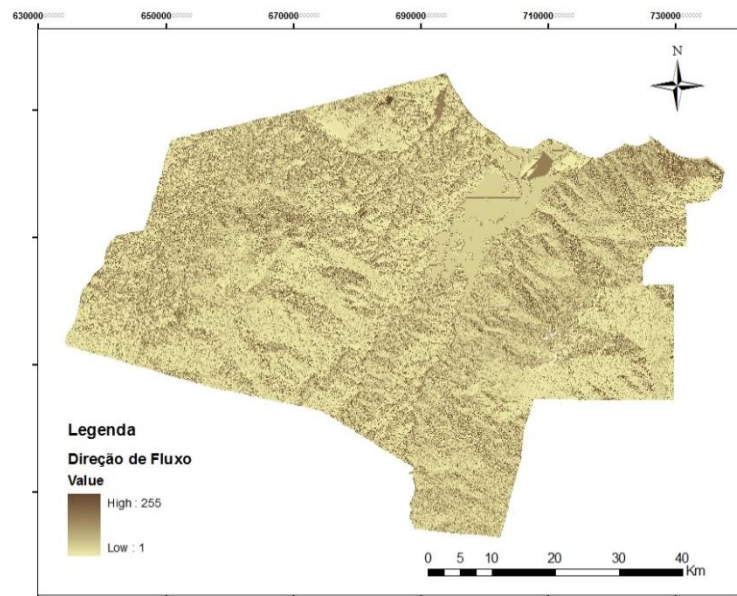
A direção do fluxo de escoamento considera uma única direção do fluxo para cada pixel do MDE, sendo essa atribuída para um de seus oito vizinhos. A determinação da direção do fluxo é realizada a partir da escolha da direção que proporcione a maior declividade, calculada como sendo a diferença de elevação entre o pixel vizinho e o pixel central, dividida pela distância entre eles, como apresenta a Figura 24, que utiliza um dos métodos mais comumente, o D8 (*deterministic eight neighbours* ou determinístico oito vizinhos), proposto por JENSON & DOMINGUE (1988). A Figura 25 indica a direção de fluxo para a Microrregião de Mossoró

Figura 24- Determinação da direção do fluxo a partir de seus oito vizinhos



Fonte: Coelho, 2010.

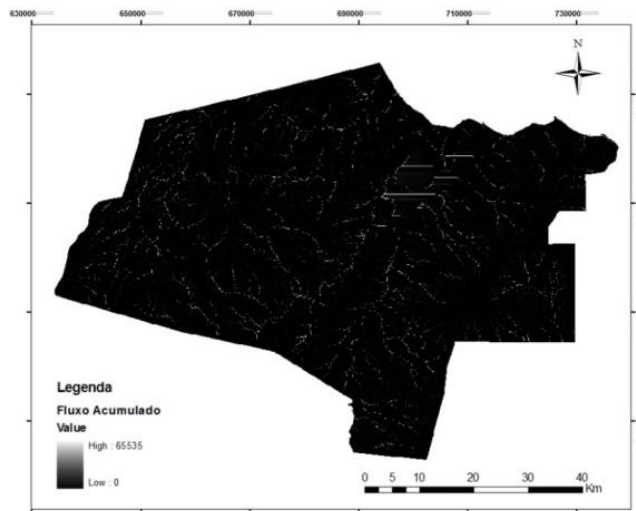
Figura 25 - Direção de fluxo para a Microrregião de Mossoró



Fonte: Autoria própria

A acumulação do fluxo expressa as áreas de drenagem acumulada sobre uma superfície, podendo ser determinada exclusivamente com base nas direções do fluxo. Visualmente, refere-se a um arquivo matricial onde cada pixel tem como atributo o valor do somatório das áreas superficiais de todos os pixels que o escoamento contribui para o pixel em questão, conforme mostra a Figura 26.

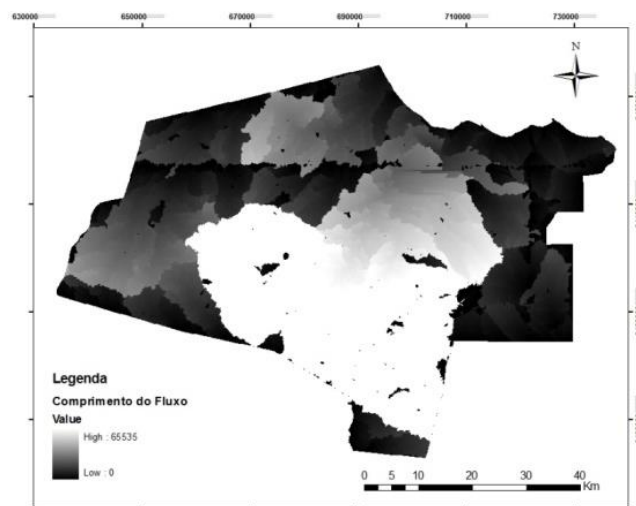
Figura 26 - Acumulação do fluxo da Microrregião de Mossoró



Fonte: Autoria própria

Assim como a acumulação do fluxo, a variável comprimento do fluxo (Figura 27) pode ser extraída diretamente por base nas direções do fluxo. O comprimento do fluxo representa os comprimentos acumulados no percurso da drenagem, desde seu pixel de origem até um ponto de estagnação da água onde o fluxo se encerra. Logo, o valor atribuído a cada pixel indica a distância do mesmo ao exutório da bacia, ou outro ponto referencial, ao longo da drenagem.

Figura 27 - Comprimento do fluxo da Microrregião de Mossoró

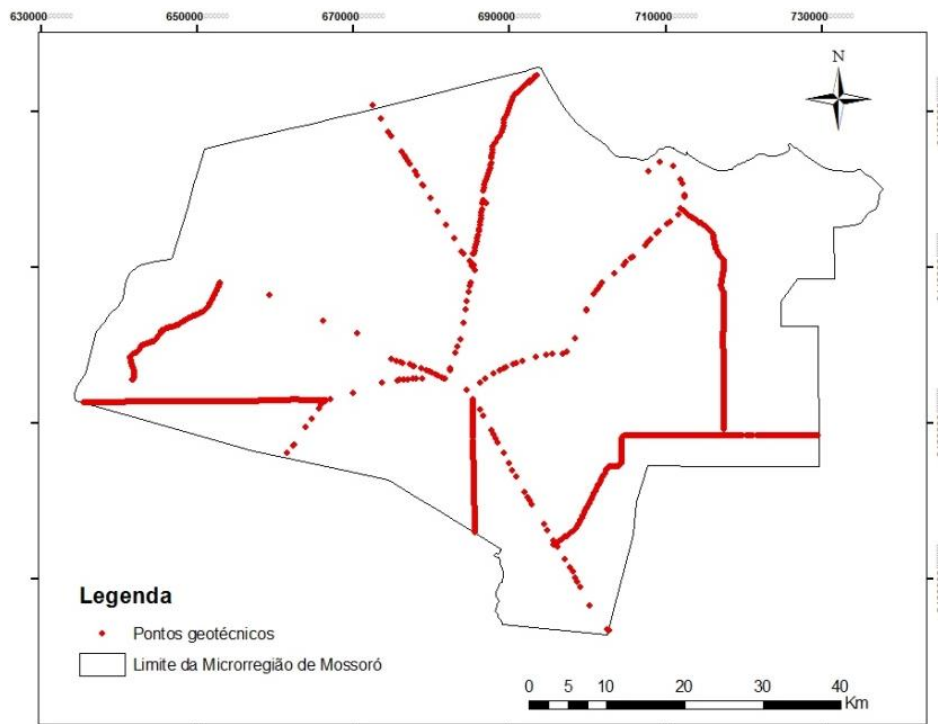


Fonte: Autoria própria

4.3 Análise dos dados de CBR e Classificação AASHTO

O banco de dados a ser utilizado nessa pesquisa será constituído de informações geomorfológica, biofísicas e geotécnicas. O mapa da Figura 28 mostra a espacialização dos 1080 pontos, que foram oriundos da investigação do subleito, dos empréstimos e jazidas dos projetos rodoviários da RN-011, RN-013, RN-014, RN-015, RN-016, BR-110, BR-304, BR-405 e BR-437.

Figura 28- Banco de Dados Espaciais




Fonte: Autoria própria

Como as informações geomorfológicas foram obtidas em formato raster, todo o estudo foi baseado nesse formato, para isso os pontos mostrados anteriormente foram transformados em grade de 250m, conforme metodologia similar a de RIBEIRO *et al.* (2015). Como os dados do SRTM foram baixados com resolução de 30m, e cada ponto se estenderá por 250m, cada ponto influenciará pelo menos 81 pixels. Esses pontos foram associados aos pixels das demais variáveis, pela função *Spatial Join*, compondo um banco de dados com 16379 amostras com 15 atributos independentes e as duas variáveis dependentes.

De posse das informações contidas no mapa apresentado na Figura 28 foi possível estratificar o CBR e a classificação AASHTO. Sendo assim, elaborou-se a Figura 29 que mostra os valores do CBR na energia normal de compactação estratificados em intervalos de 5% de variação. Pode-se verificar que os valores de CBR do subleito que predominam estão entre 5 e 25%. Já os valores de CBR abaixo de 5 e maiores que 25 encontram-se em quantidades bem inferiores.

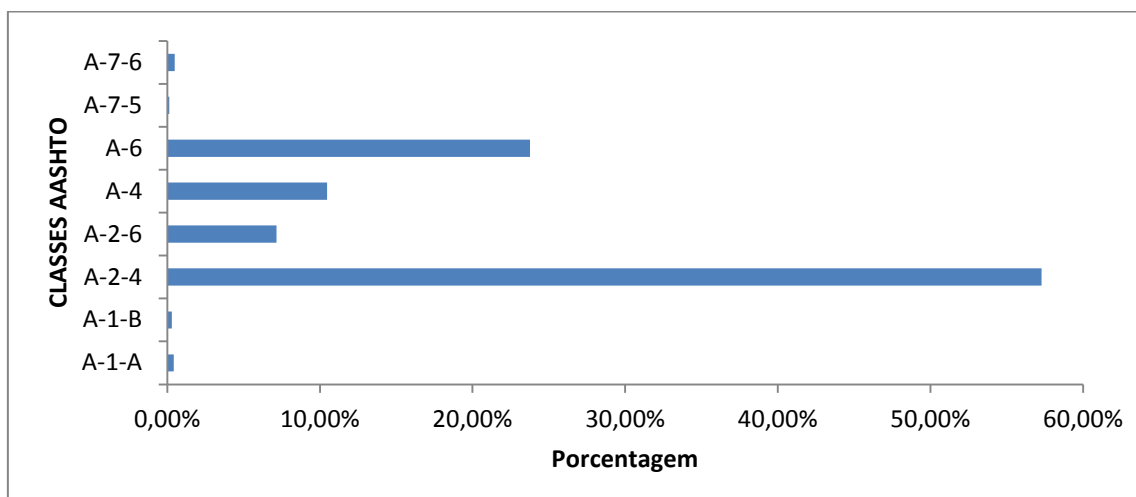
Figura 29 - Estratificação do CBR



Fonte: Autoria própria

A partir dos dados adquiridos foi confeccionado também o gráfico da Figura 30, que mostra o percentual de cada classe AASHTO distribuída no mapa da Figura 28. Pode-se perceber que a classe AASHTO que predomina com 58 % é a Classe A-2-4, seguida da A-6, A-4 e A-2-6. As Classes A-1-a, A-1-b, A-7-5 e A-7-6 aparecem em baixíssima proporção no conjunto de pontos do banco de dados. E as classes A-2-5, A-2-7, A-3 e A-5 não são representadas pelo conjunto de pontos extraídos.

Figura 30 - Estratificação da Classificação AASHTO



Fonte: Autoria própria

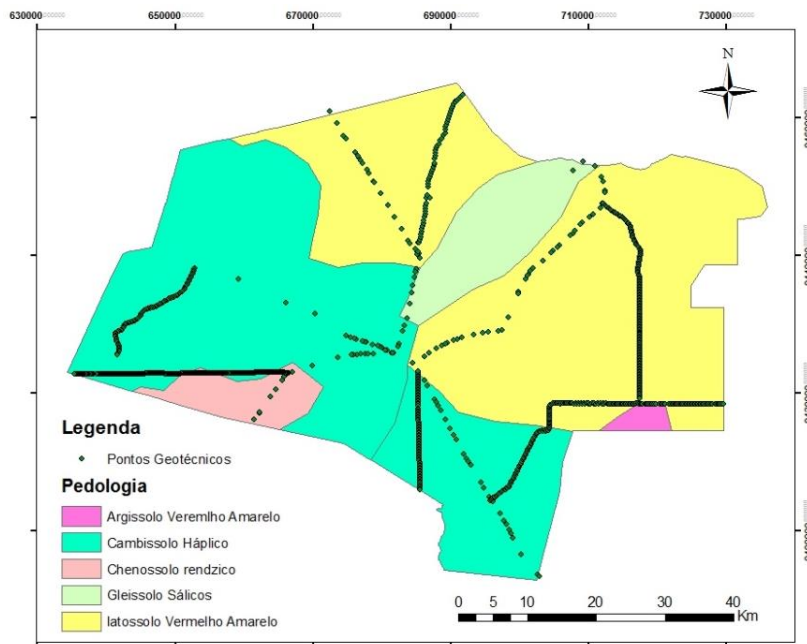
De posse dos mapas e gráficos elaborados (Figuras 26 a 28) é possível perceber uma boa representatividade espacial das amostras dos dados geotécnicos utilizados (boa distribuição na área da MM) do ponto de vista qualitativo e quantitativo.

A seguir são apresentadas a interseção dos pontos das características geotécnicas com os mapas das variáveis biofísicas e geomorfométrica que poderão fazer parte dos modelos de predição das características geotécnicas. Não serão ilustrados os pontos distribuídos no mapa das variáveis Coordenadas Este e Coordenadas Norte (projeção cartográfica UTM), pois estas já estão representadas nos demais mapas pelas as malhas de coordenadas.

(a) Pedologia


As Figuras 31 e 32 ilustram, respectivamente, a espacialização e as proporções de pontos geotécnicos distribuídos por cada classe pedológica classificada pelo Sistema Brasileiro de Classificação dos Solos – SiBCS (2006). As amostras estão distribuídas principalmente nas Classes Pedológicas dos Latossolo Vermelho Amarelo (53%), e Cambissolos Háplico (39%). As demais classes pedológicas ocorrentes na MM também estão representadas pelos pontos geotécnicos, só que em menor quantidade. Isso ocorre em virtude dessas classes serem menos ocorrentes na região.

