

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**  
**CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA URBANA**

**APLICAÇÃO E AVALIAÇÃO DE TÉCNICAS NEURO-FUZZY PARA  
A ELABORAÇÃO DE MAPAS DE SUSCEPTIBILIDADE A EROSÃO**

**VAGNER DE SOUZA SERIKAWA**

São Carlos

2020

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**  
**CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA URBANA**

**APLICAÇÃO E AVALIAÇÃO DE TÉCNICAS NEURO-FUZZY PARA  
A ELABORAÇÃO DE MAPAS DE SUSCEPTIBILIDADE A EROSÃO**

**VAGNER DE SOUZA SERIKAWA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Urbana da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Urbana.

Orientação: Prof. Dr. Edson Augusto Melanda

São Carlos

2020

Serikawa, Vagner de Souza

Aplicação e avaliação de técnicas neuro-fuzzy para a elaboração de mapas de susceptibilidade a erosão / Vagner de Souza Serikawa -- 2020. 157f.

Tese de Doutorado - Universidade Federal de São Carlos, campus São Carlos, São Carlos

Orientador (a): Edson Augusto Melanda

Banca Examinadora: Abimael Cerada Junior, Diego de Oliveira Martins, Moisés Furtado Failache, Vitor Eduardo Molina Júnior

Bibliografia

1. Engenharia Urbana. 2. Cartografia Urbana Ambiental.
3. Sistema de Informações Geográficas. I. Serikawa, Vagner de Souza. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Ronildo Santos Prado - CRB/8 7325



## UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Engenharia Urbana

---

### Folha de Aprovação

---

Defesa de Tese de Doutorado do candidato Vagner de Souza Serikawa, realizada em 16/04/2020.

#### Comissão Julgadora:

Prof. Dr. Edson Augusto Melanda (UFSCar)

Prof. Dr. Abimael Cereda Junior (PUCCAMP)

Prof. Dr. Vitor Eduardo Molina Junior (UNICAMP)

Prof. Dr. Diego de Oliveira Martins (UFSCar)

Prof. Dr. Moisés Furtado Failache (UFSCar)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Urbana.

À minha companheira Raquel e a meu filho João Pedro.  
A Dona Maria e Seu Nelson (*In Memoriam*)

---

# Agradecimentos

O maior agradecimento vai para a minha família, por compreender o quanto foi difícil todos esses anos dedicados a pesquisa.

Aos professores Edson e Carolina, pela orientação.

Aos professores do grupo de estudo de geociências da UFSCar, Carlos Wilmer, Reinaldo Lorandi e José Augusto de Lollo.

Aos técnicos dos laboratórios da UFSCar, Sidinei (Em memória), Bil e Marcão.

Aos técnicos do laboratório de Geotecnia (EESC-USP), José Luís e especialmente ao Oscar.

Aos funcionários do programa de pós-graduação em Engenharia Urbana, Alex e Antônio Pepino, por toda a ajuda nos processos burocráticos.

Aos técnicos, alunos e professores que auxiliaram esta pesquisa, Moises Failache (companheiro de Pós-Graduação), Daniel Sirio, André “Bixão”, Vitor Roatt, Marcelo Mike Mine (Laboratório de Hidráulica – USP), Maykon (CIG – UFSCar), aos alunos e professores do programa de Pós-Graduação em Transportes – EESC/USP Jorge, Cintia, Cira e André, ao professor Bruce da Engenharia Elétrica (UFSCar), professor Francisco (UFRJ), professor Luiz Eduardo Moschini, grande mestre e “guru” de SIG, professor Diego Martins (DeCiv), incrivelmente solícito.

Agradeço o convívio com os amigos de Pós-Graduação, Natália Costa, João Vitor, Beatriz Segadilha, Tatiane Olivatto, João Mateus, Felipe Facci, Francielly Afonso, Igor Barreto e Fabio Noel, pela convivência durante esses anos.

Aos professores que participaram da banca de defesa desta tese, Prof. Dr. Abimael Cerada Junior, Prof. Dr. Vitor Molina Júnior, Prof. Dr. Diego de Oliveira Martins, Prof. Dr. Moisés Furtado Failache e ao presidente da banca e orientador Prof. Dr. Edson Augusto Melanda.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Número do Processo 88882.426616/2019-01.

*“O que se aprende no caminho importa mais do que a chegada”*

Djonga

---

## Resumo

SERIKAWA, Vagner de Souza. **Aplicação e Avaliação de Técnicas Neuro-Fuzzy para a Elaboração de Mapas de Susceptibilidade a Erosão**. 2020. 157 f. Tese (Doutorado) – Departamento de Engenharia Civil, Universidade Federal de São Carlos, 2020.

O objetivo desta tese foi analisar e contrapor os modelos metodológicos existentes dentro do sistema de informações geográficas, suas técnicas e indicadores para o planejamento urbano ambiental, visando construções de bases para cidades inteligentes. Para atingir os objetivos, foram propostos os seguintes objetivos: (a) elaborar um inventário de processos erosivos na área de estudo; (b) gerar uma coleção de documentos cartográficos; (c) construir bases de treinamento para diferentes modelos de redes neurais artificiais (rede neural *perceptron* com uma camada, rede neural *multilayer perceptron* e ANFIS); e discutir os métodos e metodologias para o planejamento urbano ambiental. A área de estudo é a Bacia Hidrográfica do Rio Monjolinho inserida nos municípios de São Carlos e Ibaté, possui uma área de aproximadamente 273,77km<sup>2</sup>. O método utilizado abrangeu: a elaboração de uma estrutura de dados de entrada para o *Matlab*®, extraídos de uma matriz de dados dos mapas elaborados no *software ArcGIS*® 10.5 versão desktop. O treinamento foi realizado em duas fases, o primeiro com uma estrutura de 203.496 pontos, extraídos de uma matriz regular de 100x100m, na segunda fase um novo treinamento foi feito, com algumas modificações na estrutura, foram treinados dois modelos, *design 1* com dados *crisps* e o *design 2* com dados normalizados entre 0 e 1, utilizando o método *perceptron* com uma camada, com uma matriz de 30x30m, com 13.152, sendo 355 representando as erosões. No processamento ocorreu a remoção de tuplas com dados inválidos (por exemplo, valores -9999), a contagem do número de ocorrências de tuplas repetidas e pôr fim a remoção de tuplas repetidas, todos esses passos foram para equalizar o desbalanceamento das classes, totalizando 710 de “não erosão” e 355 de “erosão” mantendo uma proporção de 2 para 1. Buscou-se com os novos treinamentos um modelo representasse com maior precisão a ocorrência de processos erosivos, por isso é necessário que os valores que representam os falsos negativos sejam baixos, pois é crítico para o sistema indicar que não existe erosão quando na verdade existe. Nesse sentido, a rede *perceptron* do *design 2* foi a que apresentou os melhores resultados, apresentando menor ocorrência de valores de falsos negativos do que o *design 1*.

**PALVRAS-CHAVE:** Erosão; FIS; ANFIS; Geoinformação; SIG.

---

# Abstract

SERIKAWA, Vagner de Souza. **Application and Evaluation of Neuro-Fuzzy Techniques for Elaboration of Erosion Susceptibility Maps. 2020.** 157 f. Thesis (Doctorate) - Department of Civil Engineering, Federal University of São Carlos, 2020.

The objective of this thesis was to analyze and contrast the existing methodological models within the geographic information system, its techniques and indicators for environmental urban planning, aiming at building bases for smart cities. To achieve the objectives, the following objectives were proposed: (a) elaborate an inventory of erosive processes in the study area; (b) generate a collection of cartographic documents; (c) build training bases for different models of artificial neural networks (one-layer perceptron neural network, multilayer perceptron neural network and ANFIS); and discuss the methods and methodologies for environmental urban planning. The study area is the Monjolinho River Basin inserted in the municipalities of São Carlos and Ibatê, with an area of approximately 273,77km<sup>2</sup>. The method used included: the elaboration of an input data structure for Matlab®, extracted from a data matrix of the maps elaborated in the ArcGIS® 10.5 desktop version software. The training was carried out in two phases, the first with a structure of 203,496 points, extracted from a regular matrix of 100x100m, in the second phase a new training was done, with some modifications in the structure, two models were trained, design 1 with crisp data and design 2 with data normalized between 0 and 1, using the perceptron method with a layer, with a 30x30m matrix, with 13,152,355 representing erosions. In the process, the removal of tuples with invalid data (for example, values -9999), counting the number of occurrences of repeated tuples and ending the removal of repeated tuples, all these steps were done to equalize the imbalance of the classes, totaling 710 “non-erosion” and 355 “erosion” maintaining a 2 to 1 ratio. With the new training, a model was sought to more accurately represent the occurrence of erosive processes, so it is necessary that the values that represent false negatives are low, as it is critical for the system to indicate that there is no erosion when it actually exists. In this sense, the perceptron network of design 2 was the one that presented the best results, presenting less occurrence of false negative values than design 1.

**KEYWORDS:** Erosion; FIS; ANFIS; Geoinformation; GIS.

---

## Lista de Figuras

Figura 1	Fatores que influenciam nos processos erosivos .....	25
Figura 2	Tipos de erosões .....	25
Figura 3	Estrutura de SIG.....	30
Figura 4	Conjunto de pertinência de cores de uma variável fuzzy de cor qualquer .....	36
Figura 5	Conjunto de pertinências de cores de uma variável fuzzy de cor, por meio deste gráfico é possível visualizar as curvas de pertinência das funções vermelho, verde e azul .....	37
Figura 6	Conceito de $A \subseteq B$ Jang <i>et al.</i> (1997).....	38
Figura 7	Operações lógicas em conjuntos fuzzy (Jang <i>et al.</i> , 1997).....	39
Figura 8	Sistema de Inferência Fuzzy (FIS) .....	41
Figura 9	Modelo fuzzy Mamdani.....	42
Figura 10	Modelo fuzzy Takagi-Sugeno.....	43
Figura 11	Modelo fuzzy Tsukamoto .....	44
Figura 12	Sistema fuzzy Takagi-Sugeno com duas entradas e duas regras ..	45
Figura 13	Arquitetura ANFIS correspondente .....	46
Figura 14	Neurônio MCP, no qual a $\sum$ representa a soma ponderada das entradas e a função de ativação .....	48
Figura 15	Exemplos de função de ativação .....	49
Figura 16	Arquitetura de RNAs .....	50 e 51
Figura 17	Localização Geográfica da bacia hidrográfica do Rio Monjolinho...	54
Figura 18	Seção Geológica de Catanduva a São Carlos .....	57
Figura 19	Perfil morfológico-estrutural Ribeirão do Feijão - Córrego do Monjolinho .....	58
Figura 20	Média mensal para os anos 1959 a 2018 (DAAE, 2018) .....	62
Figura 21	Fluxograma das etapas do trabalho.....	64
Figura 22	Síntese da metodologia utilizada.....	65
Figura 23	Arquivos do TOPODATA produzidos ao longo do processamento dos dados SRTM .....	68
Figura 24	Variáveis geomorfométricas, derivadas da altimetria.....	69

Figura 25	Ferramenta IDW, no <i>Toolbx</i> do <i>ArcGIS</i> <sup>®</sup> .....	72
Figura 26	Grade regular criada utilizando a ferramenta <i>Fishnet</i> do <i>ArcGIS</i> <sup>®</sup> .	76
Figura 27	Matriz de dados gerada no <i>software ArcGIS</i> <sup>®</sup> .....	76
Figura 28	Fluxograma do modelo conceitual da ANFIS em ambiente SIG .....	79
Figura 29	Número de publicações por ano.....	80
Figura 30	Gráfico de frequência de publicações .....	82
Figura 31	Grupos de palavras-chave .....	83
Figura 32	Distribuição de densidade das palavras de maior ocorrência. As cores indicam a densidade de termos, sendo que quanto maior o tamanho da letra, e mais próximo do vermelho, maior a ocorrência da palavra dentro dos artigos .....	84
Figura 33	Mapa de documentação BHRM.....	86
Figura 34	Gráfico com elevação em porcentagem e área em Km <sup>2</sup> da BHRM..	87
Figura 35	Mapa Hipsométrico BHRM .....	88
Figura 36	Gráfico precipitação média anual para o ano de 2018 na BHRM..	89
Figura 37	Mapa Pluviométrico.....	90
Figura 38	Classes de declividade para a BHRM .....	91
Figura 39	Carta de Declividade BHRM.....	92
Figura 40	Gráfico das Formas do Terreno da BHRM .....	93
Figura 41	Mapa de Formas do Terreno .....	94
Figura 42	Gráfico de Formações Geológicas.....	95
Figura 43	Mapa Geológico BHRM .....	96
Figura 44	Gráfico representativo das porcentagens referentes a cada um dos tipos de materiais inconsolidados de ocorrência na bacia hidrográfi- ca do rio do Monjolinho em relação à área total da bacia .....	97
Figura 45	Mapa de Materiais Inconsolidados BHRM .....	100
Figura 46	Gráfico das porcentagens referentes a cada uma das formas de cobertura e uso da terra .....	101
Figura 47	Mapa de Cobertura e Uso da Terra BHRM .....	102
Figura 48	Mapa de Processos Erosivos BHRM .....	104
Figura 49	Matriz de confusão RNA .....	107
Figura 50	Curvas dos erros de treinamento e validação com 22 épocas.....	108
Figura 51	Curva dos erros de treinamento e validação com 8 épocas .....	108
Figura 52	Matriz de confusão RNA, microbacia hidrográfica .....	109
Figura 53	Curvas dos erros de treinamento e validação da MBHCAQ para uma época.....	110
Figura 54	Curvas dos erros de treinamento e validação da MBHCAQ para 11 época .....	110
Figura 55	Matriz de confusão multicamada com dados <i>crisps</i> .....	111

Figura 56	Matriz de confusão multicamada com dados normalizados .....	111
Figura 57	Matriz de confusão ANFIS com dados <i>crisps</i> para a BHRM.....	57
Figura 58	Matriz de confusão ANFIS com dados normalizados para a BHRM	58
Figura 59	Matriz de confusão ANFIS com dados <i>crisps</i> e normalizados para a microbacia do Córrego Água Quente.....	113
Figura 60	<i>Design 1</i> da rede <i>Perceptron</i> .....	114
Figura 61	Matriz de confusão treinamento 1.....	115
Figura 62	Curva ROC do treinamento 1.....	116
Figura 63	Matriz de confusão para todo o conjunto de dados.....	116
Figura 64	Matriz de confusão treinamento 2.....	117
Figura 65	Curva ROC treinamento 2 .....	118
Figura 66	Matriz de confusão para todo o conjunto de dados.....	119
Figura 67	<i>Design 1</i> da rede <i>Perceptron</i> .....	120
Figura 68	Matriz de confusão treinamento 1.....	121
Figura 69	Curva ROC treinamento 1 .....	122
Figura 70	Matriz de confusão para todo o conjunto de dados.....	122
Figura 71	Matriz de confusão treinamento 2.....	123
Figura 72	Curva ROC treinamento 2 .....	124
Figura 73	Matriz de confusão para todo o conjunto de dados.....	125