Figura 31 - Distribuição Espacial dos Pontos Geotécnicos na Pedologia da MM



Fonte: Autoria própria

Figura 32 - Percentuais das Classes Pedológicas da MM



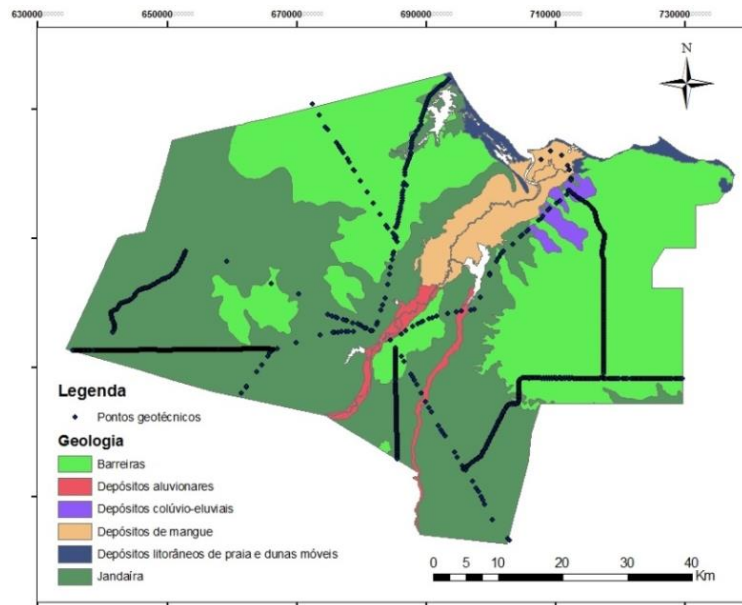
Fonte: Autoria própria

(b) Geologia

A Geologia está classificada por nível litológico, onde pode-se perceber que os pontos geotécnicos estão distribuídos ocupando grande maiorias das classes geológicas. As Figuras 33 e 34 ilustram a distribuição dos pontos geotécnicos por nível litológico. Observa-se ainda que a maior parte dos pontos estão distribuídos na Formação Barreira


e Jandaíra, os depósitos litorâneos não aparecem, e as demais classes aparecem em baixa proporção.

Figura 33 - Distribuição Espacial dos Pontos Geotécnicos na Geologia da MM



Fonte: Autoria própria

Figura 34 - Percentuais das Classes Geológicas da MM



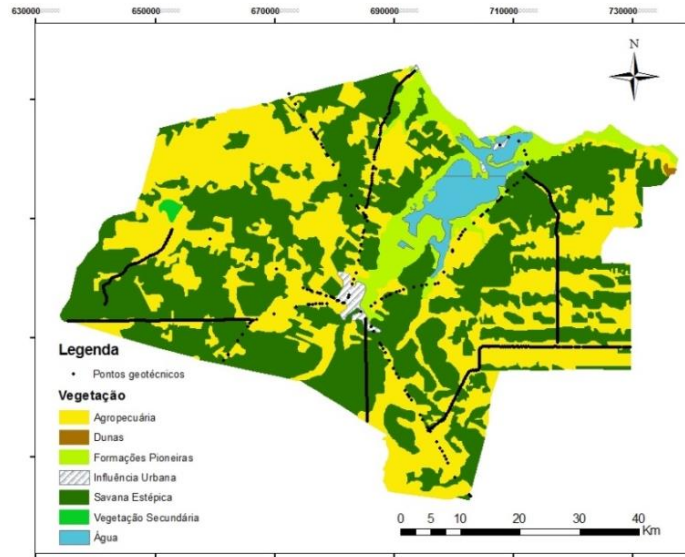
Fonte: Autoria própria

(c) Vegetação

Nas Figuras 35 e 36, pode-se perceber que os pontos distribuídos pelas informações diferentes de vegetação ocupam os 5 dos 7 parâmetros da Caatinga presentes na MM classificados pelo MMA (2009). Algumas características se omitem ao banco de dados pelo da distribuição dos pontos ser comandada pela malha viária das


quais se obteve projetos para extração desses dados e tais categorias ocorrerem em baixa quantidade e não ser um eixo estradal adquirido.

Figura 35 - Distribuição Espacial dos Pontos Geotécnicos na Vegetação da MM



Fonte: Autoria própria

Figura 36 - Percentuais das Classes de Vegetação da MM



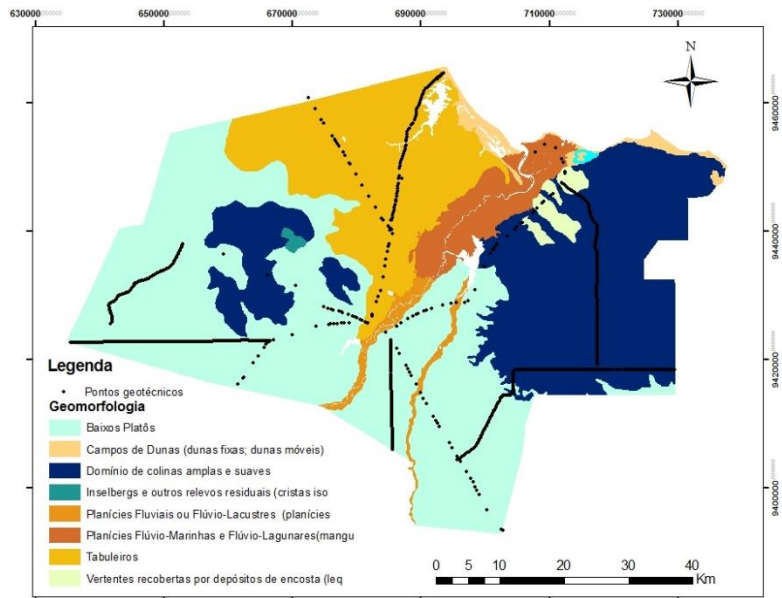
Fonte: Autoria própria

(d) Geomorfologia

O cruzamento dos pontos geotécnicos com a Geomorfologia da MM pode ser observado nas Figuras 37 e 38. Ressalta-se que a maior parte dos pontos estão


concentrados nos Baixos Platôs, Domínio de colinas amplas e suaves e Tabuleiros. E assim como na geologia tem classes que não estão no banco de dados.

Figura 37 - Distribuição Espacial dos Pontos Geotécnicos na Vegetação da MM



Fonte: Autoria própria

Figura 38 - Percentuais das Classes Geomorfológicas da MM

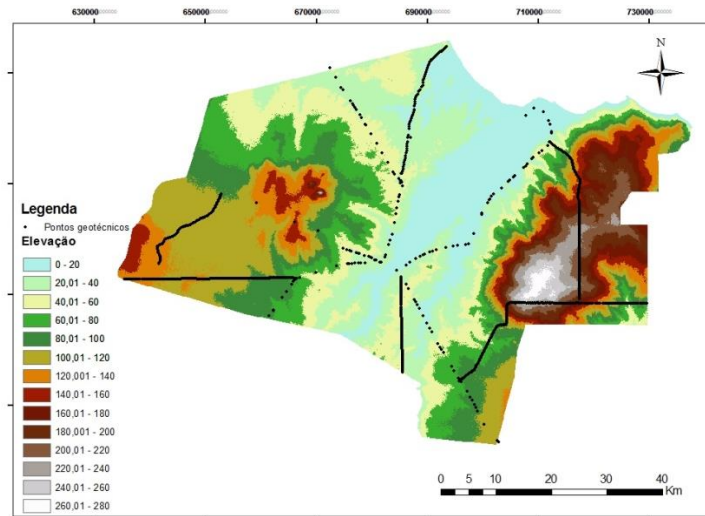


Fonte: Autoria própria

(e) Elevação

Os pontos geotécnicos da MM foram cruzados com a altimetria da região, conforme Figura 39, e pode-se notar que tem-se amostras com todas as elevações da região, mesmo que algumas sejam pouco representadas.

Figura 39 - Distribuição Espacial dos Pontos Geotécnicos na Elevação da MM

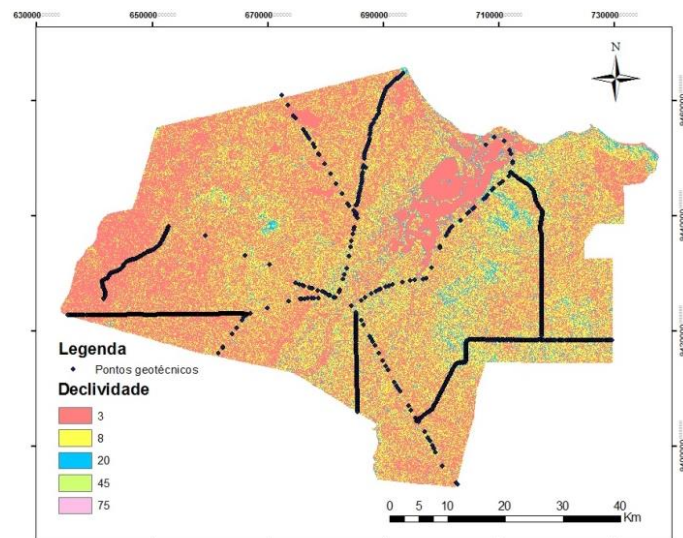


Fonte: Autorial própria

(f) Declividade

Na Figura 40, tem-se os pontos geotécnicos distribuídos na declividade do terreno da região de estudo, onde observa-se a predominância de baixa declividade, sendo a maior parte com declividade plana, seguida de suave e ondulado.

Figura 40 - Distribuição Espacial dos Pontos Geotécnicos na Declividade da MM

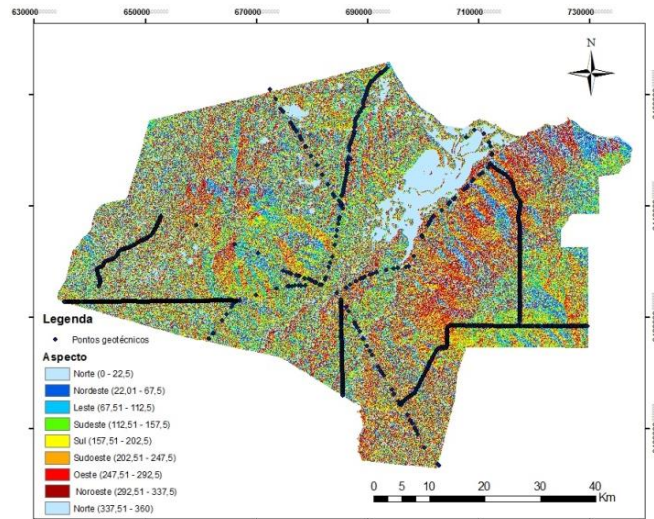


Fonte: Autorial própria

(g) Aspecto

No cruzamento dos pontos geotécnicos com a Orientação das Vertentes da MM (Figura 41) tem-se uma grande diversidade de valores, sendo apresentada todas as orientações possíveis da região.

Figura 41 - Distribuição Espacial dos Pontos Geotécnicos com o Aspecto da MM

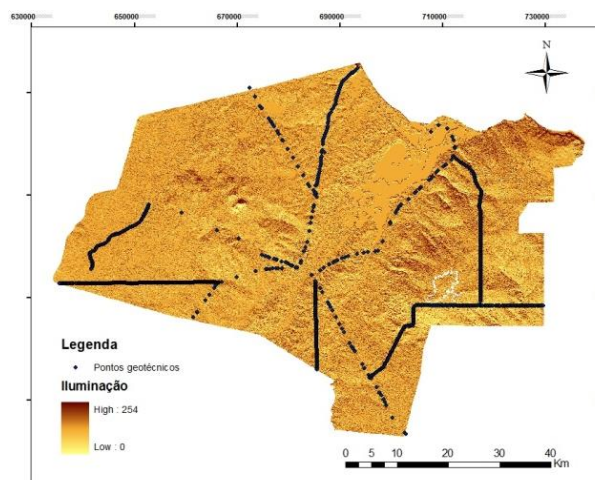


Fonte: Autoria própria

(h) Iluminação

A iluminação (Figura 42) da região está representada em escala de intensidade, e o cruzamento de variável com os pontos geotécnicos percebe-se que a essa interseção representação os pontos de mais luminosidade solar.

Figura 42 - Distribuição Espacial dos Pontos Geotécnicos na Iluminação da MM

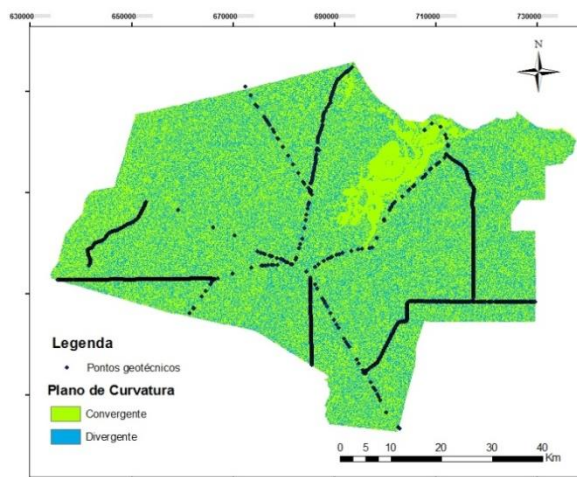


Fonte: Autoria própria

(i) Plano de Curvatura

A curvatura planar do terreno se mostra bastante equilibrada entre as duas possibilidades de ocorrência, mas no cruzamento com os pontos geotécnicos percebe-se que a grade maioria das amostras, cerca de 75%, são classificadas com divergentes, sendo o restante convergente, conforme Figura 43.

Figura 43 - Distribuição Espacial dos Pontos Geotécnicos no Plano de Curvatura da MM

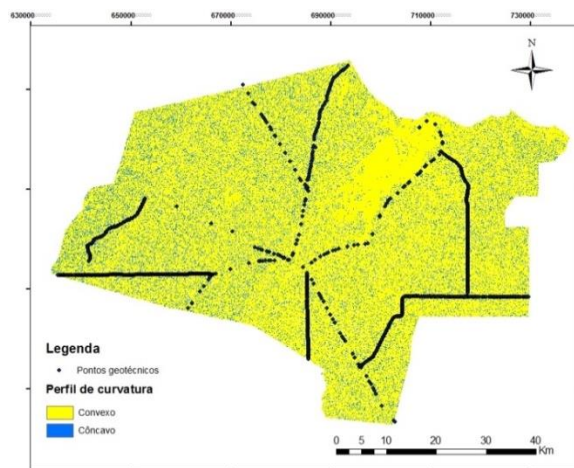


Fonte: Autoria própria

(j) Perfil de Curvatura

Assim como na curvatura planar do terreno, o perfil de curvatura se mostra bastante proporcional, mas no cruzamento com os pontos geotécnicos tem-se que a maioria das amostras são consideradas côncava, com ilustra a Figura 44.

Figura 44 - Distribuição Espacial dos Pontos Geotécnicos no Perfil de Curvatura da MM

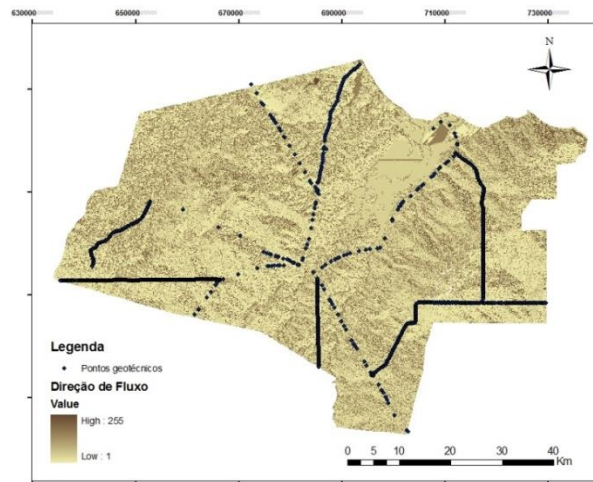


Fonte: Autoria própria

(k) Direção de Fluxo

A direção do fluxo de escoamento é representada em escala de intensidade, conforme Figura 45, e na interseção com os pontos geotécnicos tem-se os valores mais altos, o que significa que são superfícies mais baixas e recebem contribuições a jusante.

Figura 45 - Distribuição Espacial dos Pontos Geotécnicos na Direção de Fluxo da MM

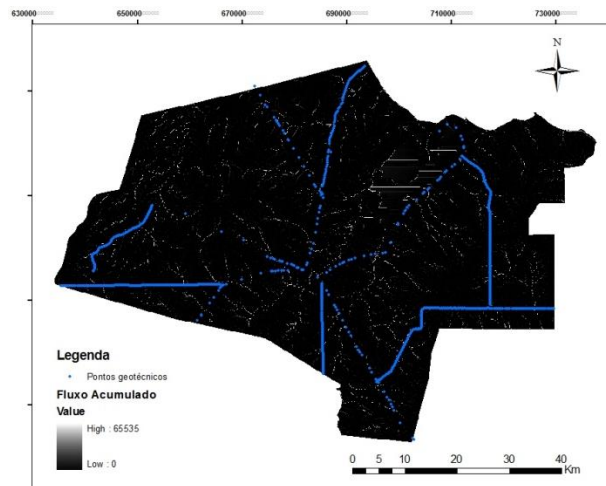


Fonte: Autoria própria

(l) Fluxo Acumulado

A acumulação do fluxo (Figura 46) expressa as áreas de drenagem acumulada sobre uma superfície e as amostras referente ao banco de dados representam áreas de grandes fluxos, que logo devem ser superfícies mais baixas.

Figura 46 - Distribuição Espacial dos Pontos Geotécnicos no Fluxo Acumulado da MM

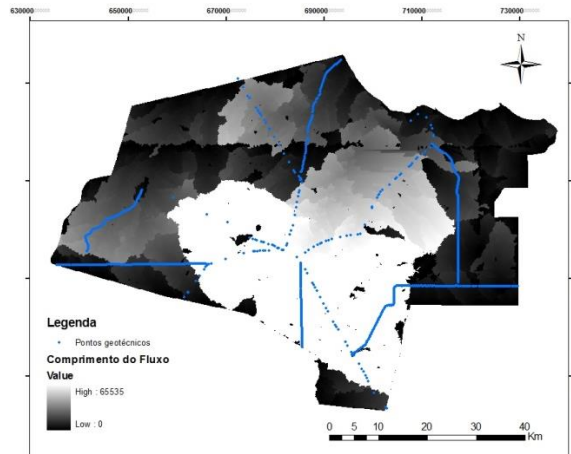


Fonte: Autoria própria

(m) Comprimento de Fluxo

O comprimento do fluxo (Figura 47) representa os comprimentos acumulados no percurso da drenagem, logo assim como o fluxo acumulado, as amostras do banco de dados são representadas por superfícies mais baixas, sendo assim as de maiores valores.

Figura 47 - Distribuição Espacial dos Pontos Geotécnicos no Comprimento de Fluxo da MM



Fonte: Autoria própria

4.4 Modelagem Estatística

Para tentar estimar o valor de CBR para a região buscou-se na literatura técnicas estatísticas para relacionar variáveis nominais (qualitativas) com o CBR, a estratégia utilizada são as variáveis Dummy, que transforma cada categoria em uma variável binária, podendo essa apresentar valor zero ou um, no caso 0 para quando ela for ausente e 1 quando for presente. Assim foi desenvolvido um modelo de regressão múltipla (com variáveis dummy) para prever o CBR.

De início foi realizado uma análise de correlação simples no excel, onde as variáveis nominais foram numerizadas. A Tabela 7 mostra esse resultado, destacando em negrito os melhores índices de correlação, mostrando que as variáveis biofísicas (Pedologia, Geologia, Geomorfologia e Vegetação) explicam melhor o CBR, mas algumas variáveis geomorfométricas também possuem um poder de explicação razoável.

Tabela 7 - Correlação das Variáveis

	NORTE	ESTE	Comp. D. Fluxo	Fluxo A.	Plano C.	Perfil C.	Aspecto	Ilum.	Elev.	Decliv.	Pedo.	Geom.	Geol.	Veg.	AASHTO	CBR	
NORTE	1																
ESTE	0,120	1															
Comp.Fluxo	0,197	-0,159	1														
Dir. Fluxo	0,025	-0,022	-0,020	1													
Fluxo Ac.	0,034	-0,021	-0,009	0,452	1												
Plano C	0,023	0,080	-0,033	0,016	0,011	1											
Perfil C	0,085	0,098	-0,030	-0,010	-0,003	0,045	1										
Aspecto	0,015	0,246	-0,032	-0,023	-0,024	-0,078	0,141	1									
Iluminação	0,102	-0,031	0,047	-0,003	-0,004	0,091	0,073	-0,028	1								
Elevação	-0,507	0,265	-0,330	-0,037	-0,041	-0,154	-0,056	0,112	-0,083	1							
Decliv.	0,130	0,375	-0,030	-0,014	-0,019	-0,016	0,032	0,064	-0,096	0,014	1						
Pedologia	-0,380	-0,462	-0,041	-0,008	-0,005	-0,030	-0,087	-0,122	-0,033	-0,009	-0,137	1					
Geomorf.	-0,744	-0,387	0,010	-0,030	-0,029	-0,025	-0,100	0,002	-0,034	0,362	-0,180	0,402	1				
Geologia	0,251	0,724	-0,039	-0,011	-0,011	0,063	0,072	0,176	0,010	0,091	0,302	-0,417	-0,407	1			
Vegetação	-0,059	-0,297	0,072	0,014	0,011	-0,001	-0,022	-0,048	0,066	-0,065	-0,156	0,118	0,140	-0,115	1		
AASHTO	-0,295	-0,724	0,014	0,009	0,012	-0,039	-0,097	-0,161	0,002	-0,084	-0,275	0,399	0,496	-0,566	0,243	1	
CBR	0,347	0,738	-0,051	0,000	-0,004	0,050	0,097	0,145	-0,025	0,131	0,297	-0,500	-0,505	0,617	-0,241	-0,660	1

Fonte: Autoria Própria

Foram feitos alguns testes a fim de mostrar a eficiência de modelos com diversas estruturas, tais estruturas estão especificadas na Tabela 8.

Tabela 8 - Especificação dos Modelos

Modelo	Composição
1	Apenas variáveis geomorfométricas primárias (elevação, declividade, iluminação, aspecto, plano e perfil de curvatura);
2	Todas as variáveis geomorfométricas
3	Somente com as variáveis biofísicas
4	Variáveis geomorfométricas e as coordenadas Norte e Este
5	Variáveis biofísicas e as coordenadas Norte e Este
6	Variáveis biofísicas, as coordenadas Norte e Este e as variáveis geomorfométricas primárias
7	Todas as variáveis

A Tabela 9 mostra os coeficientes de determinação entre as variáveis referentes a cada modelo, onde se observa crescente aumento do coeficiente de determinação com o acréscimo de variáveis ao modelo, assim foi adotado o último modelo.

Tabela 9 - Índice de Correlação dos Modelos de CBR

	Modelos						
	1	2	3	4	5	6	7
R ²	0,117	0,130	0,515	0,624	0,628	0,640	0,760

Fonte: Autoria própria

Dos setes modelos testados observou-se que as variáveis geométricas isoladas não apresentam coeficientes de determinação bons, mas o modelo com apenas variáveis biofísica e os com incrementos das coordenadas indicaram um coeficiente de determinação de razoável a bom. E como esperado, o modelo com todas as 15 variáveis foi o com melhor R², e com uma boa diferença entre os demais, mostrando que as variáveis isoladas não possui um poder de

significância tão elevado quanto em conjunto. Levando em consideração esse teste é preferível adotar o Modelo 7 como o modelo de estimação do CBR, pois este possui um melhor ajuste frente aos demais.

Os resultados dos testes de significância entre a variável explicada (CBR) e as variáveis explicativas para o modelo escolhido podem ser vistos na Tabela 10.

Tabela 10 - Teste de Razão de Verossimilhança (Significância das Variáveis)

Variáveis	Significância
Intercepto	0,000
Declividade	0,022
Elevação	0,000
Iluminação	0,012
Aspecto	0,083
Perfil de Curvatura	0,169
Plano de Curvatura	0,449
Fluxo Acumulado	0,404
Direção de Fluxo	0,335
Comprimento de Fluxo	0,907
Norte	0,000
Este	0,000
Pedologia	0,000
Geomorfologia	0,000
Geologia	0,000
Vegetação	0,000

Fonte: Autoria própria

Após os resultados de significância através do teste razão de verossimilhança com confiança de 95%, ou seja, para ter significância ao modelo a variável deve apresentar valor menor que 5% (0,05). É possível verificar na Tabela 10 que para o modelo algumas das variáveis ficaram com valor acima da significância permitida (valores em negrito). As variáveis em negrito não são muito significantes para compor o modelo.

Porém observando os valores de significância do teste quando se utiliza a interseção de todos os valores das variáveis é possível afirmar que as variáveis juntas apresentam valores menores que 5% (0,05), como pode-se observar na Tabela 10, portanto tem significância muito boa para compor o modelo, podendo assim explicar os fenômenos geotécnicos em questão. Assim, mesmo as informações que não atingiram o coeficiente individual de significância de até 5% farão parte do modelo de previsão CBR. O modelo final de estimação do CBR pode ser representado pela Equação formada pelos coeficientes B da Regressão (Ver Anexo D).

A previsão da classificação AASHTO, por se tratar de uma variável categórica, foi realizada pela Regressão Logística Múltipla Multinomial, pois essa técnica permite correlacionar de forma múltipla as variáveis de entradas, algumas nominais, com a variável geotécnica dependente, também nominal.

Apesar dessa técnica não considerar as melhores correlação como seleção das variáveis para o modelo, foram feitos testes de regressão conforme feito para a previsão do CBR, considerando a mesma estrutura dos modelos. A Tabela 11 mostra os coeficientes de determinação entre as variáveis referentes a cada modelo, onde também se observa o crescente aumento do coeficiente de determinação com o acréscimo de variáveis ao modelo, assim foi adotado o último modelo.

Tabela 11 - Índice de Correlação dos Modelos da AASHTO

	Modelos						
	1	2	3	4	5	6	7
Cox and Snell	0,421	0,490	0,578	0,678	0,648	0,672	0,685
Nagelkerke	0,213	0,402	0,641	0,751	0,719	0,745	0,761
McFadden	0,192	0,214	0,372	0,488	0,450	0,480	0,499


Fonte: Autoria própria

Os valores obtidos na Tabela 11 para os R^2 de Cox e Snell, bem como de Nagelkerke para os modelos de 4 a 7 estão entre 0,678 a 0,76, o que considerado de razoável a bom, o que indica a existência de uma boa relação entre a variável Geotécnica AASHTO e as variáveis biofísicas e geomorfométrica. Mas os primeiros modelos, onde as variáveis se aprestam de forma isolada, percebe-se que não tem uma boa correlação com a variável resposta, sendo que as variáveis biofísicas se comportam melhor do que as variáveis geomorfométricas. Considerando-se então os valores desses testes, pode-se afirmar que o melhor modelo a ser adotar é o sete, tendo esse um bom ajuste.

Por se tratar de um modelo logístico, temos como saída categorias referente às classes de solos, onde se tem a probabilidade de cada classe de solo calculada por uma equação e uma classe de referência (Ver Anexo II), considerando a classe determinante a de maior chance de ocorrer. Testando-se esse modelo com os valores conhecidos do banco de dados, e considerando a classe predita aquela de maior probabilidade de ocorrência tem-se um acerto de 42%. A Figura 48 mostra as proporções reais e estimadas das classes de solo.

Essa relativa diferença entre o índice de correlação e a taxa de acerto refere-se a probabilidade da classe. O valor de R^2 mostra a chance de ocorrência da classe correto para cada pixel, já a porcentagem de acerto compara a classe de maior probabilidade com a classe real de cada pixel.

Figura 48 - Porcentagem de acertos para o modelo estatístico da Classificação AASHTO



Fonte: Autoria própria

4.5 Modelagem Neural

A modelagem neural é constituída de três conjuntos, onde são divididos em 60% para o treinamento, fase de aprendizagem da rede com dados de entrada e saída conhecidos, 20% para validação e 20% para o teste, onde são apresentados dados de entradas às redes neurais para geração de estimativas de CBR e classificação AASHTO.

As variáveis biofísicas e algumas geomorfométricas são informações nominais, e para entrada nas redes neurais foram numerizadas e normalizadas. As demais características geomorfométricas e o CBR, por se tratarem de informações numéricas, foram apenas normalizados. Os dados da AASHTO, por se tratar de uma classificação, foram pré-processada pela dummyzação.

Neste trabalho, para se modelar os dois parâmetros geotécnicos de interesse da pavimentação, no caso CBR e Classificação AASHTO, foram testados dois algoritmos do tipo *backpropagation feed-forward*: (1) o TRAINGDX (Gradiente descendente *backpropagation* com *momentum* e taxa de aprendizagem adaptativa) e (2) TRAINLM (Levenberg-Marquardt). Verificou-se que o segundo foi aquele que produziu os melhores resultados para os dois parâmetros esperados como saída das redes neurais.

Com a definição de se buscar dois modelos para predição de cada parâmetro geotécnico em questão, realizou-se a seguinte árvore de testes para se chegar à(s) melhora(s) topologia(s):

- Redes com diferentes algoritmos de treinamento: TRAINLM e o TRAINGDX;
- Topologias com uma e duas camadas intermediárias;
- Topologias com variações do número de neurônios nas camadas intermediárias. Inicialmente testou-se a indicação de NIELSEN (1989) *apud* DA SILVA (2003) para determinação do número de neurônios na camada intermediária, posteriormente os neurônios foram variando conforme sequência: 1, 10, 15, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 40, 45, 50, 55, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 200, 250, 300.
- Topologias com função de ativação Tangente sigmoideal (*tansig*) com intervalo de ativação [-1; 1] nos neurônios da(s) camada(s) intermediária(s) e função identidade (*pureline*) nos neurônios de saída;

Foram testadas diferentes topologias para cada uma das duas variáveis de saída, combinando as camadas como os números de neurônios pré-definidos, na tentativa incansável de identificação da topologia que melhor se adaptasse a esse estudo. Conforme DA SILVA (2003), esta maneira de definir a topologia demanda um tempo considerável e ainda assim é provável que haja uma combinação não testada que responda melhor às expectativas de generalização e tempo de convergência que aquela adotada.

Para se chegar à topologia mais adequada, poderia se adotar estratégias diferentes daquela apresentada aqui, porém para esse estudo elegeu-se uma conduta racional baseada no erro mínimo para convergir a rede na tentativa de definir a topologia mais apropriada.

Para medir o desempenho das topologias testadas, adotou-se o MSE (*Mean of Squared Error*) ou (Quadrado Médio dos Erros) – medida de desempenho encontrado em DA SILVA (2003), e sendo ainda a medida de erro adotada no programa utilizado, o Matlab, a mesma é definida pela Equação (9).

$$MSE = \frac{SSE}{n - p} \quad (9)$$

Onde:

SSE = Diferenças quadráticas entre os valores de saída da RNA e os valores esperados como ideais;

n = Número de exemplos do conjunto de treinamento (quantidade de padrões);

p = Número de parâmetros a serem estimados (quantidade de pesos da rede).

Com intuito de ilustrar parte do esforço despendido nessa etapa da investigação elaborou-se as Tabelas 12 e 13, que apresenta apenas as melhores topologias testadas para cada variável geotécnica modelada, com destaque, em negrito, àquelas que obtiveram melhor desempenho, ou seja, menores erros para o conjunto de teste, na predição das variáveis em estudo.