---

## Lista de Tabelas

Tabela 1	Locais de extração dos dados pluviométricos .....	71
Tabela 2	Número de artigos publicados por autor, seu país de origem e instituição de filiação .....	81
Tabela 3	Revistas que mais publicaram no período analisado .....	81
Tabela 4	Precipitação mensal da BHRM (2018) .....	89
Tabela 5	Apresentação dos dados das principais características geotécnicas .....	98 e 99
Tabela 6	Distribuição dos processos erosivos por classe de atributo e cálculo da taxa de frequência dos processos erosivos ...	105 e 106
Tabela 7	Parâmetros do treinamento 1 .....	114
Tabela 8	Parâmetros do treinamento 2 .....	118
Tabela 9	Resultados para os conjuntos de treinamento <i>Design 1</i> .....	119
Tabela 10	Parâmetros do treinamento 2 .....	120
Tabela 11	Parâmetros do treinamento 2 .....	124
Tabela 12	Resultados para os conjuntos de treinamento <i>Design 2</i> .....	125
Tabela 13	Resultado da comparação dos conjuntos de treinamento dos <i>Design 1</i> e <i>Design 2</i> .....	126

---

# Lista de Quadros

Quadro 1	Escala fundamental de Saaty (1977) para julgamentos de variáveis par a par .....	33
----------	----------------------------------------------------------------------------------	----

---

# Sumário

<b>1</b>	<b>Apresentação do tema, justificativa e relevância do problema de pesquisa</b>	<b>15</b>
1.1	Introdução.....	15
1.1	Hipótese .....	18
1.2	Justificativa.....	18
1.3	Objetivos .....	21
1.3.1	Objetivo geral .....	21
1.3.2	Objetivos específicos.....	21
<b>2</b>	<b>Revisão bibliográfica</b>	<b>22</b>
2.1	Processos Erosivos .....	23
2.1.1	Tipo de Feições Erosivas .....	24
2.2	Cartografia Geotécnica .....	25
2.3	Sistema de Informações Geográficas (SIG) .....	28
2.4	Análise Multicritério Aplicada em Estudos Ambientais .....	31
2.5	Lógica Fuzzy.....	34
2.5.1	Teoria dos Conjuntos Fuzzy .....	34
2.5.2	Relações entre os Conjuntos Fuzzy.....	36
2.5.3	Regras IF-THEN Fuzzy .....	39
2.6	Fuzzy Inference System (FIS) .....	39
2.6.1	Modelo Fuzzy Mamdani.....	41
2.6.2	Modelo Fuzzy Takagi-Sugeno .....	42
2.6.3	Modelo Tsukamoto.....	43
2.7	Adaptative Neuro-Fuzzy Inference System (ANFIS) .....	43
2.7.1	Arquitetura do Sistema de Inferência Neuro-Fuzzy Adaptativo .....	44
2.8	Redes Neurais Artificiais (RNA).....	46
2.8.1	Arquitetura de Redes Neurais Artificiais .....	49
2.8.2	Treinamento das Redes Neurais Artificiais (RNA) .....	50
2.8.3	Rede Neuro-Fuzzy .....	51

<b>3</b>	<b>Caracterização da área de estudo</b>	<b>52</b>
3.1	Localização e aspectos demográficos.....	52
3.2	Contexto Histórico.....	52
3.3	Rede de Drenagem .....	52
3.4	Geologia.....	54
	3.4.1 Formação Itaqueri .....	54
	3.4.2 Formação Serra Geral.....	54
	3.4.3 Formação Botucatu .....	55
	3.4.4 Formação Pirambóia.....	55
	3.4.5 Formações Superficiais.....	55
3.5	Materiais Inconsolidados .....	58
3.6	Águas Subterrâneas .....	60
3.7	Geomorfologia .....	60
3.8	Clima .....	60
3.9	Vegetação.....	61
<b>4</b>	<b>Materiais e métodos</b>	<b>62</b>
4.1	Análise Bibliométrica.....	64
4.2	Levantamento e Avaliação dos Dados Pré-existentes .....	65
4.3	Processamento dos Dados .....	65
4.4	Elaboração de Documentos Cartográficos .....	66
	4.4.1 Mapa de Documentação .....	66
	4.4.2 Dados Topodata INPE.....	66
	4.4.3 Mapa Formas do Terreno.....	67
	4.4.4 Modelo Digital de Elevação e Carta de Declividade .....	68
	4.4.5 Mapa Hipsométrico.....	68
	4.4.6 Mapa de Substrato Geológico.....	68
	4.4.7 Mapa de Materiais Inconsolidados .....	69
	4.4.8 Mapa Pluviométrico .....	69
	4.4.9 Mapa Cobertura e Uso do Solo.....	71
	4.4.10 Mapas de Processos Erosivos.....	71
4.5	Mapeamento Utilizando o Método ANFIS .....	71
	4.5.1 O sistema de inferência neuro-fuzzy adaptativo .....	72
	4.5.2 Preparação dos dados de treinamento.....	73
	4.5.3 Aplicação da razão de frequência para mapeamento de susceptibilidade a erosão .....	73
	4.5.4 Aplicação do ANFIS ao mapeamento de susceptibilidade à erosão .....	74
	4.5.5 Validação do mapa de susceptibilidade à erosão .....	74
4.6	Elaboração da matriz de dados.....	74

4.7	Estrutura dos dados de entrada no Matlab.....	76
4.7.1	Preparação dos dados.....	76
4.7.2	Balanceamento dos dados .....	77
4.7.3	Conjuntos de Treinamento, Validação e Teste.....	77
<b>5</b>	<b>Resultados e discussões</b>	<b>79</b>
5.1	Análise Bibliométrica para o método ANFIS.....	79
5.2	Mapa cadastral e mapas temáticos base .....	84
5.2.1	Mapa de Documentação.....	84
5.2.2	Mapa Hipsométrico .....	86
5.2.3	Mapa Pluviométrico .....	88
5.2.4	Carta de Declividade .....	90
5.2.5	Carta de Forma do Terreno .....	92
5.2.6	Mapa Geológico.....	94
5.2.7	Mapa de Materiais Inconsolidados.....	96
5.2.8	Mapa de Cobertura e Uso da Terra.....	100
5.2.9	Mapa de Processos Erosivos.....	102
5.3	Resultados dos treinamento das Redes Neurais Artificiais .....	106
5.3.1	Treinamento da RNA Perceptron com uma camada .....	106
5.3.2	Treinamento da RNA Perceptron Multicamada .....	110
5.3.3	Treinamento da RNA ANFIS .....	111
5.4	Treinamento da RNA Perceptron com uma camada segundo período..	112
5.4.1	Rede Perceptron Design 1 .....	113
5.4.2	Divisão do conjunto de dados Treinamento e Validação. 113	
5.4.3	Divisão do conjunto de dados Treinamento, Validação e Teste..	116
5.4.4	Conclusão Design 1 .....	118
5.4.5	Rede Perceptron Design 2 .....	119
5.4.6	Divisão do conjunto de dados Treinamento e Validação. 119	
5.4.7	Divisão do conjunto de dados Treinamento, Validação e Teste..	122
5.4.8	Conclusão Design 2 .....	124
5.4.9	Conclusão geral do segundo período de treinamentos....	124
<b>6</b>	<b>Considerações finais</b>	<b>126</b>
6.1	Síntese do trabalho.....	126
6.1.1	Respostas aos objetivos da pesquisa e análise da hipótese .....	127
6.1.2	Conclusões e propostas de intervenções mitigadoras .....	128
6.1.3	Limitações da pesquisa .....	128
6.1.4	Recomendações .....	128
<b>7</b>	<b>Referências bibliográficas</b>	<b>129</b>
	<b>Apêndice</b>	<b>145</b>

# Apresentação do tema, justificativa e relevância do problema de pesquisa

## 1.1 Introdução

**P**roblemas ambientais frequentes, em diferentes escalas do globo terrestre, afetam a população de um modo geral, como queimadas, desmatamentos, aceleração nas alterações climáticas, poluição por materiais plásticos entre outros. Tantos os novos como os antigos problemas ambientais necessitam de estudos específicos e as áreas ocupadas por cidades tornam-se sensíveis a diversas mudanças em ritmo acelerado.

O aumento da população mundial, bem como o desequilíbrio biológico decorrente desta própria explosão populacional traz sérias preocupações sobre o fornecimento de água às gerações futuras, tanto em quantidade como em qualidade. A ação do homem no planejamento e desenvolvimento da ocupação do solo requer, cada vez mais, uma visão ampla sobre as necessidades da população, sobre os recursos terrestres e aquáticos disponíveis e o conhecimento sobre o comportamento dos processos naturais, para racionalmente compatibilizar necessidades crescentes com recursos limitados.

É preciso pensar as cidades, e o que pode ser visto são grandes núcleos urbanos em desenvolvimento e muitas vezes sem planejamento do seu espaço ou território, levando às consequências que geram perdas econômicas, sociais e de vidas, como em alguns desastres naturais. Essa degradação do meio ambiente também limita o uso de recursos antes disponíveis. A degradação traz uma perda significativa aos elementos do meio ambiente (solo, biodiversidade, vegetação, recursos hídricos, entre outros), compromete funções ambientais (proteção do solo contra erosão, margens dos rios, águas subterrâneas, do regime hídrico, da redução dos ecossistemas), altera a paisagem, traz risco a saúde e a segurança (SANCHEZ, 1993).

De acordo com Zuquette *et al.* (2009) a ocupação territorial diversificada gera sérios problemas ambientais degradando vários recursos naturais, como a água. Os recursos hídricos são importantes e vulneráveis à ação antrópica, principalmente quando associada ao uso indiscriminado e indisciplinado do solo para disposição de rejeitos, resíduos e como suporte de diversas atividades de infraestrutura, habitação e produção de alimentos.

O solo tem sido manipulado de maneira inadequada, causando alterações na

sua estrutura. As formas mais comuns de degradação são: a erosão do solo, compactação do solo e impermeabilização do solo, que geram consequências no meio urbano, como enchentes, deslizamentos e outros desastres naturais. A urbanização acelerada causa perda do habitat natural de muitas espécies na fauna e flora, poluição do ar e da água, e destruição do potencial natural de muitas áreas. Além disso, atividades inadequadas no solo associadas aos materiais geológicos com diferentes propriedades hidráulicas podem degradar as nascentes e corpos d'água.

Uma das ocupações que mais degradam o solo são as atividades agrícolas, com atividades que contribuem significativamente para o empobrecimento do solo (PEREIRA *et al.*, 1995). A camada superficial de solo é arrastada pelas chuvas, deixando para trás sulcos no terreno, que pode ou não evoluir para ravinas e voçorocas, empobrecendo o solo e assoreando represas, além de levar para as águas dos rios resíduos de adubos e agroquímicos. Esta remoção de solo representa milhões de reais que o país perde anualmente. A destruição do meio ambiente, por meio do mau uso da agricultura e pecuária causa deterioração física, socioeconômica e ambiental no Brasil.

Para a prática agrícola em grandes extensões, são realizados desmatamentos de modo inadequado, que podem levar mais de 50 anos para serem recuperados. Retirando a cobertura vegetal do solo, altera-se a paisagem que vai gerar consequências na estrutura do solo, na rede de drenagem, afetando as nascentes que podem secar ou mudar de lugar. Sem a proteção da cobertura vegetal, a gota da chuva cai e ocorre uma compactação do solo, algumas partículas do solo se desprendem (efeito splash), a velocidade do fluxo torna-se maior, causando um aumento no transporte de material. A desagregação do solo pela ação das chuvas e a diminuição da rugosidade da paisagem fazem com que a ação do escoamento superficial, nas encostas e nos leitos dos cursos de água, desequilibre os processos erosivos naturais das bacias hidrográficas.

Uma bacia hidrográfica, por definição, constitui um conjunto de terras drenadas por um rio e seus afluentes, formados nas regiões mais altas do relevo por divisores de água, por onde escoam superficialmente formando riachos e rios, ou infiltram no solo, formando reservatórios subsuperficiais (TEODORO *et al.*, 2007). São consideradas excelentes unidades de gestão dos elementos naturais e sociais, pois, nessa óptica, é possível acompanhar as mudanças introduzidas pelo homem e as respectivas respostas da natureza.

As características físicas de uma bacia hidrográfica têm papéis importantes no processo do ciclo hidrológico, influenciando na quantidade de água produzida como deflúvio, evapotranspiração e escoamento superficial e subsuperficial. O desempenho da bacia hidrográfica vai influenciar, por exemplo, na qualidade das nascentes, que depende da infiltração em toda a área da bacia. Toda a extensão merece atenção, evitando as erosões, compactação do solo, impermeabilização, entre outras interferências.

A área de estudo da pesquisa é a Bacia Hidrográfica do rio Monjolinho (BHRM), localizada no município de São Carlos região centro-leste do estado de São Paulo, faz parte de um importante centro industrial regional, com atividades econômicas principalmente na indústria e agronegócios (destaque para a produção de cana-de-açúcar) e está distante 230 quilômetros, aproximadamente, da capital do estado. São Carlos, como a grande maioria das cidades do Brasil, iniciou seu processo de urbanização sem um planejamento adequado, conseqüentemente, apresenta diversos problemas de infraestrutura, problemas hídricos, na saúde e educação.

O planejamento adequado da cidade é importante para equalizar o crescimento e evitar desigualdades. Para Hecht (1999) e Montañó *et al.* (2007), cabe aos governantes desenvolverem políticas que visam o crescimento econômico e proteção ao meio ambiente, superando as dificuldades de incorporar a sustentabilidade ambiental no processo de tomada de decisão, visto que, não é uma tarefa fácil, devido a urgência de resultados, e conflitos de natureza econômica, social e ambiental.

Para auxiliar no planejamento existem alguns instrumentos que ajudam na proteção dos recursos naturais, estes são utilizados para minimizar o máximo de impactos gerados pelo desenvolvimento urbano. Segundo o Ministério do Meio Ambiente (2006), o planejamento ambiental é o instrumento utilizado para delimitar as zonas urbanas, rural e demais territórios, com prerrogativa constitucional.

Por exemplo, algumas das metodologias voltadas ao planejamento ambiental urbano são: o Zoneamento Ecológico-Econômico (ZEE), o Plano Diretor Municipal, o Plano de Bacia Hidrográfica, o Plano Ambiental Municipal, dentre outros mais específicos. O zoneamento ambiental, destaca-se como um instrumento importante para o planejamento, descrito na Lei no 6.938/1981 (Política Nacional do Meio Ambiente), mesmo não consolidado como ferramenta de ordenação do território, e com diversas lacunas a serem preenchidas para promover uma eficácia maior (MONTAÑO, 2005).

Para um bom ordenamento do território deve-se levar em conta os diferentes tipos de atributos que compõem o meio físico, que utilizados em conjunto com as geotecnologias tem se mostrado uma excelente ferramenta para mapeamentos de diversas naturezas, dando suporte na elaboração de projetos de obras de engenharia e planejamento urbano e regional (GUSTAFSON *et al.*, 1992; COSTA, 2017; FAILACHE, 2018; SOUZA, 2020). Os atributos do meio físico assumem papel importante como recurso ou suporte de vida, estão associados aos processos de estruturação e esculturação do relevo, base para a cobertura e uso do solo. Conhecer os processos pretéritos e futuros auxilia no diagnóstico e análise do estado de degradação e/ou conservação que o ambiente apresenta.

Dando suporte aos estudos ambientais, o geoprocessamento atua como ferramenta para trabalhar com dados georreferenciados, oferecendo mapas temáticos que mostram a distribuição do comportamento desses atributos, como, geomorfologia, tipos de solo, vegetação, redes de drenagem, clima, vegetação, entre outros, com a possibilidade de elaborar uma base de dados digitais, com uma diversidade de planos de informação, fazer análises, representar e visualizar a superfície terrestre, compreendendo suas formas e outros fenômenos morfológicos, que no processo de tomada de decisão, colabora com os gestores, revelando-se uma eficiente ferramenta para o planejamento ambiental e territorial.