Tabela 12 - Principais Modelos de RNAs Testados para predição do CBR

CBR						
Entrada/Saída	15/1	15/1	15/1	15/1	15/1	15/1
Camadas Intermediárias	1	1	1	1	1	1
Nº de neurônios	24	32	36	37	39	50
Algoritmo	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm
MSE (Teste)	0,016182	0,0030917	0,004041	0,004142	0,003621	0,004161
R ²	0,89	0,91	0,89	0,89	0,90	0,89

Fonte: Autoria própria

Tabela 13 - Principais Modelos de RNAs Testados para predição da AASHTO

Classificação AASHTO						
Entrada/Saída	15/6	15/6	15/6	15/6	15/6	15/6
Camadas Intermediárias	1	1	1	1	1	1
Nº de neurônios	10	20	30	40	50	60
Algoritmo	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm
MSE (Teste)	0,002951	0,0298	0,02556	0,02503	0,024154	0,02
R ²	0,87	0,87	0,88	0,88	0,89	0,88

Fonte: Autoria própria

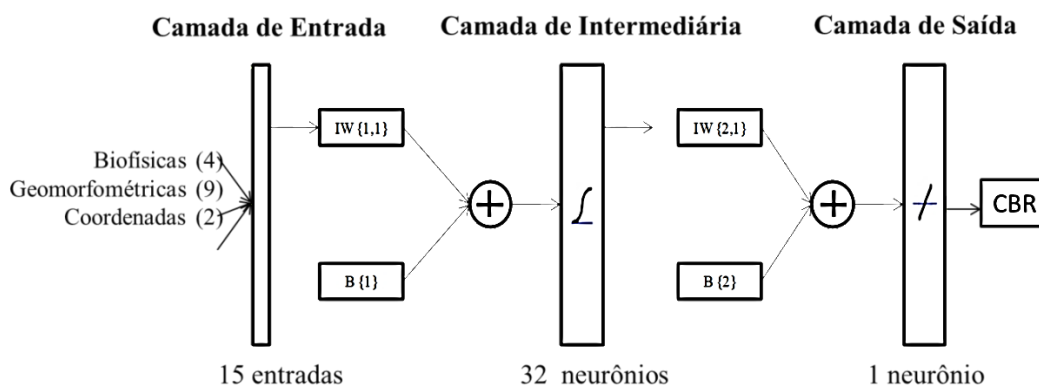
Na etapa de treinamento e validação a rede “conhece” seus valores e é nessa fase que são determinados os valores dos pesos sinápticos para se chegar a um valor de saída. No teste são aplicados esses pesos e obtido valores de saída, que em seguida são correlacionados com os valores reais, tendo assim os valores de R^2 mais confiáveis dentre as etapas do processamento, sendo assim o valor de referência para o modelo neural.

As topologias com menores erros, que coincide com o maior R^2 , na árvore de testes foram adotadas neste trabalho como topologias ótimas e, apresentaram apenas uma camada intermediária, o que indica que a generalização realizada pelas redes neurais, a partir dos dados disponíveis foi possível de ser executada através de uma função contínua, o que permite acreditar que dados eram bem representativos para os fenômenos modelados.

Após a realização da árvore de testes descrita acima, esperava-se encontrar duas topologias distintas para cada valor de saída, sendo uma para a Classificação AASHTO e outra para o CBR. As duas topologias encontradas foram muito semelhantes, diferenciando-se apenas na quantidade de neurônios de camada intermediária e de saída.

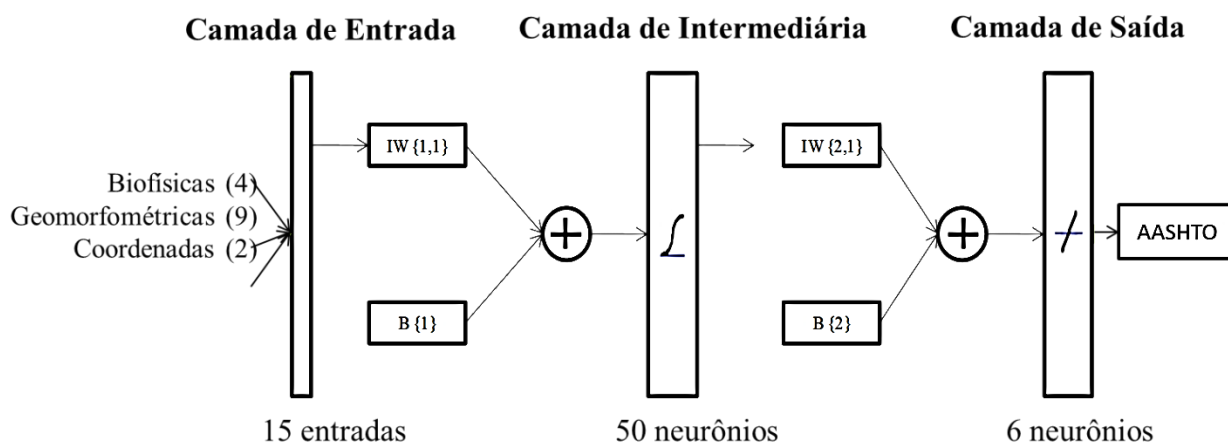
As topologias ótimas encontradas (ver Figuras 49 e 50), obtidas individualmente foram executadas com o mesmo algoritmo, TRAINLM (*Levenberg-Marquardt*), a camada de entrada das duas redes foi composta por 15 neurônios representados pelas variáveis de entrada, a camada intermediária (escondida) diferiu na quantidade de neurônios, onde a rede para o CBR possui 32 neurônios e a classificação AASHTO 50 neurônios, e a camada de saída também foi diferente, com 1 neurônio para o CBR e 6 neurônios para a classificação AASHTO, representando os tipos de solos disponíveis a serem preditos.

Figura 49 - Topologia Adotada para o CBR (15:32:1)



Fonte: Autoria própria


Figura 50 - Topologia Adotada para a Classificação AASHTO (15:50:6)



Fonte: Autoria própria


Para a configuração da rede neural com a topologia mais eficiente para os dois modelos foram obtidos MSE diferentes para os conjuntos de treinamento, validação e teste. As Figuras 51 e 52 ilustram os gráficos de desempenho extraídos do NNTOOL equivalente a modelagem para os parâmetros geotécnicos estudados.

Figura 51 - Desempenho da RNA para predição do CBR



Fonte: Autoria própria

Figura 52 - Desempenho da RNA para predição da Classificação AASHTO




Fonte: Autoria própria

Observando os gráficos das Figuras 51 e 52, percebe-se que os MSE do conjunto de treinamento dos modelos são bem inferiores que os do conjunto de teste e validação. Esse comportamento ocorre devido a quantidade de dados do conjunto de treinamento ser 3 vezes maior que a quantidade dos dados dos demais conjuntos.


O desempenho dos modelos calibrados foi diferente para os dois parâmetros geotécnicos. Para o CBR, por se tratar de aproximação de valores, foi medido pela correlação entre os dados reais e os de saída da rede, sendo para o modelo escolhido R^2 de 0,91 (Figura 53). Já a classificação AASHTO foi mensurada pelo índice de acertos, medido pelo conjunto de teste, já que para esse eram apresentados apenas os dados de entradas, sendo a saída desconhecida pela rede. Os valores desse índice correspondem a porcentagem de acertos da rede, que para a rede escolhida foi de 89% (Figura 54).

Figura 53 - Correlação entre os dados reais e o de saída para o conjunto de teste



Fonte: Autoria própria

Figura 54 - Porcentagem de acertos para o modelo neural da Classificação AASHTO



Fonte: Autoria própria

Como visto, os melhores modelos neurais apresentaram 15 variáveis de entrada, mas com o propósito de mostrar o desempenho de outros modelos foram elaboradas as Tabelas 14 e 15 que mostra um resumo similar ao adotado anteriormente nas Tabelas 12 e 13, mas considerando o melhor modelo de CBR e classificação AASHTO para cada estrutura adotada. Considerando que a estrutura 1 é composta apenas por variáveis geomorfométricas primárias (elevação, declividade, iluminação, aspecto, plano e perfil de curvatura), a estrutura 2 com todas as variáveis geomorfométricas, a estrutura 3 somente com as variáveis biofísicas, a estrutura 4 com as variáveis geomorfométricas e as coordenadas Norte e Este, a estrutura 5 com as variáveis biofísicas e as coordenadas Norte e Estes, a estrutura 6 com as variáveis biofísicas, as coordenadas Norte e Este e as variáveis geomorfométricas primárias e a estrutura 7 com todas as variáveis. As Tabelas 14 e 15 mostram os coeficientes de determinação entre as variáveis referentes a cada modelo, onde se observa crescente aumento do coeficiente de determinação com o acréscimo de variáveis ao modelo, assim foi adotado o último modelo.

Tabela 14 - Melhor desempenho para cada modelo de predição do CBR

CBR

Estrutura	1	2	3	4	5	6	7
Camadas Intermediárias	1	1	1	1	1	1	1
Nº de neurônios	40	60	60	50	39	50	32
Algoritmo	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm
MSE (Teste)	0,016182	0,019171	0,00827	0,006188	0,003735	0,003443	0,0030917
R	0,76	0,82	0,87	0,92	0,94	0,94	0,96

Tabela 15 - Melhor desempenho para cada modelo de predição da AASHTO

AASHTO							
Estrutura	1	2	3	4	5	6	7
Camadas Intermediárias	1	1	1	1	1	1	1
Nº de neurônios	30	20	20	40	20	20	50
Algoritmo	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm	Trainlm
MSE (Teste)	0,047506	0,040459	0,032320	0,038739	0,027797	0,028875	0,024154
R	0,73	0,78	0,84	0,78	0,84	0,85	0,89

Assim como na modelagem estatística os modelos com apenas as variáveis geomorfométricas foram os que tiveram menor desempenho, mas ao considerarmos todas as variáveis geomorfométricas e não somente as primárias já se tem uma melhora. No caso da classificação AASHTO tem se valores semelhante para as estruturas com as 4 variáveis biofísicas e com as 9 as variáveis geomorfométrica, bem como esses integrados as coordenadas. As coordenadas geográficas contribuem bastantes para a eficiência do modelo, e o incremento de todas as variáveis aumenta consideravelmente o desempenho do modelo.

4.6 Generalização dos Resultados para a Microrregião de Mossoró

A partir dos resultados da predição da Classificação AASHTO e do CBR, pelos modelos estatísticos ou modelos neurais desenvolvidos, foi possível realizar estimativas e extrapolação dos parâmetros modelados para todo o território da MM. As estimativas da predição das variáveis geotécnicas foram espacializadas para toda a região de estudo, gerando um Mapeamento Geotécnico.

O mapeamento foi realizado a partir de 67.839 (sessenta e sete mil oitocentos e trinta e nove) pontos gerados em todo o território MM. Para tanto, foi gerada uma grade em toda a área de estudo com malha de 250 m através do *HawthsTools* no ArcGIS 9.3. Em seguida, obteve-se o ponto de centroide de cada quadrícula que compõe a grade. Esses pontos foram cruzados espacialmente com as variáveis de entrada pelo *Spatial Join*, também no Arcgis, gerando uma tabela de atributos.

Para uniformização desses dados, essa tabela foi exportada para o Excel, onde as informações foram numerizadas e normalizadas. A modelagem estatística foi executada no próprio Excel, com as equações dos modelos gerados. Já a modelagem neural foi realizada no Matlab pelo *NNTOOL*, onde com a rede neural já calibrada e validada, simularam-se as saídas (predições) sem que os pesos do modelo adotado se alterassem.

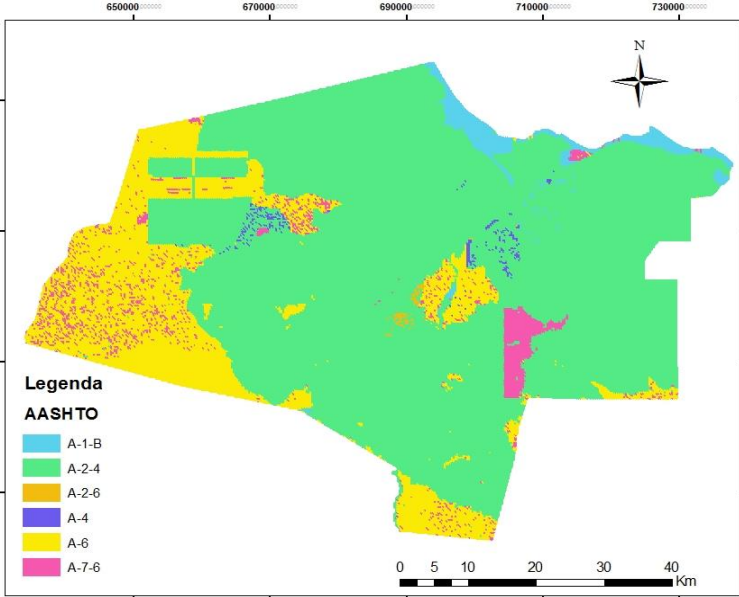
A partir dos resultados obtidos, foram gerados diversos mapas temáticos na intenção de ajudar aos tomadores de decisão acerca da ocorrência dos diferentes tipos de solos com potencial para pavimentação na MM.

4.6.1 Modelagem da Classificação AASHTO

A classificação AASHTO foi generalizada para a toda a MM com a mesma incerteza dos modelos gerados, ou seja, índice de acerto de 42% para o modelo estatístico e de 89% para o modelo neural. Como essa modelagem foi realizada a partir da classificação em categorias, foi considerada com classe predita aquela de maior probabilidade de ocorrência.

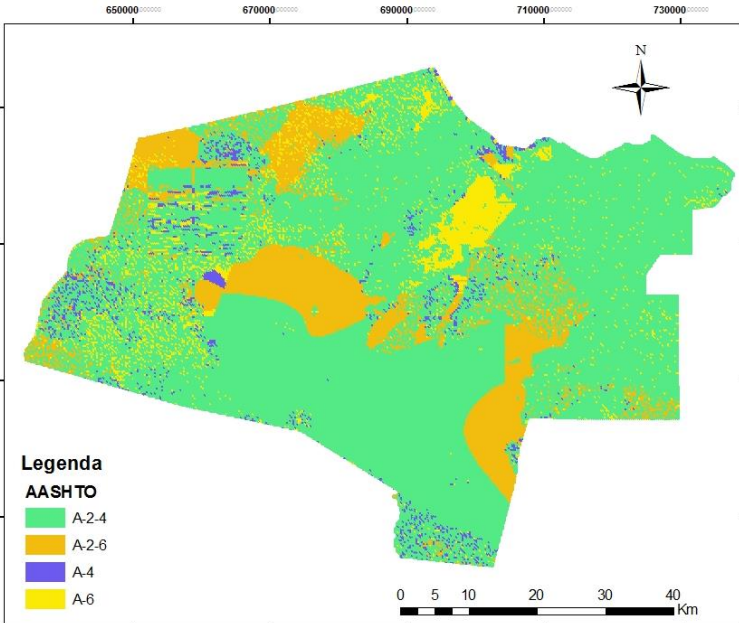
Observando-se as Figuras 55 a 58, percebe-se que os solos do tipo A-2-4 têm maior predominância nos dois modelos gerados, cerca de 74% do total para ambos os modelos, ocupando a maior parte da área ante aos demais. Os solos do tipo A-2-6, A-4 e A-6 aparecem nos dois modelos, mesmo que com variação de predominâncias, já os solos do A-1-b e A-7-6 só tem representação em um dos modelos, e com pouca frequência.