A partir da elaboração de um banco de dados dos atributos pré-definidos, é possível utilizar de diferentes metodologias, para elaboração dos produtos cartográficos. Esses produtos servem de suporte para tomada de decisão na prevenção de riscos ambientais (PRADHAN *et al.*, 2010). Em países tropicais, os processos erosivos geram grandes perdas de solo e prejuízos em diferentes áreas da economia, em alguns casos, até risco com morte. Pejon (1992) desenvolveu uma metodologia para ensaios de erodibilidade do solo compatível com a realidade dos solos brasileiros, baseando-se principalmente em dados de inventário de campo.

Dentre as diferentes metodologias para mapeamento utilizando a ferramenta SIG, as análises multicritérios são muito utilizadas, tornando o processo rápido e

confiável. Jang (1993) utilizou um modelo adaptado do sistema neuro-*fuzzy* para elaborar mapa de susceptibilidade a deslizamento de terra, outros autores também utilizaram da metodologia para o mesmo tipo de mapeamento (CEREDA JUNIOR, 2006; 2011; OH & PRADHAN, 2011; SEZER *et al.*, 2011).

A partir das literaturas citadas acima, pode-se identificar que os métodos aplicados aos diferentes mapas de risco são eficientes em diferentes áreas, seja, para mapeamento de enchentes, escorregamentos, erosões, ou qualquer outro utilizado na prevenção de danos materiais e a vida. Portanto, este trabalho utiliza o sistema de inferência neuro-*fuzzy* adaptativo (ANFIS) para o mapeamento de susceptibilidade a erosão em uma área propensa a processos recentes. O modelo ANFIS será aplicado e validado na área de estudo, utilizando um sistema de informações geográficas (SIG). O método ANFIS utilizado, baseia-se no conhecimento especializado, aplicando o sistema de inferência *fuzzy* (FIS) e o aprendizado por Redes Neurais Artificiais (RNAs). De acordo com Jang (1993) a metodologia pode ser utilizada em qualquer local com mínimas mudanças. A escolha da área de estudo foi de acordo com a disponibilidade de informação e localização, visto que, é uma bacia hidrográfica com trabalhos pretéritos em diversas áreas do conhecimento, que abrange a área urbano do município de São Carlos.

## 1.1 Hipótese

O uso de redes neurais artificiais combinada com a lógica *fuzzy*, é capaz de auxiliar a elaboração de produtos cartográficos em diferentes escalas?

## 1.2 Justificativa

A escolha do tema da pesquisa foi em função da falta de trabalhos nacionais sobre o assunto, visto que, o tema é atual abordando ferramentas de SIG pouco utilizadas, podendo trazer uma contribuição relevante no que refere-se aos mapeamentos de riscos urbanos, no caso desta pesquisa, o mapeamento de processos erosivos, que no Brasil e no mundo geram grandes perdas econômicas e sociais em diferentes escalas. A justificativa da elaboração desta pesquisa é fundamentada por trabalhos científicos publicados na área e são apresentados os temas correlatos.

No Brasil são muitos os trabalhos relacionados à erosão do solo, em diferentes áreas do conhecimento e com diferentes escalas de trabalho, por exemplo, na geografia, geologia, geomorfologia, pedologia e geotecnia. Com enfoques diferentes, visto nas obras de ELLISON (1947a e 1947b); NAKASHIMA (1973; 2000); ZACHAR (1982); BIGARELLA & MUZOCHOWSKI (1985); DAEE (1989); LAL (1990); NISHIYAMA (1991); BASTOS (1999); LIPORACI (2003).

O curso de Geotecnia da Escola de Engenharia de São Carlos (EESC-USP) contribuiu com diversos trabalhos, na área de mapeamento geotécnico, com diversas publicações que são destaque na literatura, por exemplo, o trabalho de Pejon (1992), que fez um mapeamento regional da quadrícula de Piracicaba (Folha Topográfica, SF-23-Y-A-IV-2). O autor descreve uma metodologia para áreas suscetíveis à erosão, com base na ponderação dos principais fatores que contribuem para esses processos erosivos. Foram estabelecidas classes de susceptibilidade à erosão

(áreas não susceptíveis, pouco, médio, muito e extremamente susceptíveis).

Pejon (1992) identificou 10 classes potenciais de erosão, verificou que os resultados do mapa, em conjunto com análise fotogramétrica e o inventário de campo proporcionam resultados mais detalhados e com menor subjetividade. Esse método ainda permite incluir outros fatores antrópicos na ponderação, resultando na identificação de áreas críticas a ocupação e servindo de informação base para gestores.

De acordo com Costa (2017), a degradação dos recursos hídricos, tanto na qualidade, quanto na quantidade, gera passivos sociais e econômicos, para os usuários da bacia hidrográfica, inclusive para os que estão fora dela. Por isso, elaborou seu trabalho com foco no escoamento superficial e processos de erosão acelerado, utilizou atributos geoambientais como rocha, clima, relevo, solo, corpos d'água e cobertura e uso do solo. Os dados foram integrados e avaliados dentro de um SIG, a ferramenta de análise multicritério foi a soma ponderada dos atributos. Os resultados mostram que, mais de 80% da área apresenta baixo potencial de escoamento superficial e médio potencial de erosão acelerada. Os processos erosivos acelerados foram desencadeados por mudanças na cobertura solo, mostrando relação direta com a remoção da vegetação original e implantação de atividades.

Islam *et al.* (2018), faz uso do método neuro-difuso adaptativo (ANFIS) para avaliação da erosão solo, utilizando diversos parâmetros com interação não-linear. Os autores comentam que as técnicas de computação são amplamente utilizadas, mas a aplicação no campo da ciência do solo é bem limitada. Os modelos foram estabelecidos a partir da equação universal de perda do solo (RUSLE), em seguida empregados no teste do modelo ANFIS. Também foi adicionado aos testes um parâmetro de micróbio de biomassa ( $M_f$ ), apresentando bons resultados no controle da erosão, de acordo com os autores.

A área de estudo foi amostrada em diferentes parcelas, divididas em vegetação natural, plantada, com ou sem bio-fertilizante microbiano. Os parâmetros de entrada de RUSLE, foram, erosividade da chuva, erodibilidade do solo, comprimento e inclinação da encosta, vegetação e prática de suporte. Após um ano de monitoramento, o resultado mostra uma conquista satisfatória entre modelo observado e previsto pelo ANFIS. Em termos de uma relação entre o fator  $M_f$  e a erosão do solo, percebe-se que a erosão do solo é inversamente proporcional à  $M_f$  quando todas as práticas de conservação da erosão permanecem inalteradas por um determinado período. Portanto, a aplicação de micróbios poderia ser uma alternativa ou técnica adicional de conservação do solo.

Alguns autores empregaram o método ANFIS em trabalhos relacionados a deslizamentos de terra, visto que, esse tipo de acontecimento é recorrente e natural nessas áreas. Sezer *et al.* (2011), apresentou em seu trabalho os resultados do modelo neuro-*fuzzy* usando dados de sensoriamento remoto e sistema de informações geográficas (SIG) para análise da susceptibilidade de escorregamentos em áreas de vale na Malásia. O método utilizado foi a identificação das áreas com deslizamentos (cicatrizes), por meio de imagens de satélite, apoiada por identificação em campo e elaboração de inventário. A partir de um conjunto de dados espaciais foram elaborados os seguintes produtos, índice de vegetação, mapa topográfico, lineamentos, NDVI e a cobertura do solo. Foram utilizados sete fatores considerados determinantes para os deslizamentos, foram eles: altitude, ângulo de inclinação, curvatura do plano, distância da drenagem, tipo de solo, distância das falhas e NDVI. Esses fatores foram analisados utilizando um modelo neuro-*fuzzy* (ANFIS)

para construir os mapas de susceptibilidade de escorregamentos.

Foram obtidos 5 modelos de susceptibilidade de deslizamento usando os resultados do ANFIS. Para verificação e validação dos resultados, os locais de deslizamentos foram verificados em campo, com ajuda do inventário. Os resultados da verificação mostraram 98% de precisão para o modelo 5, empregando todos os parâmetros produzidos no presente estudo como fatores de condicionamento de deslizamento. A conclusão do trabalho foi que, os resultados da validação mostraram concordância suficiente entre o mapa de suscetibilidade obtido e os dados existentes sobre áreas de escorregamento. O modelo produz resultados razoáveis que podem ser usados para fins preliminares de planejamento de uso do solo.

Um trabalho similar foi elaborado por Oh & Pradhan (2011). No artigo é apresentado um mapeamento de susceptibilidade de escorregamentos usando um sistema de inferência neuro-*fuzzy* adaptativo (ANFIS) em ambiente SIG. Na primeira etapa identificaram os deslizamentos de terras por meio de interpretação de fotografias aéreas e trabalhos de campo. Na segunda etapa, fatores condicionantes relacionados a escorregamentos como altitude, ângulo de inclinação, curvatura planeada, distância até a drenagem, distância ao solo, textura do solo e índice de potência de fluxo (SPI) foram extraídos dos mapas topográficos e de solo. Foi aplicado o modelo ANFIS, com várias funções de associação para analisar as áreas susceptíveis a escorregamentos e mapeadas usando os fatores condicionantes dos eventos, seus resultados foram comparados com os locais de escorregamentos verificados em campo.

Para todos os mapas de susceptibilidade a escorregamento foi adicionada a curva de características de operação de receptor (ROC). Essa “técnica da curva ROC baseia-se na representação gráfica da sensibilidade do modelo - valores de frações positivas verdadeiras calculadas para diferentes valores de limiar, versus especificidade do modelo - valores da fração verdadeira negativa, em um gráfico”. Os locais de teste de deslizamento que não foram usados durante o propósito de modelagem da ANFIS foram usados para validar os mapas de suscetibilidade de escorregamentos. Os resultados da validação revelaram que os mapas de suscetibilidade construídos pelos modelos preditivos da ANFIS utilizando  $MF_s$  (funções de associação) triangular, trapezoidal, sino generalizado e polinomial produziram resultados razoáveis (84,39%), que podem ser utilizados como resultado preliminar para planejamento do uso do solo.

Deste modo, com base em trabalhos já produzidos e na experiência dos autores citados anteriormente, justifica-se a utilização das técnicas de SIG já consagradas nos estudos geoambientais e técnicas que utilizam inteligência artificial e lógica *fuzzy*, a fim de, difundir o método, comparar a sua eficiência e sugerir possíveis adaptações em concordância com as condições brasileiras. Partindo do pressuposto que todo trabalho científico pode ser inédito ou, então recolocado sobre novas perspectivas (D’AGOSTINI, 1999).

## 1.3 Objetivos

### 1.3.1 Objetivo geral

O objetivo geral desta tese é: analisar e contrapor os modelos metodológicos existentes dentro do sistema de informações geográficas, suas técnicas e indicadores para o planejamento urbano ambiental, visando construções de bases para cidades inteligentes.

### 1.3.2 Objetivos específicos

Para atingir o objetivo geral da pesquisa, são propostos os seguintes objetivos específicos:

- (a) elaborar um inventário de processos erosivos na área de estudo;
- (b) gerar uma coleção de documentos cartográficos;
  - 1. Mapa de documentação
  - 2. Mapa Hipsométrico
  - 3. Mapa Pluviométrico
  - 4. Carta de Declividade
  - 5. Mapa de Formas do Terreno
  - 6. Mapa Geológico
  - 7. Mapa de Materiais Inconsolidados
  - 8. Mapa de Cobertura e Uso da Terra
  - 9. Mapa de Processos Erosivos
- (c) construir bases de treinamento para diferentes modelos de redes neurais artificiais (rede neural *perceptron* com uma camada, rede neural *multilayer perceptron* e ANFIS);
- (d) discussão dos métodos e metodologias para o planejamento urbano ambiental.

## Revisão bibliográfica

Para conhecer as potencialidades e limitações de um local, é de suma importância uma caracterização detalhada do meio físico. Ferramentas legais, aplicadas em conjunto com a cartografia geotécnica e geotecnologias são muito utilizadas no planejamento e gestão em níveis territorial, regional e local. Os produtos elaborados têm diversas finalidades, podem ser documentos voltados para a disposição correta de resíduos sólidos, escavabilidade de terrenos, fundações, obras viárias, vulnerabilidade de obras subterrâneas, zoneamento ambiental, prevenção de eventos naturais, entre outros produtos de modo geral ou finalidades específicas. A abordagem deste estudo é sobre o uso da ferramenta SIG combinadas com métodos e metodologias de inteligência artificial para elaboração de mapas de prevenção de processos erosivos recentes na bacia hidrográfica do Rio Monjolinho (BHRM).

Nas literaturas correlatas com o tema desta pesquisa, verifica-se que, de acordo com os temas *Analytic Hierarchy Process - AHP* (Saaty, 1980; Saaty, 1991; Saaty, 2005; Bhushan, & RAI (2004); Costa et al., 2018; Thomas et al., 2018) e *Adaptive Neuro-Fuzzy Inference System - ANFIS* (Jang 1993, Takagi & Sugeno, 1985; Oh & Pradhan, 2011; Sezer et al., 2011; Aghdam et al., 2016), são utilizados grandes quantidades de dados (*Big Data*).

Sezer et al. (2011), utilizou o método ANFIS, para áreas de susceptibilidade de escorregamento de encostas, e considerou como uma ferramenta muito poderosa nesses tipos de avaliações regionais. No entanto, os resultados a serem obtidos na modelagem da ANFIS devem ser avaliados cuidadosamente, pois o superaprendizado pode causar resultados enganosos.

Oh & Pradhan (2011), aplicaram o modelo *neuro-fuzzy* ao mapeamento de susceptibilidade de escorregamentos para deslizamentos rasos em uma área montanhosa tropical, considerando o método eficiente, e que pode ser facilmente estendido para considerar outros tipos de instabilidade ou outras áreas. Fazem uma ressalta quanto a escala de trabalho, para resultados mais específicos, em escala local, onde as heterogeneidades geológicas e geográficas locais podem prevalecer, os resultados apresentados podem ser usados como dados básicos para auxiliar o gerenciamento de taludes e o planejamento do uso da terra.

Thomas et al. (2018), utilizou o método de análise hierárquica para analisar o risco de potencial de erosão do solo, em área tropical montanhosa, analisando sete fatores geoambientais. A comparação cruzada dos resultados, da intensidade e risco de erosão do solo, utilizando AHP, sugere concordância significativa entre diferentes intensidades de erosão e zonas potenciais.

São diversos os trabalhos encontrados na literatura, sobre ambos os métodos porém, para estudos geoambientais é encontrado em maior quantidade o méto-

do AHP, obtendo sempre bons resultados, em diversos tipos de mapas, mapa de fragilidade ambiental (Gimenes e Augusto Filho, 2013), mapeamento de erosões (Souza, 2015), na área da saúde (Brioso e Musetti, 2015), entre outras áreas.

O mapeamento de processos erosivos envolvendo o método ANFIS são poucos, visto que nos trabalhos citados anteriormente, os autores concordam que a metodologia pode ser replicada em qualquer área, com poucas alterações no processo de construção do mapas, como algumas alterações pode-se encontrar o melhor modelo que se adapte as condições brasileiras, no que tange os processos erosivos.

## 2.1 Processos Erosivos

Os estudos relacionados aos processos erosivos possuem um reconhecimento a décadas como importante questão ambiental, são diversas abordagens diretamente ligadas à erosões lineares (BEN SLIMANE *et al.*, 2016; ERKTAN *et al.*, 2016; CASTILLO & GÓMEZ, 2016; MARARAKANYE & SUMNER, 2017; VANMAERCKE *et al.*, 2016). Na última década, as pesquisas estão mais focadas no desenvolvimento de metodologia de previsão e estratégias de gerenciamento.

Portanto, elaborar novos estudos em áreas com a formação de novos processos é essencial para a determinação de locais mais vulneráveis e para o planejamento imediato de medidas para reduzir os efeitos negativos causados pelas erosões (DEWITTE, DAOUDI, BOSCO E VAN DEN EECKHAUT, 2015; GOMEZ-GUTIÉRREZ *et al.*, 2015).

A erosão dos solos, de maneira geral, refere-se ao desgaste ou desagregação da superfície por fatores físicos, químicos, geológicos ou não, com ou sem a participação ativa dos seres humanos. A erosão foi definida por Ellison (1947), como um processo de desagregação e transporte de materiais do solo por agentes erosivos.

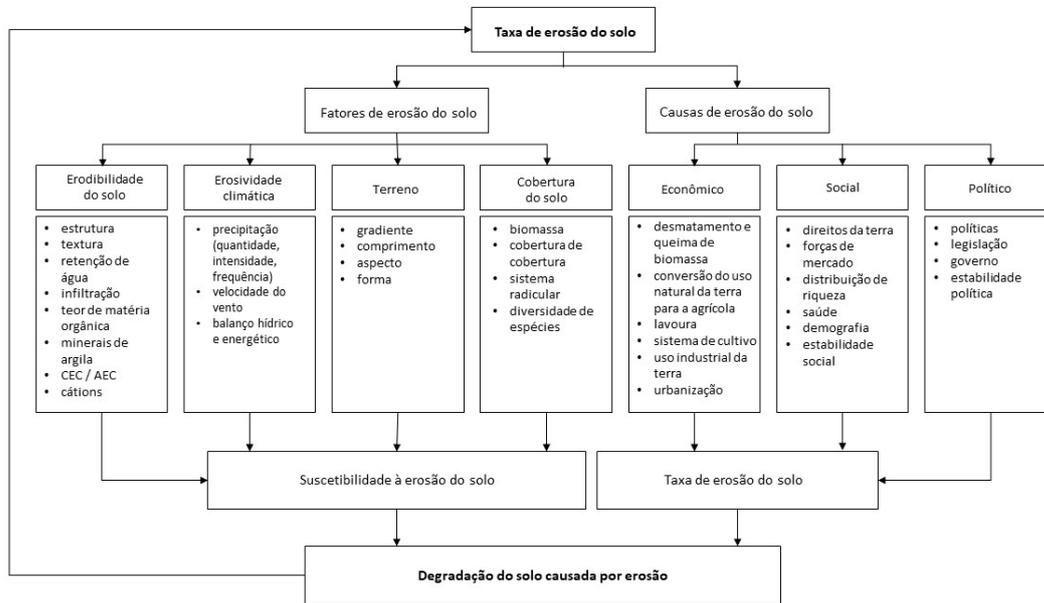
Para Gomes (2002, p. 32) *“a atuação lenta e continua dos processos erosivos modifica o quadro dinâmico da paisagem terrestre, que pode ser agravado ou não, com a interferência antrópica”*. Essas ações vão se diferenciar conforme a intensidade da chuva, declividade do terreno, impermeabilidade do solo, erosividade e cobertura vegetal.

Segundo Gomes (2001), o processo de erosão, remove seus constituintes, sobretudo pela ação da água da chuva, portanto, na superfície da terra há um quadro extremamente dinâmico, no qual diversos processos atuam de maneira contraditória, formando e erodindo os solos.

A erosão é um processo natural, que modifica a paisagem, de modo lento e pode ocorrer aceleração do processo por ação antrópica (BASTOS, 1999). Essas modificações causam problemas de ordem ambiental e socioeconômica, tendo como consequências a redução da fertilidade dos solos, o assoreamento de cursos de água, as enchentes, entre outros.

De acordo com Dantas-Ferreira (2004), os fatores que mais influenciam nos processos erosivos são: o índice pluviométrico, a susceptibilidade dos materiais geológicos presentes (materiais inconsolidados), a forma do relevo (landforms) e o uso e ocupação do solo, sendo que, a ação do Homem é um dos principais fatores para que ocorra o desequilíbrio dessas áreas e o início do processo erosivo. A Figura 1 apresenta as causas e fatores de acordo com LAL (1990).

Figura 1 - Fatores que influenciam nos processos erosivos



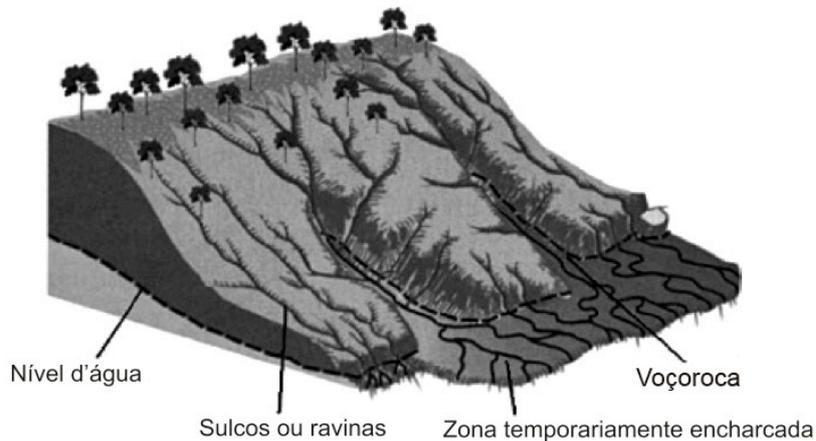
Fonte: Lal (1990)

### 2.1.1 Tipo de Feições Erosivas

Os principais termos aplicados às feições erosivas como pode ser visto na Figura 2, são: laminar, linear (sulco, ravina e voçoroca), intersulco, piping e erosão de margem (SOUZA, 2001).

Erosão Laminar - caracterizada por um arrastamento uniforme de partículas pequenas da camada superficial do solo, geralmente em declividades uniformes. A camada de água, quando constante, arrasta apenas as pequenas partículas. Denominada também de erosão em lençol, ocorre durante as fortes precipitações, quando o solo superficial já está saturado, sendo produzido por um desgaste suave e uniforme da camada superficial em toda sua extensão.

Figura 2 - Tipos de erosões



Fonte: Teixeira (2009)

Erosão Linear - é dividida em: sulco, que ocorre em declives irregulares, que facilita a concentração de água em determinadas partes da área, provocando a abertura de sulcos no solo. Ravinas, que são as feições resultantes do aprofundamento dos sulcos, sendo a continuação do processo de erosão, aumentando o tamanho. Os processos erosivos, para Ab'Saber (1968), estão associadas às paisagens de onde foi retirada a cobertura vegetal. Nestas paisagens, a água de escoamento superficial ao percolar linearmente no solo, ao atingir o lençol freático, compromete a estabilidade da área e gera a formação de voçorocas.

Intersulco - causada pelo escoamento superficial, é o impacto das gotas da chuva na superfície, que vão desintegrar parte dos agregados do solo. O golpe das gotas afeta primeiramente, a estrutura da capa superficial, predispondo a um desprendimento das partículas, que em seguida serão mobilizadas pelo escoamento (GOMES, 2001).

*Pipping* - o termo é da língua inglesa e não foi traduzido (Souza, 2001), este processo ocorre internamente no solo, na formação de tubos (processo também conhecido por entubamento). Esse processo em estágio avançado pode ocasionar problemas no terreno, os desabamentos vão alagar as voçorocas e criar novos ramos.

Erosão marginal - é causada pelo escoamento concentrado nos cursos de água, sua formação é parecida com a de ravinas e voçorocas, com o afundamento do terreno por meio do escoamento das águas. Segundo Llopis Trillo (1999), se as pequenas incisões que circulam água no terreno não forem eliminadas, irão progredindo em sentido do escoamento, captando e desprendendo materiais de maior tamanho devido a sua falta de coesão por excesso de umidade, chegando a produzir profundas incisões, mais de 30cm passando a vários metros de profundidade, com secções em forma de U, de V, ou uma combinação de ambas.

## 2.2 Cartografia Geotécnica

O mapeamento geológico-geotécnico permite representar em meio cartográfico os componentes geológicos e geotécnicos de significância para análise da degradação. O que possibilita visualizar suas particularidades de cada local, com informações sobre o tipo de solo, substrato e relevo predominante.

Na literatura, encontra-se disponíveis diversas metodologias estrangeiras e nacionais para o mapeamento geotécnico, destacando-se a proposta por Zuquette (1993) que considera as condições ambientais brasileiras. Este procedimento de mapeamento é realizado a partir de um conjunto de documentos cartográficos e tem por finalidade básica levantar, avaliar e analisar os atributos que compõem o meio físico

Os estudos geotécnicos vão definir os parâmetros do solo ou rocha, usando sondagem, ensaios de campo ou ensaios de laboratório. Podemos considerar o mapeamento geotécnico como um importante processo de investigação, com finalidades bem específicas de levantar dados, caracterizar, classificar, avaliar e analisar os atributos do meio físico. Apresentando por meio de produtos cartográficos, tabelas, quadros, gráficos, textos e dos quantitativo e/ou qualitativo (GOMES, 2002).

A elaboração de produtos cartográficos auxilia na compreensão dos dados, por meio de uma visualização espacial mais detalhada da área de estudo em questão.

Os primeiros trabalhos com características geotécnicas foram realizados em países desenvolvidos por Lange e Moldenharwer nos anos 1960 e 1970. No Brasil os primeiros trabalhos ocorrem nos anos 1960, com trabalhos de HABERLEHNER (1960), HEINE (1966), GREHS (1967). Os mais atuais e que merecem destaque são PRANDINI (1974), IPT (1980 E 1989), ZUQUETTE (1987 E 1993), COTTAS (1983), PEJON (1992) e NISHIYAMA (1991).

Esses trabalhos são de reconhecimento do meio físico que auxiliam no planejamento, tanto no âmbito regional, quanto urbano (Zuquette, 1981), seguindo políticas de uso e ocupação dos solos, que podem levar a uma melhor qualidade de vida e proteção do meio ambiente. Naturalmente os estudos geotécnicos desenvolvem-se para uma modelagem matemática e numérica do fenômeno da erosão por fluxo superficial (GOMES, 2001).

O mapeamento geotécnico vai ser uma ferramenta fundamental para orientar e subsidiar as mais variadas atividades antrópicas capazes de modificar o meio físico, ainda podendo se utilizar desses produtos para o planejamento urbano e regional (ZUQUETTE, 1987).

Segundo Gandolfi e Zuquette (1982), a carta geotécnica é aceita sem restrições como metodologia de trabalho para a geologia ambiental, por ser a forma mais completa e objetiva de registrar e apresentar os resultados, as informações e as sugestões.

Pons (2006) apresenta uma proposta metodológica para levantamento e diagnóstico geológico-geotécnico de áreas degradadas e em processo de degradação em ambientes urbanos, utilizando mapeamento geológico-geotécnico e técnicas de geoprocessamento. Em seu trabalho a autora assinala que por meio da aplicação desta metodologia foi possível identificar a maioria das degradações encontradas na cidade de São Carlos-SP.

Parar Vallejo *et al.* (2002) o mapeamento geotécnico constitui um método para apresentar cartograficamente informações geológicas-geotécnicas para fins de planejamento e uso do território e também para fins de projetos, construção e manutenção de obras de Engenharia. Portanto, o resultado apresentado nos mapas de natureza geológico-geotécnico inclui dados relativos as propriedades do solo e materiais inconsolidados, para avaliar o seu comportamento mecânico e prever problemas futuros. Todo conteúdo e detalhe dos produtos elaborados são em função da necessidade de representação, escala de trabalho, seu objetivo e disponibilidade de informações técnicas.

Para conhecer as propriedades do solo e definir fatores importantes aos processos naturais, o mapeamento de materiais inconsolidados é realizado em três fases: (a) a primeira tendo como base trabalhos de campo e aplicações das relações entre as feições do terreno e os modelos teóricos. Assim, são definidas e delimitadas as unidades dos materiais inconsolidados e suas principais características. Os trabalhos de campo devem ter definição prévia dos locais a serem amostrados para poder representar as características intrínsecas de cada material; (b) na segunda fase coleta-se o material de cada unidade identificada na fase anterior, amostras deformadas e indeformadas; (c) a terceira fase é a realização dos ensaios específicos em laboratório, para caracterização do comportamento mecânico e hidráulico do material.

A textura do solo desempenha um papel importante dentro das variáveis ambientais, ela controla a degradação, os processos de transporte e armazenamento

de água, influenciando direto na produtividade e qualidade do solo, atua direto na capacidade de retenção de nutrientes, retenção de poluentes, desenvolvimento radicular, biodiversidade do solo e ciclo biogeoquímico (CURCIO *et al.* 2013; COLE *et al.* 2017; DOBARCO *et al.* 2017; MIKHAILOVA *et al.* 2018; CASTRO-FRAANCO *et al.* 2018; SEYEDMOHAMMADI *et al.* 2019).

Um outro fator importante nos trabalhos dessa natureza é escalas adotadas nos produtos cartográficos, Zuquette (1987) comenta que podem ser: Escalas Gerais – menores que 1: 100.000; Escalas Regionais – de 1:100.000 a 1:25.000 e; Escalas Semidetalhadas – 1:25.000 a 1:10.000.

O mapeamento geotécnico pode ser aplicado em conjunto com outras metodologias, como no trabalho de Carvalho (2017a), onde as informações geotécnicas são avaliadas com os dados morfométricos da bacia hidrográfica estudada, e foram elaborados diversos mapas interpretativos e análises do potencial de inundação das bacias hidrográficas urbanas. De acordo com Carvalho (2017b) estudos que fornecem dados do espaço físico do território são de grande importância ao planejamento municipal, em seu trabalho teve como objetivo realizar o mapeamento geoambiental do município de Delfinópolis (MG), foi utilizado uma análise por agrupamento para delimitar áreas com alto nível de similaridade referente as características do meio físico.

Gomes (2018) fez uma pesquisa voltada para o entendimento dos processos de instabilização que afetam os taludes de corte das formações geológicas, utilizando duas diferentes escalas de análise, semidetalhada e detalhada. Os diferentes tipos de obras rodovias podem apresentar diferentes instabilidades de acordo com a geometria dos taludes, forma que ocorre o escoamento superficial e o tipo de solo.

Nessa linha de estudo de instabilidade de taludes Craig (2016), faz uma análise da susceptibilidade utilizando o método de talude infinito em ambiente SIG. O mapeamento geotécnico foi considerado uma ferramenta relevante no auxílio do traçado da malha e instrumento de gestão rodoviária. Foi aplicado o método de Bishop Simplificado em seções geológico-geotécnico de detalhe.