Figura 55 - Distribuição Espacial da Classificação AASHTO - Modelo Estatístico




Fonte: Autoria própria

Figura 56 - Distribuição Espacial da Classificação AASHTO - Modelo Neural




Fonte: Autoria própria

Figura 57 - Percentuais das Classes AASHTO - Modelo Estatístico



Fonte: Autoria própria

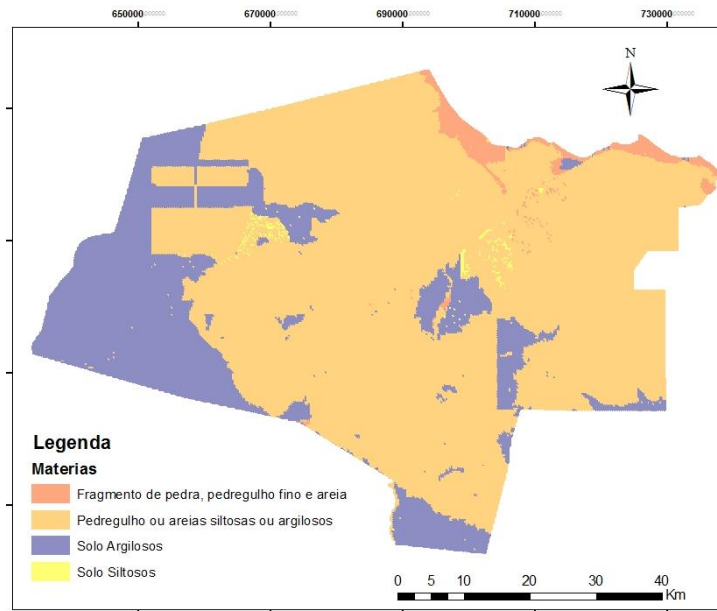
Figura 58 - Percentuais das Classes AASHTO - Modelo Neural



Fonte: Autoria própria

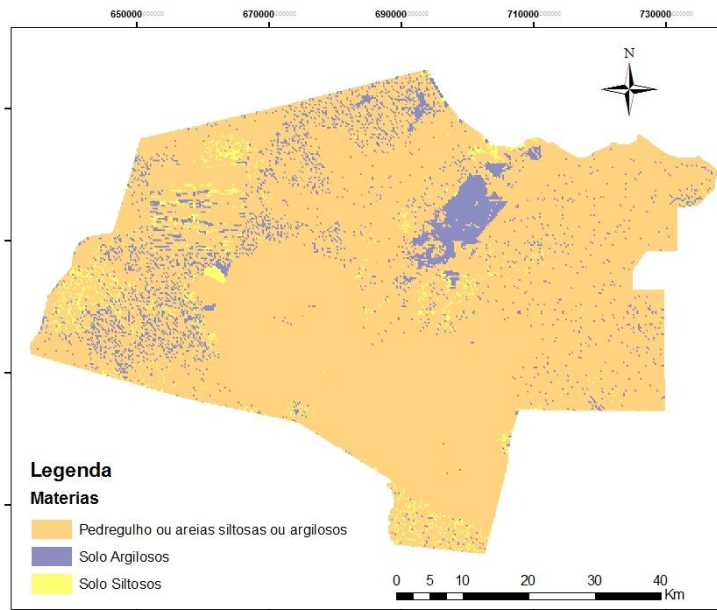
Com a classificação AASHTO é possível detalhar os materiais constituintes da MM por meio das Figuras 59 a 62 e observar que a maioria dos solos presentes da MM são constituídos de pedregulhos ou areias siltsas ou argilosas e que os solos que menos aparecem são areias finas, com 5% de presença na região.

Figura 59 - Distribuição Espacial dos Materiais Constituintes - Modelo Estatístico




Fonte: Autoria própria

Figura 60 - Distribuição Espacial dos Materiais Constituintes - Modelo Neural




Fonte: Autoria própria

Figura 61- Percentuais dos Materiais Constituintes - Modelo Estatístico



Fonte: Autoria própria

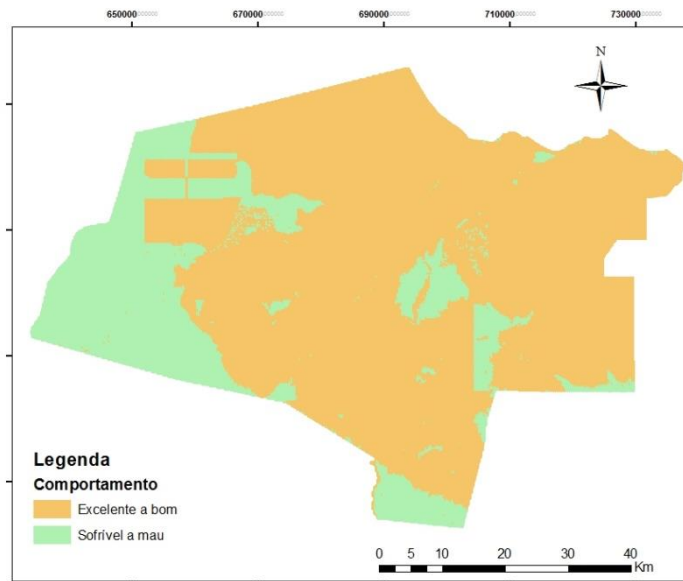
Figura 62 - Percentuais dos Materiais Constituintes - Modelo Neural



Fonte: Autoria própria

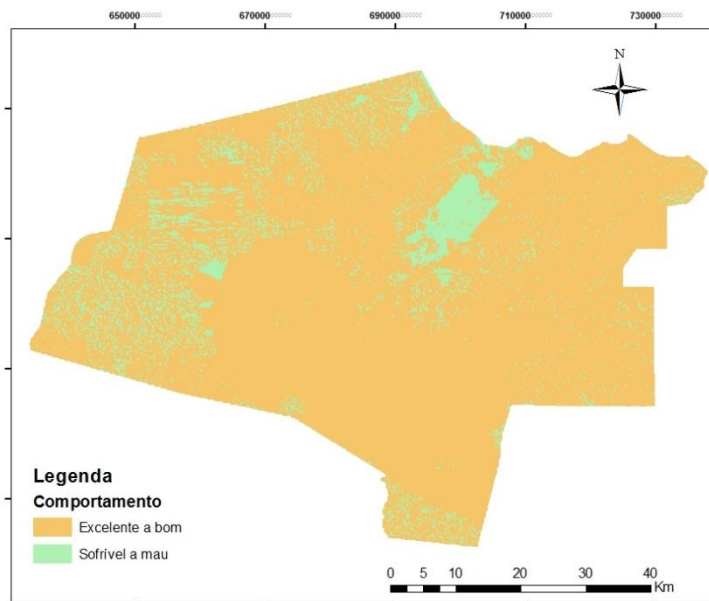
Do mapa de classificação AASHTO pode-se extrair as ocorrências de materiais granulares e materiais silto-argilosos, que refletem exatamente o provável comportamento como subleito da classificação AASHTO, que classifica os materiais em granulares com comportamento de excelente a bom como subleito e materiais silto-argilosos com comportamento de sofrível a mau como subleito, conforme mostram as Figuras 63 a 66, e observa-se que mais de 70% dos materiais que cobrem a MM são granulares e logo tem de um excelente a bom comportamento nas obras de engenharia.

Figura 63 - Comportamento como Subleito – Modelo Estatístico




Fonte: Autoria própria

Figura 64 - Comportamento como Subleito – Modelo Neural




Fonte: Autoria própria

Figura 65 - Percentuais do comportamento como Subleito – Modelo Estatístico



Fonte: Autoria própria

Figura 66 - Percentuais do comportamento como Subleito – Modelo Neural



Fonte: Autoria própria

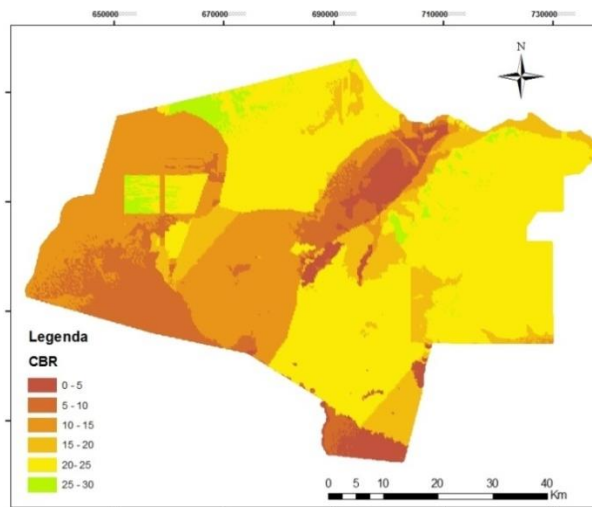
4.6.2 Modelagem do CBR (*California Bearing Ratio*)

Assim com a classificação AASHTO os valores de CBR foram generalizados para toda a MM com a mesma precisão dos modelos gerados. Tais valores de CBR foram modelados por faixas de intervalo igual a 5 (cinco) unidades. As Figuras 67 e 68 mostram os mapas que ilustram a generalização do modelo de previsão do CBR para toda MM. Para obter-se uma melhor compreensão e detalhamento dos valores de CBRs ocorrentes na MM, as Figuras 69 e

70 detalham melhor os percentuais referentes a cada valor de resistência mecânica através do CBR de solos da região.

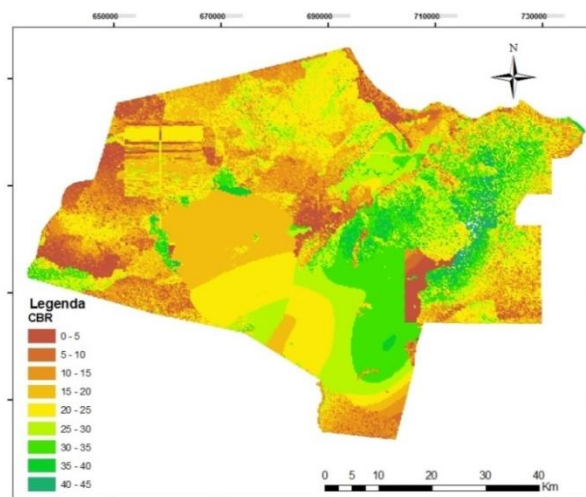
Observando-se os mapas e os gráficos mostrados nas Figuras de 65 a 68, verifica-se que, aproximadamente, para o modelo estatístico os valores máximos de CBR chegam a 30% e áreas são mais generalizadas, e o intervalo de 20 a 25% é o de maior predominância, com 48% dos solos da MM. Já o modelo neural consegue detalhar melhor as ocorrências, tendo áreas bastante mescladas e com maior variação de possibilidade de valores de CBR, extrapolando seu valor até o limite de 45%.

Figura 67 - Distribuição Espacial do CBR – Modelo Estatístico




Fonte: Autoria própria

Figura 68 - Distribuição Espacial do CBR – Modelo Neural




Fonte: Autoria própria

Figura 69 - Percentuais dos valores de CBR – Modelo Estatístico



Fonte: Autoria própria

Figura 70 - Percentuais dos valores de CBR – Modelo Neural

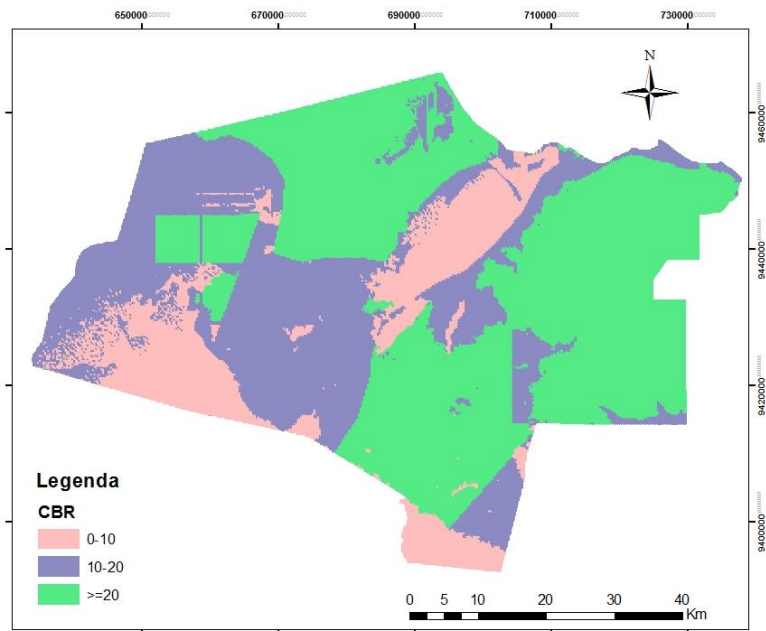


Fonte: Autoria própria

Com o objetivo de identificar melhor a aplicação dos solos de acordo com o seu valor de CBR os mapas das Figuras 67 e 68 foram refeitos extrapolando os intervalos, tendo como resultado os mapas e gráficos das Figuras de 71 a 74.

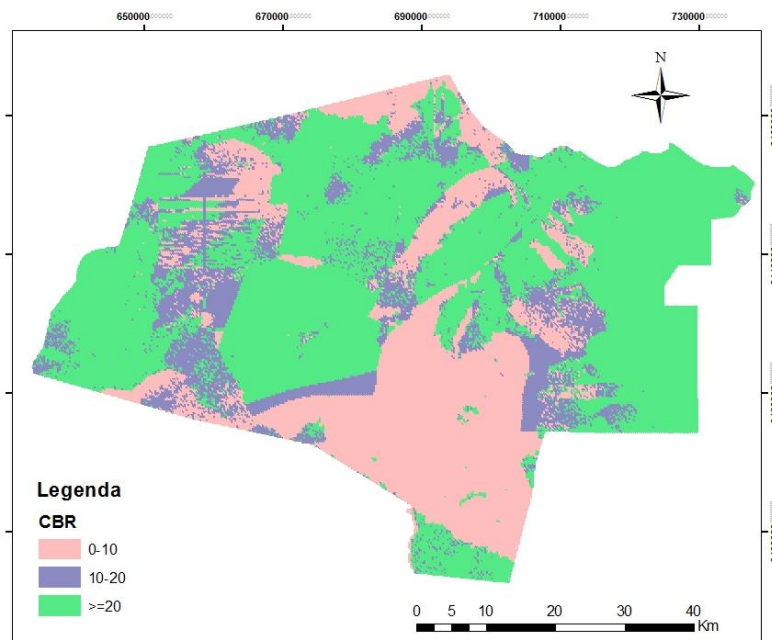
Pela observação desses elementos identificou-se que mais de 50% dos solos ocorrentes na MM podem ser empregados sem estabilização, em camadas de sub-base de pavimentos, pois podem apresentar valores acima de 20%.

Figura 71 - Distribuição Espacial do CBR em função da Aplicação – Modelo Estatístico




Fonte: Autoria própria

Figura 72 - Distribuição Espacial do CBR em função da Aplicação – Modelo Neural




Fonte: Autoria própria

Figura 73 - Percentual do CBR em função da Aplicação – Modelo Estatístico



Fonte: Autoria própria

Figura 74 - Percentual do CBR em função da Aplicação – Modelo Neural



Fonte: Autoria própria

Por fim, pode-se considerar que os dois modelos tem um índice de acerto bom, sendo o modelo neural mais bem ajustado, mas no geral muitas conclusões sobre os solos tem grande compatibilidade, de forma a afirmar que os solos da MM tem bom comportamento mecânico para serem empregados em camadas de pavimentos de baixo volume de tráfego e até rodovias com tráfego pesado sem necessidade de estabilização e que podem se comportar como subleito de forma bem razoável.

4.7 Considerações Finais

A constatação que se fez durante a fase de geração dos modelos baseia-se nas pesquisas feitas com as duas técnicas, onde as Redes Neurais se mostrou mais confiável frente o modelo estatístico. Na estatística teve-se um índice de correlação na ordem de 40% a 76% e na modelagem neural esse índice foi de 89% a 91%.

Na estatística percebeu-se que o incremento de variáveis ajusta melhor o modelo. Nas Redes neurais pode-se verificar durante a fase de implementação da árvore de testes a afirmação de CYBENKO (1988), onde afirma que “uma camada intermediária é suficiente para aproximar qualquer função contínua e duas camadas intermediárias aproximam qualquer função matemática”. Motivo provável pelo qual, topologias com mais de duas camadas intermediárias não trouxeram nenhum ganho à modelagem.