Dentre os problemas urbanos, também devemos considerar os de natureza geológica e hidrológica um dos mais recorrentes e causadores de transtornos socioeconômicos e de riscos a vida. Eiras (2017) elaborou um mapeamento de susceptibilidade a eventos perigosos de natureza geológica e hidrológica no município de São Carlos, combinando dados tanto qualitativos quanto quantitativos, com análise de frequência de eventos históricos e atributos do meio físico, os resultados foram considerados satisfatórios, todos os resultados foram validados em campo e laboratório, foi considerado enchentes/inundações evento mais crítico, alagamentos, erosões pluviais e movimentos de encostas que causam pequenos transtornos.

Todo processo de mapeamento leva em consideração o registro de observações em campo, para a elaboração de produtos cartográficos que contenham dados relativos aos tipos de rochas presentes na área, contatos litológicos, falhas, estruturas, solos, depósitos superficiais, topografia e geomorfologia, sua finalidade pode ser ampla ou específica.

### 2.3 Sistema de Informações Geográficas (SIG)

Existem algumas diferenças na definição de um Sistema de Informações Geográficas (SIG) ou *Geographic Information System* (GIS), visto que, os autores fazem sua definição de acordo com seu uso, por área de atuação, mas alguns autores definem como um conjunto integrado de *hardware*, *software*, informação espacial, procedimentos computacionais e recursos humanos que permite e facilita a análise, gestão ou representação do espaço e dos fenômenos que nele ocorrem, com a possibilidade de cruzar uma infinidade de informações cartográficas, dados *raster*, dados vetoriais, bem como colocar um conhecimento específico em uma análise, torna um sistema de informação geográfica uma ferramenta de grande utilidade para fins de ordenamento territorial e previsão de cenários (KIMERLING, 1994; FITZ, 2008; STANGANINI, 2016).

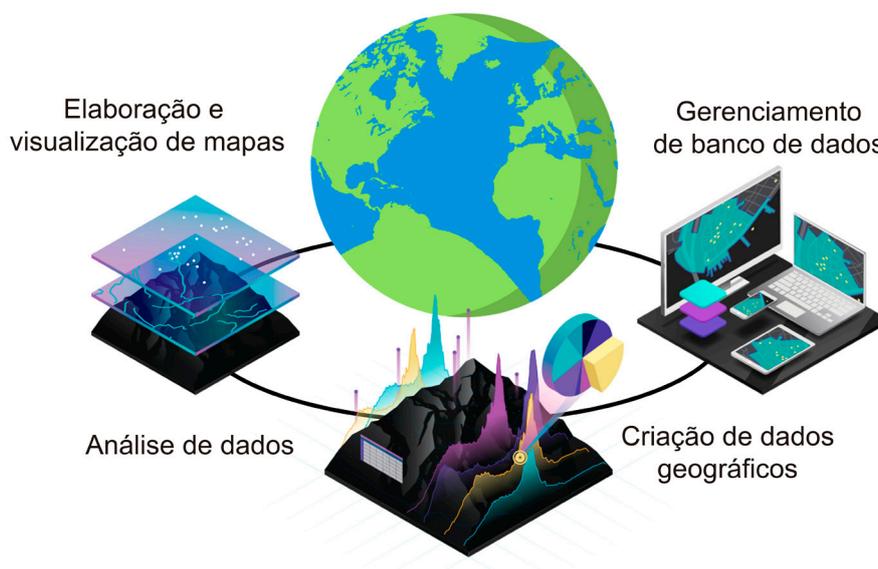
A ferramenta SIG é capaz de realizar operações complexas, integrando dados de diversas fontes, criando um banco de dados com informações georreferenciadas, ou seja, informações com coordenadas espaciais. Pode ser usado para diversas finalidades, como exemplo, diminuir e monitorar os riscos ambientais que aliado às técnicas de sensoriamento remoto e geoprocessamento, proporcionam bons resultados, pois permitem armazenar um grande número de dados e representá-los cartograficamente, colaborando com gestores e tomadores de decisão, com economia de recursos e tempo (ZANATA *et al.*, 2012).

A estrutura de entrada de dados de um SIG pode ser um dado vetorial ou dado matricial (*raster*), os dados vetoriais são representados por pontos, linhas e polígonos, os dados matriciais são formados por uma matriz de ponto ou células (*pixel*). A localização é representada por um sistema de coordenadas do centroide da célula, por coordenadas x-y e mais uma terceira sem representação espacial. Porém, Saboya (2000), cita alguns exemplos de atributos não espaciais numa matriz de ponto, como a altitude ou declividade em um relevo, tipo de solo, ou a quantidade de chuva de uma determinada área num período de tempo.

No que concerne a anatomia interna de um SIG, Câmara e Ortiz (1998) descrevem cinco componentes: (a) interface com usuário; (b) entrada e integração de dados; (c) funções de processamento gráfico e de imagens; (d) visualização e plotagem; (e) banco de dados geográficos. Relacionando-se de modo hierárquico, em um primeiro nível, mais próximo ao usuário, a interface homem-máquina define como o sistema é operado. No nível intermediário, um deve ter mecanismos de entrada, processamento, visualização e saída dos dados espaciais. No nível mais interno do sistema, um banco de dados geográficos lida com os dados espaciais e seus atributos.

O inter-relacionamento dos componentes principais de um sistema de informação geográfica (Figura, 3) operam sobre grandes arcabouços teóricos e metodológicos, indispensáveis para soluções de problemas espaciais.

Figura 3 - Estrutura de Sistema de Informações Geográficas



Fonte: Organizado pelo autor (2020)

Com a possibilidade de mesclar uma grande quantidade de dados cartográficos, utilizar de conhecimento específico em uma análise, torna essa ferramenta muito utilizada para fins de planejamento ambiental e territorial.

Não é novidade que as atividades humanas sobre o meio ambiente têm gerado mais problemas e conseqüentemente, aumenta a demanda por ferramenta que supra esse manejo com qualidade. Cada vez mais são necessários mapeamentos e monitoramentos dos recursos ainda hoje disponíveis, renováveis ou não renováveis.

Segundo Stanganini (2016), o uso das geotecnologias e de sistemas de informações tem intensificado nas últimas décadas, com isso, aprimorando os estudos e alocações das atividades dos municípios, permitindo aos planejadores direcionar o desenvolvimento e crescimento de modo a minimizar e dar maior capacidade de suporte para os possíveis impactos ambientais advindos de determinadas atividades.

O SIG inicialmente utilizado no auxílio na produção cartográfica, ganhou espaço como uma poderosa ferramenta, de extração e armazenamento de informações, tomada de decisão, em diversas áreas, comercial, saúde, ambiental, entre outras. Ligado aos problemas ambientais, o SIG auxilia nos mapeamentos, diagnóstico e avaliação de impactos no meio ambiente. Alguns trabalhos em diferentes áreas, utilizando essa ferramenta podem ser citados.

Domazetović *et al.* (2019) utiliza um modelo automático de análise de decisão multicritério baseada em GIS para determinar a presença de ravinas na Ilha de Pag na Croácia, o método conhecido como GAMA é aplicável em áreas cársticas. Para atribuir pesos específicos a cada critério foi utilizado o método de análise hierárquica (AHP), foram criados quatro modelos diferentes de susceptibilidade à erosão de encostas, para validar o modelo foi utilizado a curva ROC, com base em dois conjuntos de dados de voçorocas.

Na área da saúde o uso de banco de dados é muito eficiente, visto que, trata-se

de um fenômeno afetado por vários determinantes, são fatores pessoais, sociais, econômicos e ambientais. Os estudos relacionados à saúde pública na Turquia, estão focados na assistência médica utilizando a tecnologia como recurso essencial (DOGRU *et al.*, 2019).

Os riscos como poluição interna e externa, fumo passivo, água poluída, falta de assistência médica e higiene inadequada fazem com que cerca de 1,7 milhão de crianças menores de 5 anos percam suas vidas a cada ano (URL 4 ; NASCIMENTO *et al.*, 2018 ; MIDOUHAS *et al.*, 2017). Tais condições afetam particularmente a saúde das crianças em uma extensão considerável (GRIMALT *et al.*, 2017).

Os problemas relacionados a saúde são transversais a geografia do entorno, a análise espaço-temporal promove a introdução das características espaciais e interações dos problemas de saúde. Portanto, o uso do Sistemas de Informações Geográficas em estudos de saúde pública contribuiu para qualquer estudo ou pesquisa epidemiológica existentes (DOGRU *et al.*, 2017). As capacidades do SIG em relação à análise de dados espaciais e apresentação de informações derivadas de dados como mapas temáticos e outros trabalhos científicos podem ser consideradas como o potencial declarado da tecnologia (DOGRU *et al.*, 2019).

Trabalhos recentes nas áreas de engenharia e arquitetura mesclam o sistema BIM, de modelagem de informações de construção com o sistema de informações geográficas, fornecem representação digital arquitetônica e ambiental. Wang *et al.* (2019) fazem uma revisão sobre essa temática e ressalta que o BIM concentra-se na representação do ambiente em nível micro as próprias edificações, já o SIG fornece informações/representações em nível macro dos ambientes externos dos prédios, além do que, a combinação das técnicas pode proporcionar uma visão mais abrangente de um ambiente construído com base de dados integrados, que sustenta o desenvolvimento e a transição das indústrias de arquitetura, engenharia e construção na era digital.

A população mundial está aumentando e tem projeção para atingir um nível de 9,8 bilhões de habitantes até 2050 (UNITED NATIONS, 2017; HARRIS-LOVETT *et al.*, 2019; SINGH, 2019a; SINGH, 2019b; SINGH, 2019c). Nesse contexto alguns problemas são de extrema importância, como o gerenciamento de resíduos urbanos, Singh (2019c) propõe o uso de produtos de sensoriamento remoto e a ferramenta SIG. Com a utilização dessas técnicas é possível fazer a captura, manuseio e transmissão de informações necessárias de maneira adequada, rápida, com custo baixo de operação.

Em relação aos trabalhos sobre a disposição de resíduos urbanos, Costa *et al.* (2018) utiliza das técnicas em SIG e análise multivariada para elaborar uma carta potencial a implantação de aterro sanitário, foram utilizados como dado de entrada diversos atributos do meio físico (cobertura e uso da terra, geologia, propriedades dos materiais inconsolidados, declividade e forma das encostas) para compor as álgebras dos mapas e numa etapa seguintes, áreas excluídas de acordo com os aspectos legais, como, áreas de preservação permanentes, aeroportos e distância das áreas urbanas.

A produção dos mapas temático, utilizou o *software ArcGIS®* e uma metodologia de análise multicritério com matriz par a par. O resultado obteve uma classificação das classes de aptidão (favorável, moderada, severa e restritiva) para implantação do aterro. A análise multicritério, foi desenvolvida com a participação de uma equipe multidisciplinar e implantada com ferramentas de cartografia digital proporcio-

nou a seleção dos locais mais adequados mesmo considerando a diversidade de fatores envolvidos.

## 2.4 Análise Multicritério Aplicada em Estudos Ambientais

Para a criação de conhecimento em trabalhos acadêmicos ou empresariais é necessária uma técnica que melhore a avaliação dos dados, as técnicas de análise multicritério são populares, devido a possibilidade de trabalhar com uma diversos atributos simultaneamente, melhorando assim suas tomadas de decisões. Análise multivariada se refere a todas as técnicas estatísticas que simultaneamente analisam múltiplas medidas sobre os indivíduos ou objetos sob investigação. Assim, qualquer análise simultânea com mais de duas variáveis pode ser considerada, a princípio, como multicritério (HAIR *et al.*, 2009).

A tomada de decisões utilizando SIG vem crescendo em diversas áreas da sociedade, e com ela algumas preocupações relacionadas ao seu uso indiscriminado. São diversos os produtos gerados, podendo ser desde a localização de um imóvel, para um cadastro no município, ou a gestão, planejamentos ambientais e econômicos (FITZ, 2008).

Relacionadas ao planejamento ambiental, a técnica de análise multicritério pode ser aplicada em estudos como: definição de áreas mais adequadas para instalação de empreendimentos; análise de risco ambiental; análise de sensibilidade ambiental; e planejamento de uso do solo, entre outros (MALCZEWSKI, 2004; EASTMAN, 2003; COLLINS *et al.*, 2001; JIANG & EASTMAN, 2000).

O procedimento da análise multicritério é feito por meio de métodos matemáticos estatísticos, que compara os mais diferentes cenários, fundamentado em diversos critérios, com o objetivo de direcionar a decisão para uma escolha ponderada (ROY, 1996). Sendo um processo que combina e transforma dados espaciais em uma resposta para a tomada de decisão. Dentro do SIG permite um avanço nas metodologias de sobreposição de documentos cartográficos.

De acordo com Faria e Augusto Filho (2013), o método AHP foi desenvolvido por Thomas L. Saaty em meados da década de 1970 com base em conceitos de matemática e psicologia. Utilizando um critério de ponderação de pesos, o método fornece um procedimento compreensivo e racional para modelar um problema de decisão, representando e quantificando as variáveis envolvidas em uma hierarquia (BHUSHAN & RAI, 2004).

Segundo Souza (2015), o método AHP utiliza da análise multicritério baseado na decomposição e síntese das relações entre as variáveis e grupos de critérios, resultando na priorização dos seus indicadores, aproximando-se de uma melhor resposta de medição única de desempenho, utilizando a escala de julgamento definida por SAATY (1977).

A escala fundamental de Saaty (Quadro 1), fornece classificações utilizadas para a ponderação das variáveis par a par, onde, 1 significa a indiferença de importância de uma variável em relação a outra, e 9 significando a extrema importância de uma variável sobre outra, com estágios intermediários de importância entre 1 e 9. Esse processo resulta em uma matriz de comparação para a avaliação de cada variável analisada. (SOUZA, 2015).

Quadro 1 - Escala fundamental de Saaty (1977) para julgamentos de variáveis par a par

<b>Intensidade de importância</b>	<b>Definição</b>	<b>Explicação</b>
1	Mesma importância	As duas atividades contribuem igualmente para o objetivo
3	Importância pequena de uma sobre a outra	A experiência e o julgamento favorecem levemente uma atividade em relação à outra
5	Importância grande ou essencial	A experiência e o julgamento favorecem fortemente uma atividade em relação a outra
7	Importância muito grande ou demonstrada	Uma atividade muito fortemente favorecida em relação à outra; sua denominação de importância é demonstrada na prática
9	Importância absoluta	A evidência favorece uma atividade em relação à outra com mais alto grau de certeza
2,4,6,8	Valores intermediários entre valores adjacentes	Quando se procura uma condição de compromisso entre duas definições
Recíprocos dos valores acima de zero	Se a atividade i recebe uma das designações diferentes acima de zero, quando comparada com a atividade j, então j tem o valor recíproco quando comparada com i	Uma designação razoável
Racionais	Razões resultantes da escala	Se a consistência tiver de ser forçada para obter valores numéricos n, somente para completar a matriz

Fonte: Saaty (1977)

Os cálculos utilizando o método AHP, segue a regra de consistência com o valor inferior a 0.1, significa que há consistência para prosseguir. Se for maior do que 0.1 recomenda-se que julgamentos sejam refeitos. Na literatura, em geral, os 85 julgamentos par a par são subsidiados pelas considerações e resultados das pesquisas referentes ao tema e, principalmente, pelo conhecimento de especialistas da área (FARIA e AUGUSTO FILHO, 2013).

Como resultado temos um modelo que permite analisar várias alternativas com base na capacidade humana de usar a informação e a experiência para estimar magnitudes relativas por meio de comparações par a par realizadas de modo consistente e racional (TOMA & ASHARIF 2003, TRENTIM 2012).

O método AHP fornece suporte a tomada de decisão e é capaz de justificá-la (TRENTIM 2012). Sua aplicação é recomendada para solucionar problemas que implicam escolher soluções potenciais a partir da avaliação de um conjunto de dados (ASAHI *et al.* 1994, FINNIE & WITTIG 1999, KIM 1999). Os documentos

cartográficos no formato vetorial podem ser convertidos para o formato *raster* (matricial) e reclassificados, de acordo o método desenvolvido por SAATY (1980). Essas operações são realizadas dentro o ambiente SIG.

O processo de hierarquização é uma tarefa para representar o problema com o máximo de detalhamento possível, sem alterar a sensibilidade dos elementos, buscando solucionar o problema utilizando esse método de tomada de decisões. A definição dos pesos terá auxílio de outros profissionais devido à complexidade do problema, para uma hierarquização que defina a realidade do problema.

A matriz é construída por meio de comparação de critérios, de acordo com a importância relativa entre os pares de modelo de susceptibilidade adotado, por meio de uma escala continua de 9 pontos. Os fatores são comparados entre si e classificados segundo a maior importância em relação aos demais e controlam como os fatores irão compensar-se uns aos outros, numa escala variável de extremamente menos importante até extremamente mais importante, de acordo com a escala de julgamento.

Segundo Magri (2013), após a determinação dos valores de importância relativa, é necessário determinar os pesos de cada atributos e temas. Para calcular os pesos, as matrizes devem ser normalizadas, por meio da divisão de cada elemento pela somatória dos elementos da coluna a que ele pertence e por último fazer uma média aritmética de cada linha da matriz, obtendo assim os pesos.

Todos os critérios/fatores que são considerados relevantes para uma decisão são comparados um contra o outro em uma matriz de comparação por pares, que é uma medida para expressar a preferência relativa entre os fatores. Portanto, valores numéricos expressando um julgamento da importância relativa (ou preferência) de um fator em relação a outro devem ser atribuídos a cada fator.

De acordo com HAIR *et al.* (2009) muitas das técnicas multivariadas são complementos das análises univariadas (análises de distribuições de uma única variável) e da análise bivariada (classificação cruzada, correlação, análise de variância, e regressão simples usadas para analisar duas variáveis), por exemplo:

*“regressão simples (com uma variável preditora) é estendida no caso multivariado para incluir diversas variáveis predictoras. Analogamente, a variável dependente única encontrada na análise de variância é estendida para incluir múltiplas variáveis dependentes em análise multivariada de variância. Algumas técnicas multivariadas (por exemplo, regressão múltipla ou análise multivariada de variância) fornecem um meio de executar em uma única análise aquilo que antes exigia múltiplas análises univariadas para ser realizado. Outras técnicas multivariadas, não obstante, são exclusivamente planejadas para lidar com aspectos multivariados, como a análise fatorial, que identifica a estrutura inerente a um conjunto de variáveis, ou a análise discriminante, que distingue entre grupos baseada em um conjunto de variáveis.”*

Nos trabalhos relacionados ao meio físico, ambientais é muito comum o uso desse tipo de análise dentro de ambiente SIG. O trabalho de Rodríguez-Merino *et al.* (2020) utiliza dessa combinação, análise multicritério e SIG para avaliar a fragilidade de áreas protegidas, para evitar a subjetividade do método, que tem critério

estabelecidos por especialistas, foi adotada uma abordagem mais objetiva, focada na classificação da vulnerabilidade de uma zona dentro da área de proteção, por meio de bioindicadores.

Para identificar as zonas potencialmente frágeis, utilizou-se o método análise multicritério de soma ponderada, dentro do ambiente SIG. Os pesos dos critérios foram determinados pela contribuição das variáveis obtidas por meio de modelos de distribuição de espécies, por meio do algoritmo de entropia máxima.

## 2.5 Lógica Fuzzy

A lógica *fuzzy* ou lógica nebulosa se preocupa com os princípios formais do raciocínio aproximado, ou seja, fornece um ferramental matemático para o tratamento de informações de caráter impreciso ou vago (nebuloso). Nos últimos anos, diversos autores abordaram o tema mineração de dados, tais como, a lógica *fuzzy* (ERCANOGLU & GOKCEOGLU, 2002; KANUNGO *et al.*, 2006; KANUNGO *et al.*, 2008; LEE, 2007; MUTHU *et al.*, 2008; PRADHAN *et al.*, 2009; PRADHAN, 2010a; PRADHAN, 2010b).

Um sistema de lógica *fuzzy* pode operar dados numéricos e conhecimentos linguísticos simultaneamente. Um sistema *fuzzy* é um sistema não-linear de mapeamento de um vetor de entrada em uma saída escalar, isto é, um mapa de números dentro de um mapa de números. Uma das suas principais vantagens é que toda a formulação é feita a partir de regras linguísticas, sem necessidade de modelo matemático formal. Com isso, é capaz de incorporar tanto o conhecimento objetivo quanto o conhecimento subjetivo.

Segundo Zadeh (1965), “quanto mais próximo de um problema real alguém olha, mais nebuloso este problema se torna”. Conforme a complexidade de um sistema, nossa habilidade de fazer declarações precisas e significativas sobre o seu comportamento diminui, até alcançar um limite além do qual a precisão e relevância tornam-se características mutuamente exclusivas (OH & PRADHAN, 2011). A lógica *fuzzy* fornece um método para reduzir e explicar a complexidade de um sistema.

A riqueza da lógica *fuzzy* é que há um número enorme de possibilidades que levam a um grande número de diferentes mapas. No entanto, esta riqueza requer um cuidadoso conhecimento da teoria e dos elementos que a compõem.

Nos tópicos a seguir serão abordados os temas sobre os componentes de um sistema *fuzzy*, tais como: teoria de conjuntos *fuzzy*, relações básicas dos conjuntos *fuzzy*, regras *IF-THEN fuzzy*. Neste trabalho não serão utilizados todos os componentes deste sistema, mas terão uma breve explanação, mesmo que superficial.

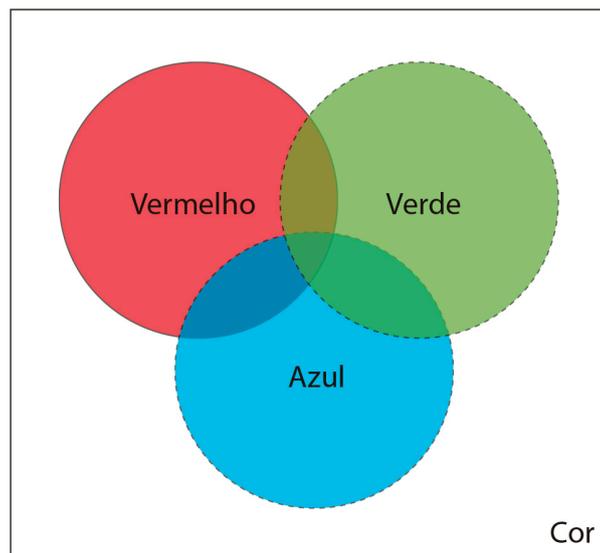
### 2.5.1 Teoria dos Conjuntos Fuzzy

Para Zadeh (1996), o conceito de conjunto *fuzzy* está associado com a capacidade de classificação ou categorização de um elemento no contexto do mundo real. Desta maneira, poucas vezes conseguimos definir com clareza, a qual classe de conjunto um elemento isolado pertence. Esta subjetividade existe porque na maioria das vezes um elemento pertence a mais de uma classe simultaneamente, por isto, a dificuldade de precisão em relação a classificação do elemento, sempre com um grau de incerteza quanto a classificação (Duda *et al.* 2000)

Para classificar um elemento são necessárias informações discriminantes, ou seja, cada uma dessas informações é representada matematicamente por um vetor de dimensionalidade, esses vetores, dentro da lógica *fuzzy*, são chamados de variáveis *fuzzy*, sendo assim, um único elemento utiliza uma ou mais variáveis *fuzzy* para ser classificado (Sandmann, 2006). Haykin (1999) comenta que o uso de um grande número de variáveis pode gerar um problema conhecido como “mal da dimensionalidade”, o que aumenta a complexidade do sistema em função do seu desempenho.

No universo *fuzzy*, a complexidade é igual ao mundo real, podendo conter um ou mais graus de pertinência, esses graus de pertinência são domínios de uma variável *fuzzy* (DUBOIS, 1996). Sandmann (2006) usa o exemplo que, ao tentar classificar um elemento quanto a sua cor podemos recorrer a uma variável *fuzzy*, porque é possível encontrar três universos de pertinência, como pode ser observado na Figura 4.

Figura 4 - Conjunto de pertinência de cores de uma variável *fuzzy* de cor qualquer



Fonte: Sandmann (2006)

A natureza e a necessidade de granularidade da aplicação, vão definir o grau de pertinência de uma variável do universo *fuzzy*, sendo que, esses graus de pertinência são dados por funções de pertinência. As funções de pertinência representam o valor de inferência de um elemento a ser classificado na curva de pertinência. Assim uma variável *fuzzy* genérica A pode ser descrita na forma de

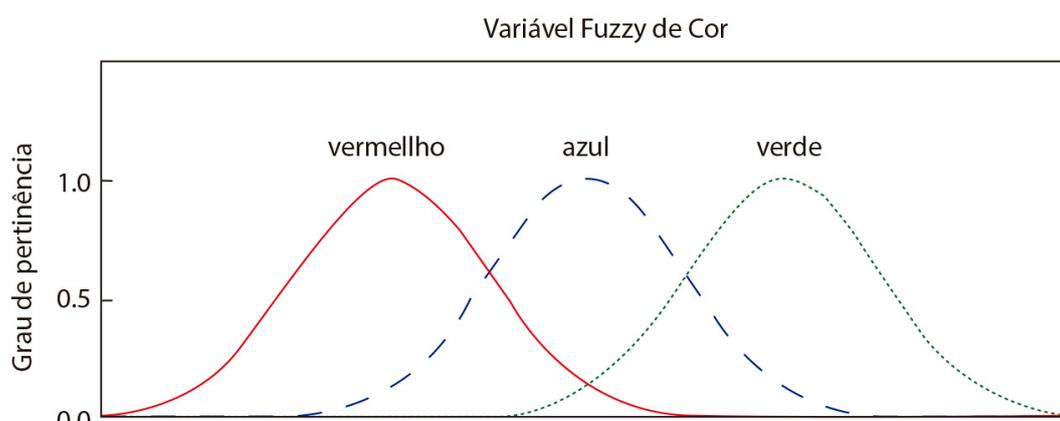
$$A = \{(x, \mu_A(x) | x \in X\} \quad (2.1)$$

Sendo a função  $\mu_A(x)$  uma função de pertinência do conjunto A (JANG *et al.*, 1997).

São diversas as equações para expressar uma função de pertinência, as mais comuns são equações triangulares, trapezoidais, gaussianas, entre outras.

Em conformidade com a Figura anterior, a Figura 5, mostra uma outra forma de visualizar de maneira clara o grau de pertinência do elemento dentro do universo da variável *fuzzy*. A teoria *fuzzy* atua sobre o grau de pertinência de um elemento dentro da variável *fuzzy*, e pode existir um ou mais graus de pertinência para o mesmo elemento. Quando adotado a um elemento, os graus de pertinência podem ser titulados por rótulos, logo, uma cor pode ser ao mesmo tempo verde e vermelho, ou até mesmo as três, o que se assemelharia ao mundo real (SANDMANN, 2006).

Figura 5 - Conjunto de pertinências de cores de uma variável *fuzzy* de cor, por meio deste gráfico é possível visualizar as curvas de pertinência das funções vermelho, verde e azul



Fonte: Sandmann (2006)

Conjuntos *fuzzy* podem ser operados como os conjuntos clássicos: podemos promover uniões, intersecções, complementar e elaborar o produto cartesiano entre conjuntos *fuzzy*. Os elementos dos conjuntos apresentam grau de pertinência que variam sempre entre 0 e 1, característica que tem mostrado grande aplicabilidade em geotecnologias.

Quando o seu comportamento é comparado com os conjuntos clássicos, apresentam uma distinção evidente dos conjuntos *fuzzy*, uma vez que nos conjuntos clássicos o elemento pertence ou não a um conjunto. De imediato, nos conjuntos *fuzzy*, o elemento contém grau de pertinência para cada conjunto, acontecendo em alguns casos desse grau de pertinência ser até mesmo 0.

### 2.5.2 Relações entre os Conjuntos Fuzzy

Ainda que as relações entre os conjuntos clássicos e os conjuntos *fuzzy* sejam feitas de maneira similar, os conjuntos *fuzzy* apresentam algumas particularidades em seu universo. Assim como nos conjuntos clássicos, os conjuntos *fuzzy* também são utilizados em operações lógicas, como as de união, intersecção e complemento de conjuntos *fuzzy* (ZADEH, 1965; JANG *et al.*, 1997; SANDMANN, 2006).

A seguir estão descritas algumas relações básicas realizadas com conjuntos *fuzzy*, de acordo com os autores citadas anteriormente.

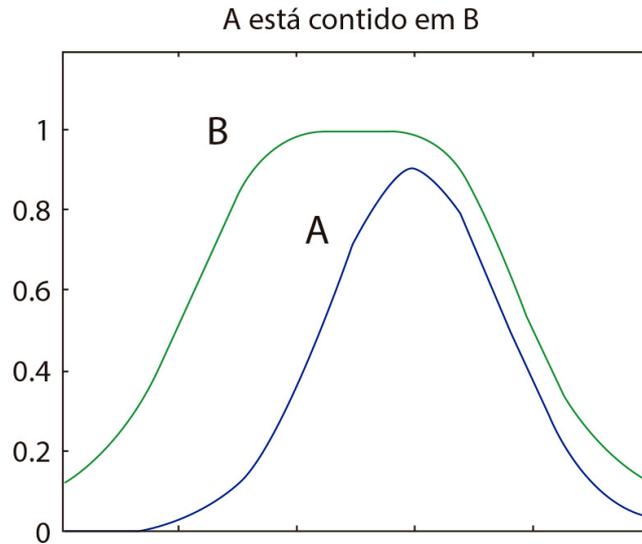
Conjunto contido ou subconjunto: é quando o conjunto *fuzzy*  $A$  está contido no conjunto *fuzzy*  $B$  (ou similar,  $A$  é um subconjunto de  $B$ , ou  $A$  é menor ou igual a  $B$ )

se e somente se  $\mu A(x) \leq \mu B(x)$  para todo  $x$ . Em símbolos temos que

$$A \subseteq B \Leftrightarrow \mu A(x) \leq \mu B(x). \tag{2.2}$$

Para ilustrar o conceito  $A \subseteq B$  segue a Figura 6.