As melhores topologias encontradas apresentaram apenas uma camada intermediária, com 32 e 50 neurônios, sendo para a o CBR e para a Classificação AASHTO, respectivamente. Tais redes mostram-se eficientes, uma vez que para o modelagem do CBR obteve-se uma correlação de $R^2= 91\%$ entre os resultados esperados e os da saída da rede. Já a classificação AASHTO teve um índice de acertos de 89%.

Os trabalhos com modelagem estatística referem-se à ciência do solo, e apresentam resultados de classificação de solos de 45% a 72%, nesse estudo a classificação geotécnica de pavimentação obteve correlação de até 76% e taxa de acerto de 40%. Já para a predição do CBR teve taxas de acertos de 76%, que se mostra compatível com valores da faixa de acerto da técnica estatística.

O estado da arte das pesquisas feitas com RNA's mostra índices de acertos entre 77% e 92%. Como esperado o estudo aqui realizado obteve melhores resultados para a modelagem neural em comparação a modelagem estatística.

Chagas (2006) e Arruda *et al.* (2013) utilizaram atributos de terreno extraídos do MDE e a estimação da classificação de solos teve taxa de acertos de 70% a 72,75% e Ribeiro (2013) utilizou variáveis biofísicas e coordenadas geográficas para o mesmo fim e sua verificação foi de 92%, como essa investigação utilizou o conjunto de variáveis preditora dos dois trabalhos esperava-se uma boa porcentagem de acertos, que no caso foi de 89%, considerada de boa qualidade e comparável ao estudos na área.

Ribeiro (2013) utilizou das mesmas variáveis do modelo de classificação TRB para estimar o CBR, e a correlação encontrada foi de 90%. A modelagem do presente estudo agregou os atributos de terreno à variáveis preditoras e o percentil de acerto foi de 91%, refletindo a margem de resultado encontrado da literatura.

5 CONSIDERAÇÕES FINAIS

5.1 Considerações Iniciais

Esta pesquisa teve como objetivo principal a geração de modelos de localização e predição de características geotécnicas (Classificação AASHTO e CBR) de solos, com o intuito de contribuir no processo da tomada de decisão quanto à utilização de materiais para fins de pavimentação. Para tanto, foi selecionada a Microrregião de Mossoró como área de estudo, por ser uma região que liga dois importantes estados, Ceará e Paraíba, além da forte economia local e vem ganhando grandes intervenções na infraestrutura, incluindo a rodoviária.

A geração dos modelos baseou-se na existência apenas de dados secundários, sem a necessidade da realização de pesquisas de campo e/ou ensaios de laboratório que constituem uma etapa onerosa e demorada do projeto rodoviário. O estudo procurou tanto contribuir para o reconhecimento dos solos da MM, quanto na implementação de uma metodologia, de fácil replicação, para que se possa verificar a sua eficiência em outras áreas de estudo que se tenha interesse de reconhecer os parâmetros dos solos com fins de pavimentação.

A execução do trabalho aqui proposto representou um grande desafio de pesquisa, tendo em vista dificuldade de se conseguir informações geotécnicas disponíveis para área de estudo devido à burocracia dos órgãos competentes. Contudo os resultados obtidos mostram que o objetivo principal desta investigação foi alcançado, ou seja, é possível modelar o comportamento do subleito a partir de características biofísicas e geomorfométricas. Também conseguiu desenvolver e apresentar uma metodologia clara e objetiva para estimar características geotécnicas de solos, que permite um conhecimento prévio dessas informações sem necessidade de deslocamentos e sem investimentos em sondagens prévias para a área a ser estudada.

Espera-se que o estudo aqui gerado contribua para reconhecimento prévio dos solos da MM para finalidades de pavimentação, de maneira a propiciar a construção e conservação de rodovias de maneira mais econômica, segura, e com menor impacto para o meio ambiente. Espera-se também que essa pesquisa seja seguida de outras em que sejam fomentadas novas

soluções que, por sua vez, que contribuam para o conhecimento prévio dos solos e promova a economia nos projetos e na execução de pavimentos.

5.2 Principais Conclusões

A seguir são apresentadas as principais conclusões, sugestões e recomendações para estudos futuros obtidas da aplicação dos métodos gerados.

5.2.1 *Quanto aos Métodos Empregados*

Foram aplicados o método estatístico e o neural, pois numa pesquisa sobre estimação de solos encontrados na literatura esses foram os mais aplicados. Durante a implantação dos modelos observou-se o que mostra a revisão de literatura: os modelos Estatístico apresentaram acertos de 42 a 76% e os modelos neurais mostraram se mais eficientes, com acertos entre 89% a 91%.

Foram testados e implementados varias opções de modelo estatísticos, mas como esperado o melhor modelo foi o que teve mais dados de entradas, com uma boa diferença para as outras opções de modelo. Na modelagem neural foi realizada uma imensa árvore teste com um grande número de combinações de possibilidades na tentativa de se obter a melhor topologia, menor erro e maior índice de correlação. Não foi possível testar todas as possibilidades, e fica claro que podem existir outras topologias mais adequadas para o modelo, mas as topologias encontradas se mostrou eficiente para o parâmetro e fins desejados.

5.2.2 *Quanto às incertezas dos modelos gerados*

Os modelos de previsão de características geotécnicas (Classificação AASHTO e CBR) gerados neste trabalho tiveram os níveis de acertos considerados satisfatórios, e dentro do esperado, sendo os modelos neurais mais ajustados que os estatísticos, pela característica do modelo neural “aprender” as informações que lhe são dadas e poder estimar da melhor forma.

Como a medida de desempenho comum aos dois métodos é o índice de correlação, este foi utilizado como referência, e tais índices resultantes dos modelos gerados quando comparado à demais modelos geotécnicos vistos na literatura se comportaram tão bem quanto.

5.2.3 Quanto aos Modelos Proposto Para a Classificação AASHTO

De acordo com o modelo proposto para a classificação AASHTO, os solos ocorrentes na MM podem ser divididos inicialmente em dois grandes grupos: materiais granulares (comportamento granular) e materiais silto-argilosos (comportamento coesivo), que reflete no comportamento como subleito na aplicação da pavimentação. De acordo com os dois modelos gerados mais de 70% dos materiais que cobrem a MM são granulares e logo tem de um excelente a bom comportamento nas obras de engenharia, de acordo com a própria classificação.

E quanto às classes de solos AASHTO, os solos da região são predominantemente do tipo A-2-4, com ocorrência de A-2-6, A-4 e A-6. Já os grupos do tipo A-1-b e A-7-6 teve incidência apenas no modelo estatístico, sendo mesmo assim bem insignificante.

De maneira geral, os solos da MM podem ser considerados adequados para aplicação como subleito em pavimentação, não necessitando em sua maior parte de estabilização para tal finalidade.

Foram elaboradas diversas topologias na tentativa de encontrar um melhor modelo para estimar as classificações de solo segundo a AASHTO. A princípio aplicou-se os conjuntos de variáveis isoladas, obtendo para o caso das variáveis geomorfométricas correlação de no máximo 49% para o modelo estatístico e 78% para o modelo neural. Para as variáveis biofísicas esses valores foram de no máximo 75% pelo modelo estatístico e de 78% para o modelo neural. Ao acrescentar as coordenadas geográficas à essas variáveis teve-se um acréscimo no coeficiente de determinação, sendo esse valor de 64% para o modelo estatístico com as variáveis geomorfométricas e as coordenadas, e 72% também modelagem estatística para as variáveis biofísicas com as coordenadas. Na modelagem neural a porcentagem de acerto foi de 84% para essas duas estruturas. Tanto na modelagem estatística como na neural, percebeu-se que o incremento de mais variáveis melhora os modelos. No estrutura com todas

as variáveis propostas obteve-se os melhores resultados, inclusive foram os modelos escolhidos para prever as características geotécnicas estudadas. No modelo estatístico o modelo gerado apresenta R^2 de 0,76, mas um índice de acertos de 42%, já o modelo neural apresenta um percentual de acertos de 89%

5.3.4 Quanto aos Modelos de CBR

O modelo estatístico de previsão de CBR de solos proposto para a Microrregião de Mossoró tem seu valor máximo limitado a 30%, e cerca de 50% da área é representada por solo com valores de CBR's entre 20 a 25%. A principal diferença entre o modelo estatístico e o neural é a generalização. O modelo estatístico generaliza os resultados, enquanto o modelo neural tem maior capacidade de detalhamento. É tanto que neste modelo tem-se um limite maior do valor de CBR, podendo ter mais possibilidades de categorias, tendo também mais espalhamento das áreas.

No entanto, para os dois modelos, tem-se que pelo menos 50% da área de cobertura de solos da região podem apresentar valores de CBRs acima de 20%, sendo assim materiais apropriados para subleitos ou camadas mais nobres de pavimentos.

Ribeiro (2013) mapeou o CBR da Região Metropolitana de Fortaleza pelas redes neurais com nível de certeza 90%, utilizando com variáveis preditoras as variáveis físicas (pedologia, geomorfologia, geologia e vegetação) e as coordenadas geográficas (Norte, Este). Nesta pesquisa quando usados apenas essas características para a geração dos modelos pelas RNA's obteve-se um índice de determinação de 88%, mas quando foram adicionadas ao modelo as características geomorfométricas esse apresentou R^2 de 91%, o que mostra que o incremento dessas variáveis pode melhorar o desempenho do modelo.

Foram realizados outros modelos, inclusive considerando apenas essas variáveis geomorfométricas e não se obteve um bom resultado tanto para o modelo estatístico (0,13%) quanto para o modelo neural (0,67%), confirmando que o modelo com apenas as variáveis geomorfométricas não tem um bom poder explicativo. Assim como só as variáveis biofísicas também não, apesar de possuir um R^2 melhor, ainda apresentou-se baixo, com 0,52 para o modelo estatístico e 0,76 para o modelo neural. Mas foi possível observar que a adição das

coordenadas melhora os modelos, tendo o modelo com variáveis geomorfométricas e coordenadas R^2 de 62% para a estatística e 85% para a modelagem neural e o modelo com variáveis biofísicas e coordenadas R^2 de 63% e 88%, respectivamente para a modelagem estatística e neural. Observou-se ainda que os modelos neurais de modo geral apresentassem-se mais eficiente.

5.3 Recomendações e Sugestões para Trabalhos Futuros

A partir dos resultados obtidos e com base no conhecimento adquirido ao longo do desenvolvimento desta pesquisa, percebeu-se que existe a necessidade de trabalhos que venham a complementar este ou ainda melhorar e expandir a área de estudo da MM. Assim, recomenda-se realização das seguintes pesquisas:

- Recomenda-se para trabalhos futuros, a validação dos mapas gerados através da coleta e ensaio em laboratórios de solos de pontos espacialmente mais distribuídos na MM, principalmente distantes das rodovias, já que a maioria dos pontos estudados foram extraídos do eixo estradal dos projetos rodoviários. Podendo assim verificar a precisão dos mapas gerados;
- Recomenda-se aos órgãos rodoviários que construam uma base de dados com as informações geotécnicas das rodovias já construídas e/ou projetadas, além de instruir que os futuros projetos disponham de pontos locais. Essa ação facilitaria os trabalhos atuais e futuros a serem executados nas áreas de interesse e ainda subsidiaria um futuro trabalho do tipo aqui apresentado para outra região;
- Sugere-se a aplicação dessa metodologia na extrapolação do Estado do Rio Grande do Norte, e até para outras regiões do Brasil, de maneira que se possa ter o conhecimento prévio dos materiais que ocorrem em cada região para serem aplicados no projeto e construção de rodovias;
- Sugere-se que sejam pesquisados a possibilidade de outras variáveis que possam ser significativas para a predição dessas características geotécnicas;

- Sugere-se também que seja feito mapas de probabilidade de ocorrência das classes de solo, podendo se ter um valor em porcentagem que represente a chance de chance de ocorrência de determinada classe.

REFERÊNCIAS

- AMBRÓSIO, Paulo. Eduardo. **Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares**. Ribeirão Preto – SP: Dissertação (Mestrado) – Faculdade de Filosofia, Universidade de São Paulo. 2002.
- ARNOFF, Stanley. *Geographic information systems: A Management Perspective*. WDL Publications, Ottawa, Canada, 1995.
- BAILEY, N.; CLEMENTS, T.; LEE, J. T.; THOMPSON, S. **Modelling soil series data to facilitate targeted habitat restoration: a polytomous logistic regression approach**. Journal of Environmental Management, v. 67, n. 4, p. 395-407, 2003.
- BARBOSA, Cláudio Clemente Faria. **Álgebra de Mapas e Suas Aplicações em Sensoriamento Remoto e Geoprocessamento**. Dissertação (Mestrado em Sensoriamento Remoto), INPE, 1997.
- BARROSO, Suelly Helena de Araújo. **Estudo dos solos da Região Metropolitana de Fortaleza para aplicação na Engenharia Rodoviária**. Tese (Doutorado em Engenharia. Área: Transporte). USP. São Carlos. 253p.
- BERNUCCI, Liedi Bariani.; MOTTA, Laura Maria Goretti da; CERATTI, Jorge Augusto Pereira; SOARES, Jorge Barbosa. **Pavimentação asfáltica: formação básica para engenheiros**. PETROBRAS:ABEDA,2006.
- BOCANEGRA, Charlie Williams Rengifo. **Procedimentos para tornar mais efetivo o uso de Redes Neurais Artificiais em planejamento de transportes**. Dissertação (Mestrado em Engenharia Civil. Área: Transportes). USP-São Carlos, Departamento de Engenharia de Transportes. São Carlos-SP, 2002.
- BURROUGH, Peter A., MCDONNELL, Rachel A. *Principles of geographical information Systems*. Oxford, Clarendon Press, 2a edição, 311p, 1998.
- BRAGA, Antonio de Pádua; CARVALHO, André Ponce de Leon F. de; LUDERMIR. Teresa Bernarda. **Redes neurais artificiais: Teoria e Aplicações**. Editora LTC. Rio de Janeiro. RJ.2000.
- CÂMARA, Gilberto; MEDEIROS, Cláudia. M. B.; CASA NOVA, Marco A.; HEMERLY, Andrea S.; MAGALHÃES, Geovane. **Anatomia de sistemas de informação geográfica**. Escola de Computação, SBC, 1996.
- CATEN, Alexandre ten. **Aplicação de componentes principais e regressões logísticas múltiplas em sistema de informações geográficas para a predição e o mapeamento digital de solos**. Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós- Graduação em Ciência do Solo, RS, 2008.

CHAGAS, César da Silva. **Mapeamento Digital dos Solos por Correlação Ambiental e Redes Neurais em uma bacia hidrográfica no domínio de mar e morros.** Tese de Doutorado, UFV, Viçosa, MG, 2006.

CHAVES, Franklin José. **Caracterização geotécnica de solos da formação barreiras da região metropolitana de Fortaleza para aplicação em obras rodoviárias.** Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

CYBENKO, George. *Approximation by superpositions of a sigmoidal function.* Urbana, IL: University of Illinois, 1988.

COELHO, Fabrício Fernandes; GIASSON, Elvio. **Métodos para mapeamento digital de solos com utilização de sistema de informação geográfica.** Ci. Rural, 40:2099-2106, 2010.

COUTINHO, João Camilo Penna. **Dimensionamento de pavimentos asfáltico:** comparação do método do dner com o método mecanístico – emprico aplicada a um trecho. Dissertação (Mestrado) – Universidade Federal de Ouro Preto. Escola de Minas, MG.