Figura 6 - Conceito de  $A \subseteq B$



Fonte: Jang *et al.* (1997)

União: representa a união de dois conjuntos *fuzzy* A e B que gera um outro conjunto *fuzzy* C. A operação de união é representada como  $C=A \cup B$  ou  $C=A \vee B$ ,

$$\mu C(x) = \max(\mu A(x), \mu B(x)) = \mu A(x) \vee \mu B(x). \tag{2.3}$$

Interseção: quando o conjunto *fuzzy* A interseção com o conjunto *fuzzy* B resulta em um conjunto *fuzzy* C, escrito como  $C=A \cap B$  ou  $C=A \wedge B$ . Sua função de pertinência é denotada como

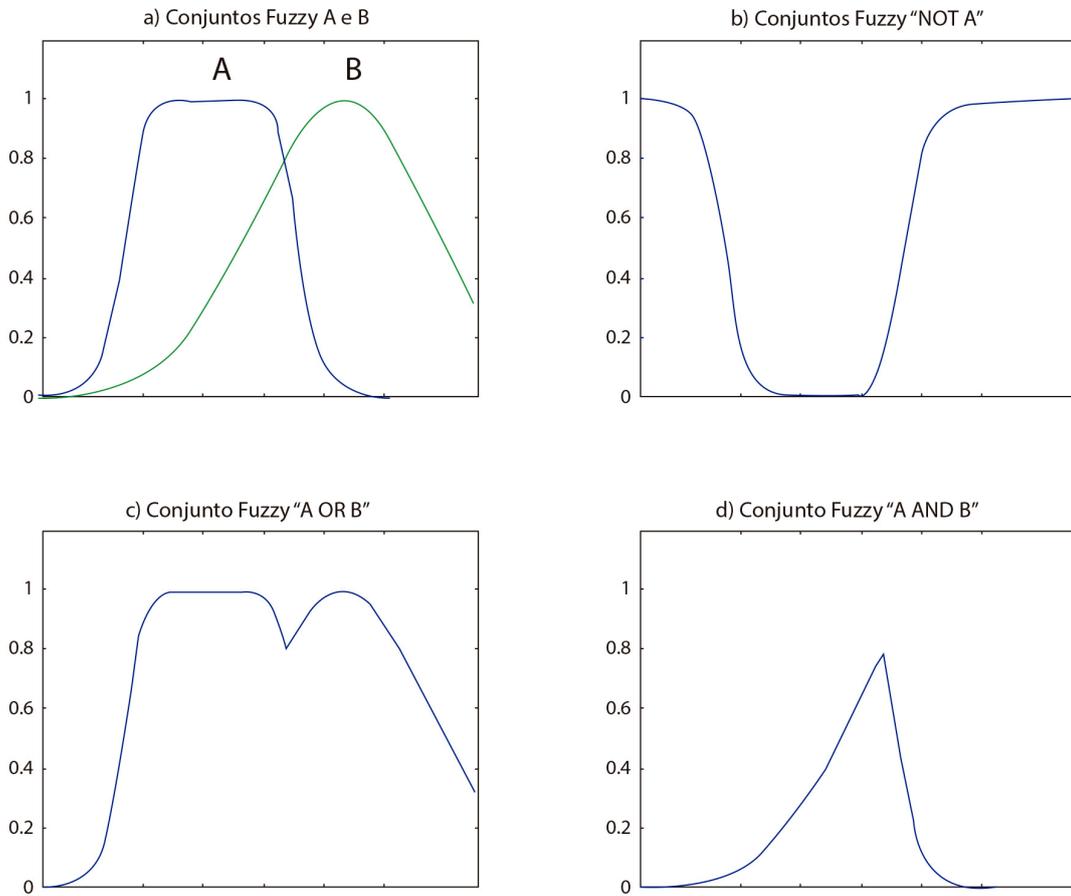
$$\mu C(x) = \min(\mu A(x), \mu B(x)) = \mu A(x) \wedge \mu B(x). \tag{2.4}$$

Complemento ou negação: é o complemento do conjunto *fuzzy* A, denotado por  $\bar{A}$  ou  $\neg A$ , é definido com

$$\mu \bar{A}(x) = 1 - \mu A(x). \tag{2.5}$$

Na Figura 7, é demonstrado as operações básicas aplicadas aos conjuntos *fuzzy*: (a) dois conjuntos *fuzzy* A e B; (b) é o complemento do conjunto *fuzzy* A; (c) a Figura ilustra a união dos conjuntos *fuzzy* A e B; (d) é representado a interseção entre os conjuntos *fuzzy* A e B.

Figura 7 - Operações lógicas em conjuntos *fuzzy* (Jang *et al.*, 1997)



Fonte: Jang *et al.* (1997)

A partir de operações lógicas simples com conjuntos *fuzzy*, é possível realizar operações mais complexas, por exemplo, o produto cartesiano e o coproduto cartesiano em conjunto *fuzzy*.

Produto Cartesiano: quando A e B estão nos conjuntos X e Y, respectivamente, o produto cartesiano entre os dois é designado com  $A \times B$ , que é o conjunto *fuzzy* do produto do espaço  $X \times Y$ . A função de pertinência é dada por

$$\mu_{A \times B}(x,y) = \min(\mu_A(x), \mu_B(y)). \tag{2.6}$$

Coproduto Cartesiano: é um conjunto *fuzzy* simular, ou seja, um conjunto formado pela maximização de dois pontos de pertinência, cujo o conjunto *fuzzy*  $A+B$  é dado pela função de pertinência

$$\mu_{A+B}(x,y) = \max(\mu_A(x), \mu_B(y)). \tag{2.7}$$

Essas operações são caracterizadas pelo uso de ao menos duas variáveis *fuzzy*, tornando sua interseção uma relação com, no mínimo, duas dimensões.

### 2.5.3 Regras IF-THEN Fuzzy

Neste tópico será abordado o conceito de variável linguística. Zedah (1973) propõe o conceito de variável linguística *fuzzy* como uma opção para modelar o pensamento humano, de maneira a sumarizar e expressar informações em termos de conjunto *fuzzy*, em vez de números discretos precisos. Os conjuntos *fuzzy* permitem manipular as informações que possuem características qualitativas, como as variáveis linguísticas no contexto do mundo real.

Para Gonçalves (2007), a variável linguística é uma variável cujos valores são nomes de conjuntos *fuzzy*. Sua principal função é fornecer uma maneira sistemática de aproximação de fenômenos complexos ou mal definidos. Portanto, valores de uma variável linguística podem ser sentenças em uma linguagem especificada, construída a partir de termos próprios (baixo, médio, alto), de conectivos lógicos (negação “não”, conectivos “e/ou”), de modificadores (muito, pouco) e de delimitadores (como parênteses) (SANDRI, 1999).

Por meio da possibilidade de operar variáveis linguísticas, faz-se possível criar regras lógicas para processar essas variáveis. Sandamann (2006) demonstra numa equação a seguir, uma simples dedução realizada por uma regra *fuzzy*, em que é possível fazer um processamento

$$\text{if } x \text{ is } A \text{ then } O \quad (2.8)$$

Na qual  $A$  e  $B$  são rótulos das funções de pertinência de duas variáveis *fuzzy*, definidas previamente. Portanto  $x$  e  $y$  são inferências de elementos no universo de discurso das funções de pertinência das respectivas variáveis *fuzzy*. Geralmente, o termo “ $x$  é  $A$ ” é chamado de antecedente ou premissa, enquanto o termo “ $y$  é  $B$ ” é chamado de consequência ou conclusão. Em uma maneira abreviada é comum encontrar essa notação como

$$A \rightarrow B, \quad (2.9)$$

ou seja, dado  $A$ , por consequência, temos  $B$ .

Essa expressão é conhecida como regra *IF-THEN fuzzy*. Essa expressão lógica simples é fundamental para começar uma discussão de raciocínio *fuzzy* (JANG *et al.*, 1997; ZADEH, 1996; KOSKO, 1992; SANDMANN, 2006). A partir desse raciocínio surge uma expressão capaz de relacionar as duas variáveis  $x$  e  $y$  de maneira linguística, coincidentemente permite um processamento das informações contidas das mesmas.

## 2.6 Fuzzy Inference System (FIS)

O Sistema de Inferência *Fuzzy* ou do inglês, *Fuzzy Inference System* (FIS) opera com conjuntos *fuzzy* na forma de um *framework*, permitindo implementação de aplicações com relações de conjuntos e regras *IF-THEN fuzzy*, que vimos anteriormente.

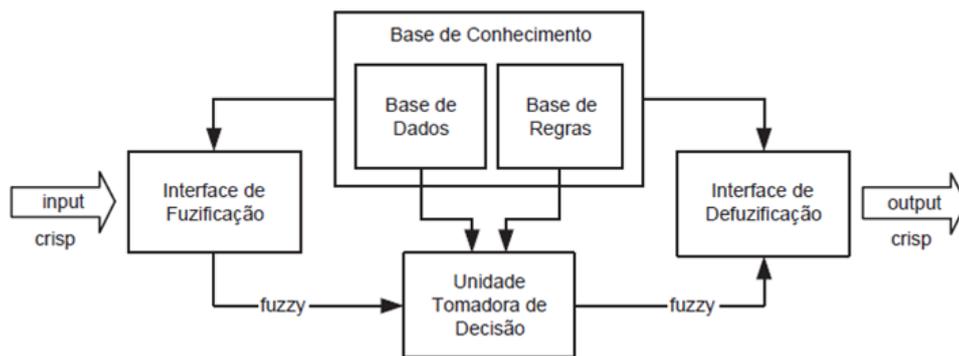
Um FIS funciona como um sistema de controle que recebe informações em valores numéricos de conjuntos clássicos, ou valores numéricos crisp, e transforma esses valores em inferência de variáveis linguísticas. Essa transformação é feita a partir das funções de pertinência contidas em cada variável *fuzzy* do sistema. O sistema passa a operar com rótulos linguísticos no lugar de valores dos conjuntos clássicos, esse processo de transformação é conhecido como fuzificação (JANG *et al.*, 1997).

Como apresentado anteriormente, é possível fazer operações com variáveis linguísticas por meio da aplicação de regras *IF-THEN fuzzy*. O FIS utiliza deste recurso depois da transformação das variáveis para o universo *fuzzy*, além de realizar operações que processam essas variáveis de maneira linguística, produzindo na saída uma outra variável linguística. Esse processamento é baseado em uma base de dados e regras que representam o conhecimento do especialista que elaborou o conhecimento a ser aplicado pelo FIS (SANDMANN, 2006).

De acordo com Lee (1990a, 1990b) o processo de transformação de uma variável *fuzzy* para uma variável dos conjuntos clássicos é conhecida como método de defuzificação. Para que o valor retorne ao sistema externo é necessário interpretar e converter novamente o valor da variável linguística em um valor dos conjuntos clássicos.

Na arquitetura padrão de FIS (Figura 8), o sistema é alimentado por dados de entrada em valores dos conjuntos clássicos, em seguida, ocorre a fuzificação desses valores, ou seja, são convertidos em valores de pertinência *fuzzy*. Só então, a variável *fuzzy* é processada por um tomador de decisões que faz uso das regras *IF-THEN fuzzy* elaborada por um especialista. No final do processo a variável *fuzzy* resultante é novamente transformada em uma variável dos conjuntos clássicos e, na sequência, é utilizada pelo sistema externo (JANG, 1993).

Figura 8 - Sistema de Inferência *Fuzzy* (FIS)



Fonte: Sandmann (2006)

O FIS determina uma estratégia de funcionamento básico para implantações de soluções *fuzzy* em diversas áreas do conhecimento: controle, classificação de padrões, tomadas de decisões, previsões de séries temporais, entre outras (LEE, 1990a; LEE, 1990b; DUBOIS *et al.*, 1996).

Na literatura existem basicamente três modelos FIS: o modelo Mamdani, o modelo Takagi-Sugeno e o modelo Tsukamoto. Substancialmente, no que difere os três modelos é na forma de operar os parâmetros consequentes e na forma de re-

alizer o processo de defuzificação (DUBOIS *et al.*, 1996).

Nos tópicos seguintes será feito uma breve apresentação das três implementações de modelos que constituem o FIS e seus processos de defuzificação.

### 2.6.1 Modelo Fuzzy Mamdani

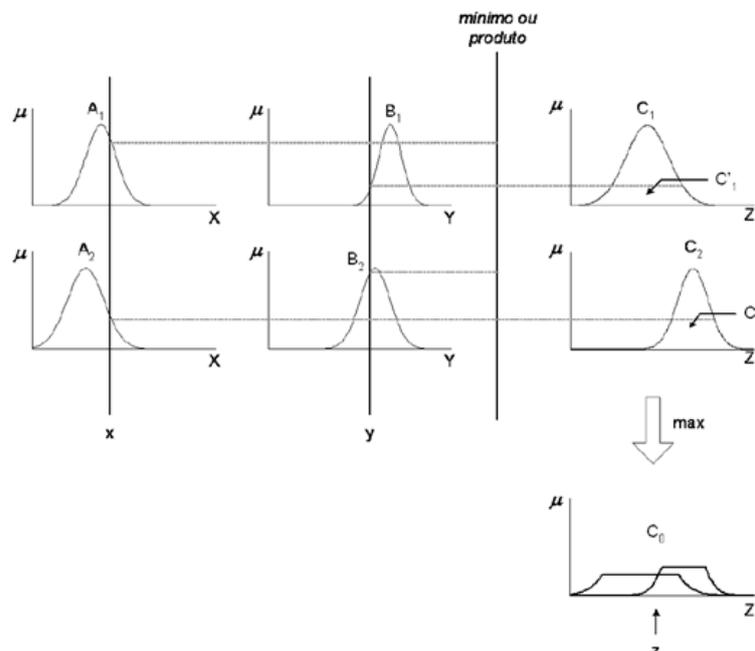
O modelo FIS Mamdani foi proposto como a primeira tentativa de controlar uma combinação de motor a vapor e caldeira por um conjunto de regras de controle linguístico obtidas de operadores humanos experientes. Este sistema utiliza operações de regras *IF-THEN fuzzy* elaboradas previamente por um especialista para realizar os processamentos de regras *fuzzy*. O processo de inferência no modelo Mamdani é dado pelas regras:

$$\begin{aligned} & \text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } z \text{ is } C_1 \\ & \text{if } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } z \text{ is } C_2. \end{aligned} \tag{2.10}$$

Na Figura 9, as duas primeiras colunas são variáveis de entradas  $x$  e  $y$  respectivamente, sendo que cada linha destas colunas representam as funções de pertinência das variáveis *fuzzy* de entrada,  $A_1$  e  $A_2$  pertencem à variáveis *fuzzy*  $A$ , e  $B_1$  e  $B_2$  pertencem à variável *fuzzy*  $B$  (JANG *et al.*, 1997)

Utilizando as regras *IF-THEN*, o sistema realiza uma operação de intersecção entre os valores das funções de pertinência obtidas para cada regra. Essa intersecção diminui os valores adquiridos como uma função *and* (descrita anteriormente). Os pontos tracejados (Figura 9) demonstram essa operação que são comparados, logo após é executada a operação *and*.

Figura 9 - Modelo *fuzzy* Mamdani



Adquiridos os valores de pertinência para cada função da variável *fuzzy* *C* de saída, é realizado pelo sistema uma operação de união entre a área dada por *C1* e *C2*. A área obtida pela união de todos os resultados das regras aplicadas sobre as variáveis *fuzzy* representa o valor numérico dos conjuntos clássicos da saída do sistema, dado por *z*.