DA SILVA, Carlos Augusto Uchõa. **Um método para estimar observáveis GPS usando redes neurais artificiais.** Tese de Doutorado, EESC-USP, Departamento de Transportes, São Carlos, SP, 2003.

DAVISON DIAS, Regina. **Metodologia de estudo do comportamento geotécnico dos solos do rio grande do sul, visando a cartografia.** In. Colóquio de solos Tropicais e Subtropicais e suas aplicações em Engenharia Civil. Anais . Porto Alegre, 1989.

DAVISON DIAS, Regina. **Proposta de metodologia de definição de carta geotécnica básica em regiões tropicais e subtropicais.** Artigo obtido na Revista IG, v. especial, São Paulo, SP, 1995.

DNER - Departamento Nacional De Estradas De Rodagem, (1996). **Manual de pavimentação.** 2^a. Edição. Rio de Janeiro –RJ.320p.

DNIT - Departamento Nacional de Infraestrutura de Transportes (2006). **Manual de pavimentação.** 3^a Edição

DNIT - Departamento Nacional de Infraestrutura de Transporte. Norma DNIT 134/2010 – ME: Pavimentação – Solos – **Determinação do módulo de resiliência - método do ensaio.** Diretoria Geral, Diretoria Executiva, Instituto de pesquisa Rodoviárias, Rio de Janeiro, RJ, 2010. 10P.

EMPRAPA. Empresa Brasileira de Pesquisa Agropecuária. Disponível em <<http://www.uep.cnps.embrapa.br/solos/index.php?link=rn>> Acesso em: 15 de Novembro de 2014.

FABRI, José Augusto; GENVIGIR, Elias Canhadadas; L'ERARIO, Alexandre; PALÁCIOS, Rodrigo Henrique Cunha. **A model propose of requirements traceability based on mind maps**. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, Paraná, 2012.

FALAS, T. (1995). **Neural networks in empirical accounting research**: na alternative to statistical models. *Neural Network World*, v.5, n.4, 1995.

FENSTERSTOCK, F. **Credit scoring and the next step**. *Business Credit*, New York, v. 107, n. 3, 2005.

FIGUEIREDO, S. R. **Mapeamento supervisionado de solos através do uso de regressões logísticas múltiplas e sistema de informações geográficas**. 96f. Dissertação (Mestrado em Ciência do Solo), Universidade Federal do Rio Grande do Sul, Porto Alegre.

FIORINI, Daniel V.; MARTINS, Fernando. R.; SCHUCH, Nelson J.; PEREIRA, Enio B. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. *Revista Brasileira de Ensino de Física*. vol.33 no.1 São Paulo, 2011.

GALLANT, John C.; WILSON, John P. Primary topographic attributes. In: WILSON, J. P.; GALLANT, J. C. (Eds.). ***Terrain analysis: principles and applications***. New York: John Wiley, 2000.

GIASSON, Elvio; INDA JUNIOR, Alberto Vasconcellos.; NASCIMENTO, Paulo César do **Estimativa do benefício econômico potencial de dois levantamentos de solos no Estado do Rio Grande do Sul**. *Ciência Rural*, Santa Maria, v. 36, p. 478-486, 2006.

HAYKIN, Simon. **Neural networks: A Comprehensive Foundation**. Second Edition, Pearson Education, McMasterUniversity, Hamilton, Ontario, Canada.

HECHT-NIELSEN, Robert. **Neurocomputing**. Addison-Wesley Longman Publishing Co. Inc. Boston, 1889.

HENGL, Tomislav; ROSSITER, David G. ***Supervised landform classification to enhance and replace photo-interpretation in semi-detailed soil survey***. *Soil Science Society of America Journal*, Madison, v. 67, n. 6, p. 1810, 2003.

HENGL, T.; TOOMANIAN, N.; REUTER, H.I.; MALAKOUTI, M.J. (2007). ***Methods to interpolate soil categorical variables from profile observations***: lessons from Iran. *Geoderma*, v.140, p.417-427, 2007.

IBGE (1990). **Divisão do Brasil em mesorregiões e microrregiões geográficas**. Vol I. Rio de Janeiro: Fundação do Instituto Brasileiro de Geografia e Estatística (FIBGE). Diretoria de Geociências (DGC) e Departamento de Geografia (DEGEO). Rio de Janeiro. 1990. 137 p.

IDEMA. Instituto de Desenvolvimento Sustentável e Meio Ambiente do Rio Grande do Norte (2014). **Perfil do Rio Grande do Norte**.

JENNY, H. **Factors of soil formation**. McGraw-Hill, NY, 1941

JENSON S. K.; DOMINGUE J. O. **Extracting topographic structure from digital elevation data for geographic information system analysis**. Photogrammetric Engineering and Remote Sensing. Vol 54, 1988.

LIPPMANN, Richard P. **An introduction to computing with neural nets**. IEEE ASSP Magazine, vol.4, pp 4-22, 1987.

LEMOS, Jeanderson Rodrigues; SANTOS, Adailton Antônio. **Desenvolvimento de ferramenta computacional para dimensionamento de pavimentos pelo método do DNER e da resiliência**. UNESC –Universidade do Extremo Sul Catarinense. 2013.

MARANGON, Márcio. **Proposição de estruturas típicas de pavimentos para região de minas gerais utilização solos lateríticos locais a partir da pedologia, classificação mct e resiliência**. (COPPE/UFRJ, D.Sc., Engenharia Civil,)Tese – Universidade Federal do Rio de Janeiro.

MATULA, M **Engineering geology in country and urban planning**. In: Int Cong Eng Geology, 2, São Paulo. Proceedings. V., 1974

MASTERS, Timothy. **Signal and image processing with neural networks - Ac++ Sourcebook**. John Wiley & Sons.Inc, New York, 1994.

McBRATNEY, A. B.; MENDONÇA-SANTOS, M. L.; MINASNY, B. **On digital soil mapping**. Geoderma, v. 117, 2003.

MIRANDA, Talita Caroline. **Mapeamento das unidades geotécnicas e desenvolvimento de um sistema de informações geográficas para área de abrangência da rodovia BR-101/RS**. Dissertação de Mestrado, UFRS, Departamento de Engenharia Civil, Porto Alegre, RS, 2008.

MOORE, I. D.; GISSLER, P. E.; NIELSEN, G. A.; PETERSON, G. A. **Soil attribute prediction using terrain analysis**. Soil Science Society of America Journal, v.57, 1993.

MORETI, Ricardo de Sousa. **Avaliação das perspectivas de avaliação da cartografia geotécnica no planejamento urbano**. In: Cólóquio de solos tropicais e subtropicais e suas aplicações em engenharia civil, Amais p257-267, Porto Alegre, RS, 1989.

NANNI, Marcos Rafael. **Delimitação de unidades fisiográficas para estudo de solos utilizando análise multivariada e técnicas de sensoriamento remoto**. Dissertação de Mestrado, Curso de Pós Graduação em Agronomia/UFPR, Paraná, PR,Brasil.

NOGAMI, Job Shuji; VILLIBOR, Douglas Fadul. **Pavimentação de baixo custo com solos lateríticos**. Editora Vilibor, São Paulo, SP, 1995.

NOGAMI, Job Shuji; VILLIBOR, Douglas Fadul. **Uma nova classificação de solos para finalidades rodoviárias.** In: Simpósio Brasileiro de Solos Tropicais em Engenharia. Rio de Janeiro, 1981.

PAIS DE ARRUDA, Gustavo; DEMATTÊ, José Alexandre M.; DA SILVA CHAGAS, César. **Mapeamento digital de solos por redes neurais artificiais com base na relação solo-paisagem.** Revista Brasileira de Ciência do Solo, 2013

PEREIRA, Alexandre. **Guia prático de utilização do SPSS: Análise de Dados Para Ciências Sociais e Psicologia.** Lisboa: Sílabo, 2006.

PINHO, Leandro de Andrade Lameira. **Cartografia geotécnica de parte das áreas do município de Japeri e rural do município de Seropédica, com base na definição de unidades geomorfológicas.** Monografia de Graduação. LAMAGE/UFRRJ. Seropédica, RJ, Brasil.

RIBEIRO, Antonio Júnior de Alves, DA SILVA, Carlos Augusto Uchôa, BARROSO, Suelly Helena de Araújo. **Estimação e mapeamento do comportamento mecânico dos solos no estado do Ceará como apoio ao dimensionamento mecanísticoempírico de pavimentos.** XXVIII Congresso de Pesquisa e Ensino em Transportes. Curitiba, PR, 2010.

RIBEIRO, Antonio Júnior de Alves. **Um método para localização e estimação geotécnicas dos solos da região metropolitana de Fortaleza –CE para fins de pavimentação.** Dissertação (Mestrado). Universidade Federal do Ceará, Departamento de Engenharia de Transportes, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, Ceará, 2013.

RIBEIRO, Antonio Júnior de Alves, DA SILVA, Carlos Augusto Uchôa, BARROSO, Suelly Helena de Araújo. *Neural estimation of localization and classification of soils for use in low-traffic-volume roads.* Transportation Research Record , v. 2473, p. 98-106, 2015.

RIBEIRO, Rochele Amorim, AYMONE, José Luis Farinatti, LEÃO, Simone Zarpelon. **Aplicação do geoprocessamento no estudo da impermeabilidade urbana.** Programa de Pós-graduação em Planejamento Urbano e Regional – PROPUR. Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, 2006.

RUMELHART, Davis E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. *Learning representations by back-propagating errors.* In Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1: Foundations (eds Rumelhart, D. E. & McClelland, J. L.) 318–362 (MIT, Cambridge, 1986).

SILVA, Felipe da Cruz Santos; NETO, Murilo Russo; **redes neurais artificiais e as células da glia:** Novas Pesquisas na Área da Neurociência. Faculdade De Ciências e Tecnologia. Monografia. Universidade Santa Cecília. Santos, SP, 2011.

SIRTOLI, Angelo Evaristo. **Mapeamento de solos com auxílio da geologia, atributos do terreno e índices espectrais integrados por redes neurais artificiais.** Tese (Doutorado em Geologia). Universidade Federal do Paraná, Curitiba, 2008.

SOUZA JÚNIOR, Tadeu Antonio Torquato. **Respostas estruturais em pavimentos flexíveis via utilização de equações de módulos de resiliência de solos de subleito e da camada de reforço.** Dissertação (Pós-Graduação). Viçosa, MG, 2011.

SUBRAMANIAN, V.; HUNG, M.S.; HU.M.Y. (1993). *Na experimental evaluation of neural networks for classification.* Computer & Operations Research, v.20, n.7. 1993.

TEN CATEN, Alexandre; DALMOLIN, Ricardo Simão Diniz; RUIZ, Luiz Fernando Chimelo; SEBEM, Elódio; PEREIRA, Rudiney Soares. **Mapeamento digital de solos através da aplicação de componentes principais em modelos logísticos.** In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2009, Natal, RN. Anais... São José dos Campos: INPE, 2009.

TOMLIN, Dana. *Geographic information systems and cartographic modeling.* Prentice Hall, New York, 1990.

VALENTE, Antonio Luis Schifino. **Integração de dados por meio de geoprocessamento, para elaboração de mapas geotécnicos análise do meio físico e suas interseções como mancha urbana: o caso de Porto Alegre (RS).** Dissertação de Mestrado, PPGEM/UFRS, Rio Grande do Sul, RS, Brasil.

VALERIANO, Márcio de M. **Curvatura vertical de vertentes em microbacias pela análise de modelos digitais de elevação.** Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v.7, n.3, p.539-546, 2003.

VILLIBOR, D. F.; NOGAMI, J. S.; BELIGNI, M. e CINCERRE, J. R. **Pavimentos com solos lateríticos e gestão de manutenção de vias urbanas.** In: Anais da X Reunião Anual de Pavimentação. Uberlândia, Mg, 2000.

ZHU, A.-Xing. *Mapping soil landscape as spatial continua: the neural network approach.* Water Res. Res., 36:663-667, 2000.

ZUQUETTE, Lazaro Valentim. **Mapeamento geotécnico preliminar na região de São Carlos.** Dissertação de Mestrado, Departamento de Geotecnia. Departamento de Geotecnia, Escola de Engenharia de São Carlos, Universidade de São Paulo, 1981.

ANEXO I - Resultado Da Regressão Linear Múltipla – (Software SPSS)

Regression

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	V5,G5,V1,P5, Direção de Fluxo, Perfil de Curvatura, GM3, P4, Plano de Curvatura, Iluminação, GM1, Comprimento de Fluxo, Aspecto, Declividade, V4, P3, V2, Fluxo Acumulado, G1, Elevação, G3, Norte, Este, G4, P2, GM4		Enter

a. Tolerance = ,000 limits reached. b. Dependent Variable: CBR

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,872 ^a	,761	,760	3.83822

a. Predictors: (Constant), V5, G5, V1, P5, Direção de Fluxo, Perfil de Curvatura, GM3, P4, Plano de Curvatura, Iluminação, GM1, Comprimento de Fluxo, Aspecto, Declividade, V4, P3, V2, Fluxo Acumulado, G1, Elevação, G3, Norte, Este, G4, P2, GM4

b. Dependent Variable: CBR

Model Summary^b

Model	Sum of Squares	Df	Mean Square	F	Sig.
1 Regression	765977,447	26	29460,671	1999,787	,000
Residual	240910,774	16353	14,732		
Total	1006888,221	16379			

a. Predictors: (Constant), V5, G5, V1, P5, Direção de Fluxo, Perfil de Curvatura, GM3, P4, Plano de Curvatura, Iluminação, GM1, Comprimento de Fluxo, Aspecto, Declividade, V4, P3, V2, Fluxo Acumulado, G1, Elevação, G3, Norte, Este, G4, P2, GM4

b. Dependent Variable: CBR

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients		Sig
	B	Sta. Error	Beta	t	
	(Constant)	-546,784	45,575		
Declividade	,047	,020	,010	2,288	,022
Elevação	-,005	,001	-,040	-6,345	,000
Iluminação	-,014	,006	-,010	-2,518	,012
Aspecto	-,001	,000	-,007	-1,732	,083
Perfil de Curvatura	,152	,110	,005	1,377	,169
Plano de Curvatura	-,056	,073	-,003	-,757	,449
Fluxo Acumulado	-8,849E-6	,000	-,003	-,668	,504
Direção de Fluxo	1,315E-5	,000	,004	,964	,335
Comprimento de Fluxo	-3,290E-7	,000	-,001	-,117	,907
Norte	6,638E-5	,000	,106	14,026	,000
Este	-7,635E-5	,000	-,304	-20,522	,000
P2	-12,044	,258	-,748	-46,739	,000
P3	-8,749	,446	-,092	-19,617	,000
P4	-13,152	,288	-,357	-45,592	,000
P5	,855	,206	,017	4,157	,000
GM1	-1,149	,252	-,051	-4,553	,000
GM3	7,440	,606	,164	12,268	,000
GM4	2,978	,276	,183	10,780	,000
G1	-3,580	,151	-,228	-23,768	,000
G3	-3,898	,639	-,043	-6,099	,000
G4	-6,848	,561	-,141	-12,201	,000
G5	-15,847	,851	-,079	-18,625	,000
V1	-,284	,344	-,003	-,824	,410
V2	-3,104	,296	-,056	-10,488	,000
V4	-,655	,067	-,041	-9,780	,000
V5	-7,187	,742	-,051	-9,686	,000

Excluded Variables^b

Model	Beta In	T	Sig.	Partial Correlation	Collinearity Statistics Tolerance
1 P1	,000 ^a	,000	1,000	,000	1,762E-13
GM2	a	.	.	.	,000
GM5	a	.	.	.	-1,879E-13
GM6	a	.	.	.	,000
G2	a	.	.	.	-1,413E-13
V3	a	.	.	.	-1,404E-13

a. Predictors in the Model: (Constant), V5, G5, V1, P5, Direção de Fluxo, Perfil de Curvatura, GM3, P4, Plano de Curvatura, Iluminação, GM1, Comprimento de Fluxo, Aspecto, Declividade, V4, P3, V2, Fluxo Acumulado, G1, Elevação, G3, Norte, Este, G4, P2, GM4


b. Dependent Variable: CBR

Residuais Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	3,2935	27,4581	17,0541	6,83855	16380
Residual	-12,20486	20,51797	,00000	3,83517	16380
Std. Predicted Value	-2,012	1,521	,000	1,000	16380
Std. Residual	-3,180	5,346	,000	,999	16380


a. Dependent Variable: CBR

Charts



Scatterplot

Dependent Variable: CBR



ANEXO II - Resultado Da Regressão Logística Múltipla – (Software SPSS)

Nominal Regression

Warnings

Unexpected singularities in the Hessian matrix are encountered. This indicates that either some predictor variables should be excluded or some categories should be merged.

The NOMREG procedure continues despite the above warning(s). Subsequent results shown are based on the last iteration. Validity of the model fit is uncertain.

		N	Marginal Percentage
AASHTO	A-1-A	70	,4%
	A-1-B	49	,3%
	A-2-4	9382	57,3%
	A-2-6	1173	7,2%
	A-4	1714	10,5%
	A-6	3892	23,8%
	A-7-5	20	,1%
	A-7-6	80	,5%
Valid		16380	100,0%
Missing		0	
Total		16380	
Subpopulation		15821	

a. The dependent variable has only one value observed in 15821 (100,0%) subpopulations.

Model Fitting Information

Model	Model Fitting Criteria	Likelihood Ratio Tests		
	-2 Log Likelihood	Chi-Square	df	Sig.
Intercept Only	38019,4			
Final	19049,2	18970,1	105	,000

Pseudo R-Square

Cox and Snell	,686
Nagelkerke	,761
McFadden	,499

Likelihood Ratio Tests

Effect	Model Fitting Criteria	Likelihood Ratio Tests		
	-2 Log Likelihood of Reduced Model	Chi-Square	df	Sig.
Intercept	33730,8	14681,6	7	,000
Vegetação	19055,8	6,639	7	,467
Geologia	19242,4	193,197	7	,000
Geomorfologia	19244,4	195,210	7	,000
Pedologia	19277,9	228,732	7	,000
Declividade	19147,0	97,812	7	,000
Elevação	19411,6	362,419	7	,000
Iluminação	19123,5	74,354	7	,000
Aspecto	19096,1	46,874	7	,000
Perfil_curvatura	19066,6	17,400	7	,015
plano_curvatura	19068,0	18,857	7	,009
Fluxo_Acumulado	19054,6	5,384	7	,613
Direção_Fluxo	19067,5	18,301	7	,011
ComprimentoFluxo	19670,6	621,400	7	,000
Norte	19821,8	772,610	7	,000
Este	21122,5	2073,27	7	,000

The chi-square statistic is the difference in -2 log-likelihoods between the final model and a reduced model. The reduced model is formed by omitting an effect from the final model. The null hypothesis is that all parameters of that effect are 0.

- The log-likelihood value cannot be further increased after maximum number of step-halving.
- Unexpected singularities in the Hessian matrix are encountered. This indicates that either some predictor variables should be excluded or some categories should be merged.

Parameter Estimates

AASHTO		B	Std. Error	Wald	df	Sig.
A-1-A	Intercept	-6087,549	815,554	55,716	1	,000
	Vegetação	-2,436	,486	25,157	1	,000
	Geologia	1,523	3,041	,251	1	,617
	Geomorfologia	1,869	1,414	1,748	1	,186
	Pedologia	-5,933	5,417	1,200	1	,273
	Declividade	,102	,157	,428	1	,513
	Elevação	,035	,013	7,787	1	,005
	Iluminação	-,245	,052	22,332	1	,000
	Aspecto	,009	,002	15,652	1	,000
	Perfil_curvatura	3,275	5,186	,399	1	,528
	plano_curvatura	-,209	,505	,171	1	,679
	Fluxo_Acumulado	,001	,002	,544	1	,461
	Direção_Fluxo	,001	,001	,276	1	,599
	ComprimentoFluxo	,000	,000	17,446	1	,000
	Norte	,001	,000	57,957	1	,000
	Este	,000	,000	3,988	1	,046
	A-1-B	Intercept	-5003,334	43,221	13400,684	1
Vegetação		,357	,550	,420	1	,517
Geologia		4,959	3,070	2,609	1	,106
Geomorfologia		2,287	1,160	3,886	1	,049
Pedologia		2,615	1,636	2,555	1	,110
Declividade		,909	,166	30,155	1	,000
Elevação		-,031	,013	5,772	1	,016
Iluminação		-,116	,064	3,288	1	,070
Aspecto		,004	,003	2,521	1	,112
Perfil_curvatura		5,095	5,183	,966	1	,326
plano_curvatura		-,220	,577	,146	1	,702
Fluxo_Acumulado		,001	,002	,643	1	,423
Direção_Fluxo		,001	,001	,255	1	,614
ComprimentoFluxo		,000	,000	7,259	1	,007
Norte		,001	,000		1	
Este		,000	,000	4,443	1	,035

Parameter Estimates

AASHTO		95% Confidence Interval for Exp (B)		
		Exp(B)	Lower Bound	Upper Bound
A-1-A	Intercept			
	Vegetação	,088	,034	,227
	Geologia	4,585	,012	1775,952
	Geomorfologia	6,483	,406	103,587
	Pedologia	,003	6,494E-8	108,187
	Declividade	1,108	,815	1,506
	Elevação	1,036	1,011	1,062
	Iluminação	,783	,707	,867
	Aspecto	1,009	1,005	1,014
	Perfil_curvatura	26,432	,001	685662,193
	plano_curvatura	,812	,301	2,185
	Fluxo_Acumulado	1,001	,998	1,004
	Direção_Fluxo	1,001	,998	1,004
	ComprimentoFluxo	1,000	1,000	1,001
	Norte	1,001	1,000	1,001
	Este	1,000	1,000	1,000
	A-1-B	Intercept		
Vegetação		1,428	,486	4,200
Geologia		142,442	,347	58453,730
Geomorfologia		9,843	1,013	95,621
Pedologia		13,668	,554	337,452
Declividade		2,482	1,794	3,434
Elevação		,970	,946	,994
Iluminação		,891	,786	1,009
Aspecto		1,005	,999	1,010
Perfil_curvatura		163,172	,006	4207405,671
plano_curvatura		,802	,259	2,484
Fluxo_Acumulado		1,001	,998	1,004
Direção_Fluxo		1,001	,998	1,004
ComprimentoFluxo		1,000	1,000	1,000
Norte		1,001	1,001	1,001
Este		1,000	1,000	1,000

Parameter Estimates

AASHTO		B	Std. Error	Wald	df	Sig.
A-2-4	Intercept	-2973,003	397,259	56,007	1	,000
	Vegetação	-,461	,301	2,343	1	,126
	Geologia	1,797	3,023	,353	1	,552
	Geomorfologia	,734	1,101	,444	1	,505
	Pedologia	2,847	1,465	3,778	1	,052
	Declividade	,223	,128	3,003	1	,083
	Elevação	-,002	,005	,195	1	,659
	Iluminação	-,236	,043	30,652	1	,000
	Aspecto	,006	,002	11,946	1	,001
	Perfil_curvatura	4,119	5,157	,638	1	,424
	plano_curvatura	-,615	,341	3,259	1	,071
	Fluxo_Acumulado	,001	,002	,683	1	,408
	Direção_Fluxo	,001	,001	,339	1	,561
	ComprimentoFluxo	,000	,000	15,035	1	,000
	Norte	,000	,000	57,152	1	,000
	Este	,000	,000	70,260	1	,000
A-2-6	Intercept	-1579,700	397,530	15,791	1	,000
	Vegetação	-,166	,300	,304	1	,581
	Geologia	2,051	3,023	,460	1	,498
	Geomorfologia	,819	1,101	,553	1	,457
	Pedologia	2,486	1,465	2,881	1	,090
	Declividade	,296	,129	5,312	1	,021
	Elevação	-,020	,005	15,130	1	,000
	Iluminação	-,201	,043	21,697	1	,000
	Aspecto	,006	,002	12,893	1	,000
	Perfil_curvatura	4,406	5,157	,730	1	,393
	plano_curvatura	-,933	,341	7,488	1	,006
	Fluxo_Acumulado	,001	,002	,648	1	,421
	Direção_Fluxo	,001	,001	,227	1	,634
	ComprimentoFluxo	,000	,000	,177	1	,674
	Norte	,000	,000	16,368	1	,000
	Este	,000	,000	20,074	1	,000

Parameter Estimates

AASHTO		Exp(B)	Lower Bound	Upper Bound
A-2-4	Intercept			
	Vegetação	,631	,350	1,138
	Geologia	6,029	,016	2257,077
	Geomorfologia	2,083	,241	18,012
	Pedologia	17,234	,976	304,240
	Declividade	1,249	,971	1,607
	Elevação	,998	,988	1,008
	Iluminação	,790	,727	,859
	Aspecto	1,006	1,003	1,009
	Perfil_curvatura	61,518	,003	1508788,297
	plano_curvatura	,541	,277	1,054
	Fluxo_Acumulado	1,001	,998	1,004
	Direção_Fluxo	1,001	,998	1,004
	ComprimentoFluxo	1,000	1,000	1,000
	Norte	1,000	1,000	1,000
	Este	1,000	1,000	1,000
A-2-6	Intercept			
	Vegetação	,847	,470	1,527
	Geologia	7,772	,021	2909,239
	Geomorfologia	2,268	,262	19,628
	Pedologia	12,013	,681	212,045
	Declividade	1,345	1,045	1,731
	Elevação	,981	,971	,990
	Iluminação	,818	,751	,890
	Aspecto	1,006	1,003	1,009
	Perfil_curvatura	81,914	,003	2008222,063
	plano_curvatura	,394	,202	,767
	Fluxo_Acumulado	1,001	,998	1,004
	Direção_Fluxo	1,001	,998	1,003
	ComprimentoFluxo	1,000	1,000	1,000
	Norte	1,000	1,000	1,000
	Este	1,000	1,000	1,000

Parameter Estimates

AASHTO		B	Std. Error	Wald	df	Sig.
A-4	Intercept	-1610,093	396,834	16,462	1	,000
	Vegetação	-,572	,297	3,700	1	,054
	Geologia	,530	3,025	,031	1	,861
	Geomorfologia	,417	1,101	,143	1	,705
	Pedologia	1,936	1,465	1,747	1	,186
	Declividade	,175	,128	1,869	1	,172
	Elevação	-,016	,005	10,686	1	,001
	Iluminação	-,183	,043	18,210	1	,000
	Aspecto	,008	,002	20,978	1	,000
	Perfil_curvatura	4,016	5,156	,607	1	,436
	plano_curvatura	-,743	,336	4,883	1	,027
	Fluxo_Acumulado	,001	,002	,696	1	,404
	Direção_Fluxo	,001	,001	,358	1	,550
	ComprimentoFluxo	,000	,000	,000	1	,998
	Norte	,000	,000	17,477	1	,000
	Este	,000	,000	10,180	1	,001
	A-6	Intercept	-1821,466	396,220	21,133	1
Vegetação		-,072	,295	,060	1	,806
Geologia		2,588	3,024	,732	1	,392
Geomorfologia		1,418	1,103	1,654	1	,198
Pedologia		2,345	1,464	2,564	1	,109
Declividade		,309	,127	5,947	1	,015
Elevação		-,020	,005	16,807	1	,000
Iluminação		-,239	,042	31,847	1	,000
Aspecto		,006	,002	14,573	1	,000
Perfil_curvatura		4,059	5,156	,620	1	,431
plano_curvatura		-,870	,333	6,829	1	,009
Fluxo_Acumulado		,001	,002	,701	1	,403
Direção_Fluxo		,001	,001	,334	1	,563
ComprimentoFluxo		,000	,000	18,457	1	,000
Norte		,000	,000	22,833	1	,000
Este		,000	,000	5,403	1	,020

Parameter Estimates

AASHTO		Exp(B)	Lower Bound	Upper Bound
A-4	Intercept			
	Vegetação	,564	,315	1,011
	Geologia	1,699	,005	638,614
	Geomorfologia	1,517	,175	13,125
	Pedologia	6,932	,393	122,395
	Declividade	1,191	,927	1,529
	Elevação	,984	,974	,993
	Iluminação	,833	,766	,906
	Aspecto	1,008	1,004	1,011
	Perfil_curvatura	55,493	,002	1359475,532
	plano_curvatura	,476	,246	,919
	Fluxo_Acumulado	1,001	,998	1,004
	Direção_Fluxo	1,001	,998	1,004
	ComprimentoFluxo	1,000	1,000	1,000
	Norte	1,000	1,000	1,000
	Este	1,000	1,000	1,000
	A-6	Intercept		
Vegetação		,930	,522	1,657
Geologia		13,299	,035	4983,525
Geomorfologia		4,130	,476	35,868
Pedologia		10,430	,591	183,941
Declividade		1,362	1,062	1,745
Elevação		,980	,970	,989
Iluminação		,787	,724	,855
Aspecto		1,006	1,003	1,010
Perfil_curvatura		57,915	,002	1416915,434
plano_curvatura		,419	,218	,805
Fluxo_Acumulado		1,001	,998	1,004
Direção_Fluxo		1,001	,998	1,004
ComprimentoFluxo		1,000	1,000	1,000
Norte		1,000	1,000	1,000
Este		1,000	1,000	1,000

Parameter Estimates

AASHTO		B	Std. Error	Wald	df	Sig.
A-7-5	Intercept	-13621,421	2802,734	23,620	1	,000
	Vegetação	-1,087	2,624	,172	1	,679
	Geologia	-29,873	9,867	9,165	1	,002
	Geomorfologia	15,875	5,880	7,290	1	,007
	Pedologia	8,215	2,109	15,179	1	,000
	Declividade	,517	,291	3,167	1	,075
	Elevação	,158	,037	18,003	1	,000
	Iluminação	-,255	,150	2,868	1	,090
	Aspecto	-,004	,009	,171	1	,679
	Perfil_curvatura	2,072	6,370	,106	1	,745
	plano_curvatura	-4,817	4,171	1,334	1	,248
	Fluxo_Acumulado	,001	,002	,607	1	,436
	Direção_Fluxo	,001	,002	,294	1	,588
	ComprimentoFluxo	,000	,000	,097	1	,755
	Norte	,001	,000	23,055	1	,000
	Este	,001	,000	27,791	1	,000

Parameter Estimates

AASHTO		Exp(B)	Lower Bound	Upper Bound
A-7-5	Intercept			
	Vegetação	,337	,002	57,742
	Geologia	1,063E-13	4,240E-22	2,665E-5
	Geomorfologia	7841251,820	77,561	7,927E11
	Pedologia	3696,757	59,284	230518,043
	Declividade	1,677	,949	2,965
	Elevação	1,171	1,089	1,260
	Iluminação	,775	,577	1,041
	Aspecto	,996	,979	1,014
	Perfil_curvatura	7,941	3,006E-5	2098052,565
	plano_curvatura	,008	2,279E-6	28,720
	Fluxo_Acumulado	1,001	,998	1,005
	Direção_Fluxo	1,001	,998	1,004
	ComprimentoFluxo	1,000	1,000	1,000
	Norte	1,001	1,001	1,002
	Este	1,001	1,000	1,001