Portanto, o processo de defuzificação pode ser feito pelo cálculo do centro da área obtida por *z*; correlacionando, a saída em valores dos conjuntos clássicos é produzida pelo cálculo do centro de gravidade dos conjuntos (Sandmann, 2006). A expressão a seguir realiza o cálculo de centro de gravidade para a saída de um FIS.

$$Z = \frac{\sum_{i=0}^m \mu_C(z_i)z_i}{\sum_{i=0}^m \mu_C(z_i)} \tag{2.11}$$

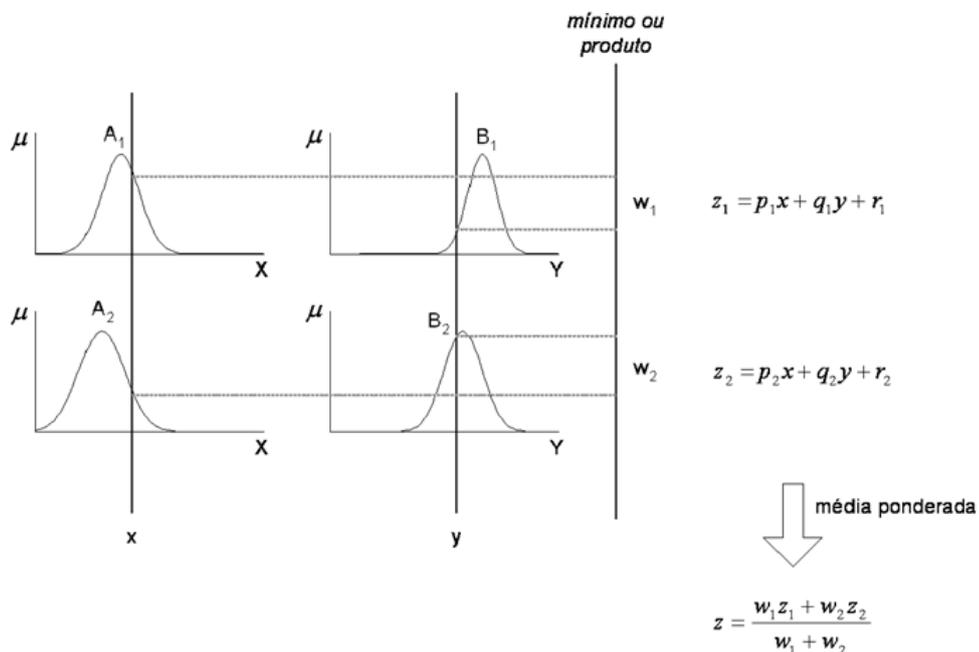
Onde *m* é o número de intervalos de quantização da saída, *z<sub>i</sub>* é o valor da variável de saída para intervalo de quantização *i* e  $\mu_C(z_i)$  é seu grau de pertinência.

### 2.6.2 Modelo Fuzzy Takagi-Sugeno

O modelo *fuzzy* Takagi-Sugeno, ou apenas Sugeno, utiliza uma função de mapeamento para cada saída de regra *IF-THEN fuzzy*. De acordo com Sandmann (2006), a função mapeia a entrada e saída da regra por uma combinação linear das entradas, por exemplo,  $z_1 = p_1x + q_1y + r_1$  (no caso de  $p = q = 0$ , logo  $z = r$ , temos uma função *singleton*).

Deste modo, os valores de *z1* e *z2* são dados por funções lineares que representam as funções de pertinência de uma análoga variável *fuzzy* *C* de saída. O processo do modelo Takagi-Sugeno é mostrado na Figura 10.

Figura 10 - Modelo *fuzzy* Takagi-Sugeno



O processo de defuzificação é realizado por meio da média ponderada da pertinência de saída na variável C. De forma genérica, z é obtido por:

$$Z = \frac{\sum_{i=1}^m \mu_i z_i}{\sum_{i=1}^m \mu_i} \quad (2.12)$$

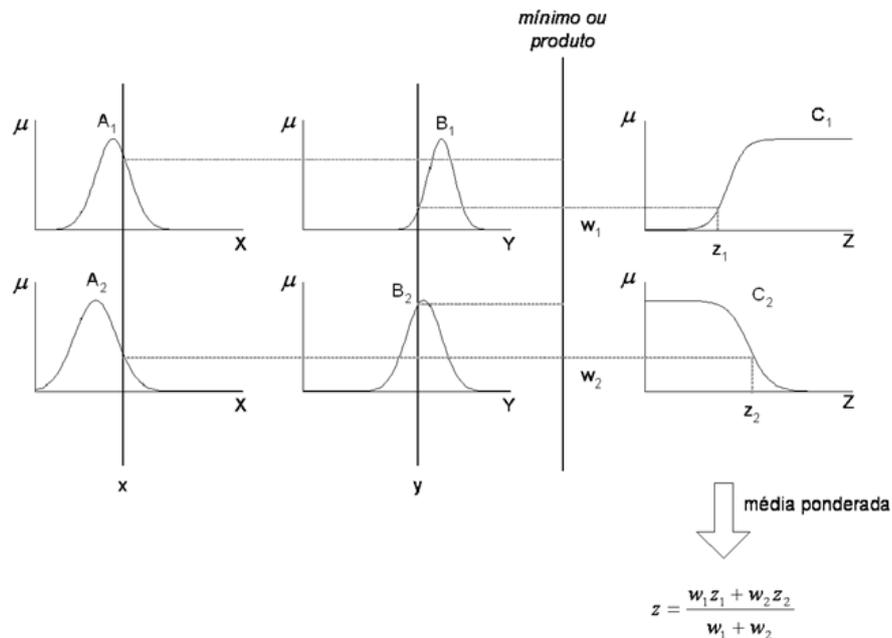
na qual n é o número de regras *fuzzy*,  $\mu_i$  é seu grau de pertinência da regra i, e  $z_i$  é o valor da função de pertinência de i.

### 2.6.3 Modelo Tsukamoto

No método de Tsukamoto cada conseqüente das regras *IF-THEN* deve ser representado por um conjunto *fuzzy* com função de pertinência monótona, a Figura 11, ilustra este modelo. Conseqüentemente, as saídas de interferência de cada regra são apresentadas de forma rigorosa. O resultado final é obtido por uma média ponderada (ARIANI & ENDRA, 2013).

Nesse método, o cálculo *fuzzy* é feito pela simples inferência do min das funções e pertinência avaliadas sob uma função de pertinência da variável de saída Z. Neste cenário, o processo de defuzificação é semelhante ao utilizado pelo método Takagi-Sugeno.

Figura 11 - Modelo *fuzzy* Tsukamoto



Fonte: Jang *et al.* (1997)

## 2.7 Adaptative Neuro-Fuzzy Inference System (ANFIS)

Um sistema de inferência neuro-*fuzzy* adaptativo (*Adaptative Neuro-Fuzzy Inference System* - ANFIS) é um tipo de rede neural artificial que é baseada no sistema

de inferência difusa Takagi-Sugeno. A ANFIS tem a função de implementar um FIS sob o domínio de redes neurais. A técnica foi desenvolvida no início dos anos 90.

Da mesma maneira que a FIS, a ANFIS possui modelos que implementam formas diferentes para o processamento dos parâmetros consequentes e defuzzificação dos dados de entrada. Como ele integra as redes neurais e os princípios da lógica *fuzzy*, tem potencial para capturar os benefícios de ambos em uma única estrutura (SANDMANN, 2006).

Seu sistema de inferência corresponde a um conjunto de regras *IF-THEN fuzzy* que possuem capacidade de aprendizado para aproximar funções não-lineares. Portanto, o ANFIS é considerado um estimador universal. Para utilizar o ANFIS de maneira mais eficiente e ótima, pode-se usar os melhores parâmetros obtidos pelo algoritmo genético (SEZER *et al.*, 2011). O sistema ANFIS pode aproximar todos os sistemas não lineares com menor conjunto e dados de treinamento, maior rapidez e maior precisão (HOU *et al.*, 2003).

Um dos sistemas de inferência *fuzzy* mais utilizados é baseado no modelo de Mamdani, mas os sistemas ANFIS, seguem o sistema de inferência Takagi-Sugeno. A principal diferença do modelo Mamdani em relação ao Takagi-Sugeno está no fato da saída poder ser linear ou constante. O modelo Takagi-Sugeno tem a forma:

$$\text{Se } \textit{Entrada1} = x \textit{ e } \textit{Entrada2} = y, \textit{ então Saída } z = px + qy + r \quad (2.13)$$

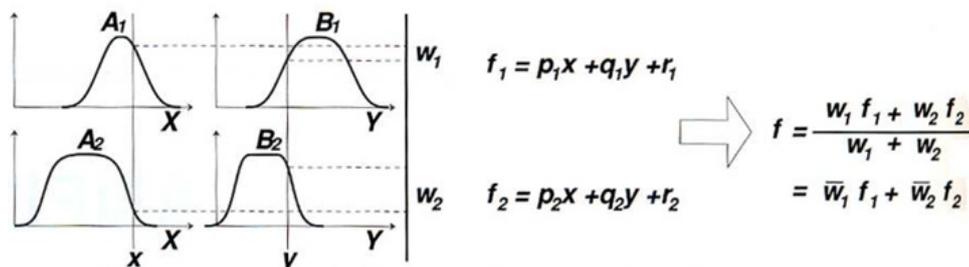
Para um modelo de Takagi-Sugeno de ordem zero o nível de saída  $z$  é uma constante ( $p = q = 0$ ).

Segundo Jang (1992), uma das principais vantagens do sistema de inferência Sugeno é sua eficiência computacional. Isto permite a construção de modelos *fuzzy* adaptativos. Deste modo, os ajustes feitos nas funções de pertinência se adaptam melhor ao conjunto de dados sem a necessidade de conhecimento especialista.

### 2.7.1 Arquitetura do Sistema de Inferência Neuro-Fuzzy Adaptativo

Jang (1993) desenvolveu uma das primeiras propostas de arquitetura neuro-*fuzzy*. Uma arquitetura ANFIS característica possui cinco camadas de neurônios, na Figura 12 apresentado a estrutura de um sistema *fuzzy* Sugeno com duas regras que podem sintetizar a derivação de um modelo ANFIS, sem qualquer perda de generalidade.

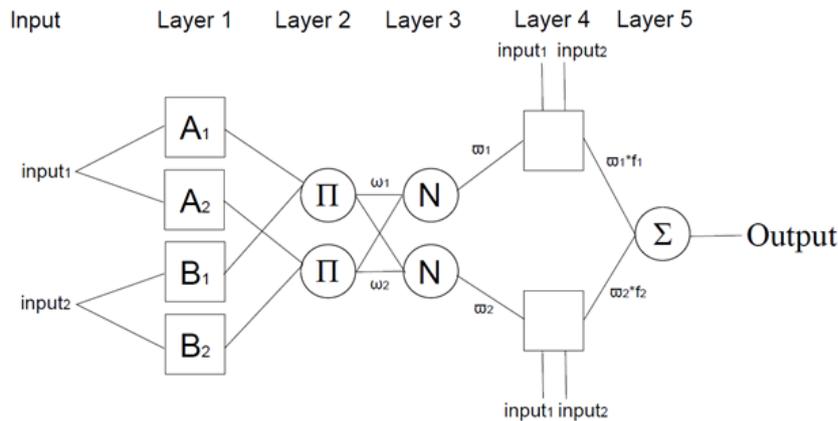
Figura 12 - Sistema *fuzzy* Takagi-Sugeno com duas entradas e duas regras



Fonte: Jang *et al.* (1997)

A Figura 13, apresenta o sistema ANFIS correspondente, com os nós das mesmas camadas tem funções análogas, como a descrita a seguir.

Figura 13 - Arquitetura ANFIS correspondente



Fonte: Jang *et al.* (1997)

Na arquitetura apresentada, o sistema de inferência embutido no ANFIS, proposto por Takagi e Sugeno (1985), as funções de pertinência das variáveis consequentes são funções das variáveis de entrada e não conjuntos difusos como no modelo tipo Mamdani. As regras têm, portanto, a seguinte forma geral:

$$R_i: \text{ Se } (x \text{ é } A_i) \text{ E } (y \text{ é } B_i) \text{ Então } (z_i = f_i(x, y)) \quad (2.14)$$

onde  $x$  e  $y$  são variáveis difusas de entrada sobre os universos de domínio  $U_x$  e  $U_y$ , e  $A_i$  e  $B_i$  são seus possíveis valores difusos sobre os mesmos universos de domínio.

A ANFIS recebe as variáveis do mundo real no formato dos conjuntos clássicos. Por meio das iterações em suas camadas, os dados de entrada são transformados em variáveis linguísticas, no final retornando à variável em formato dos conjuntos clássicos. A seguir apresenta-se uma breve descrição de cada uma das camadas, de acordo com Jang (1993).

Camada 1 - todo nó  $i$  nessa camada é um nó adaptativo com uma função definida por:

$$O_{i,i} = \mu_{A_i}(x), \text{ para } i = 1, 2, \text{ ou } O_{i,i} = \mu_{B_{i-2}}(y) \text{ para } i = 3, 4, \quad (2.15)$$

onde  $x$  (ou  $y$ ) é a entrada de nó  $i$  e  $A_i$  (ou  $B_{i-2}$ ) é o rótulo linguístico associado a esses nós. Resumidamente, este nó determina o grau de pertinência das entradas a uma dada função de pertinência do conjunto de funções de pertinência. Parâmetros dessa camada são tratados como parâmetros de premissa.

Camada 2 - é do tipo não-adaptativa, portanto, não possui parâmetros a serem ajustados. Nesta é executada uma função fixa de multiplicação dos sinais de entrada na camada, tendo como resultado o grau de aplicabilidade ( $\omega_i$ ) de uma regra.

Matematicamente, tem-se que:

$$O_{2,i} = \omega_i = \mu_{A_i}(x), \mu_{B_i}(y) \quad i=1,2 \quad (2.16)$$

Cada nó representa o nível de disparo de uma regra.

Camada 3 – cada nó nessa camada é um nó fixo denominado N. O *i*ésimo nó calcula a razão do nível de disparo da *i*ésima regra para a soma do nível de disparo de todas as regras:

$$O_{3,1} = \bar{\omega}_i = \frac{\omega_1}{\omega_1 + \omega_2}, \quad i=1,2 \quad (2.17)$$

Camada 4 – cada nó *i* desta camada é um nó adaptativo com a função de nó dada por:

$$O_{4,1} = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x + q_i y + r_i) \quad (2.18)$$

Onde  $\omega_i$  é o nível de disparo normalizado proveniente da camada 3 e  $(p_i, q_i, r_i)$  é o conjunto de parâmetros para este nó. Parâmetros nesta camada são referenciados como parâmetros consequentes.

Camada 5 – o único nó dessa camada é um nó fixo denominado  $\Sigma$ , o qual calcula a saída total como um somatório de todos os sinais de entrada:

Ao final deste processo, o ANFIS equivale a um sistema de inferência, com a mesma vantagem de incorporar ao seu processo o conhecimento aproximado de um especialista.

$$\text{Saída total} = O_{5,1} = \sum_i \bar{\omega}_i f_i = \frac{\sum_i \omega_i f_i}{\sum_i \omega_i} \quad (2.19)$$

## 2.8 Redes Neurais Artificiais (RNA)

As redes neurais representam uma tecnologia que têm raízes em muitas disciplinas: neurociência, matemática, estatística, física, ciência da computação e engenharia. Uma rede neural “artificial” é um dispositivo capaz de processar informação de forma distribuída e de incorporar conhecimento por meio de exemplos.

A motivação da construção de uma rede neural nasceu da ideia de modelar a rede de neurônios humanos visando compreender o funcionamento do cérebro. Portanto, uma rede neural artificial se assemelha ao cérebro humano em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente por meio de um processo de aprendizagem e os pesos sinápticos, que são as forças de conexão entre neurônios, são utilizados para armazenar o conhecimento adquirido.

As redes neurais artificiais são consideradas boas técnicas computacionais para estimar funções, já que podem aproximar um comportamento desejado, sem

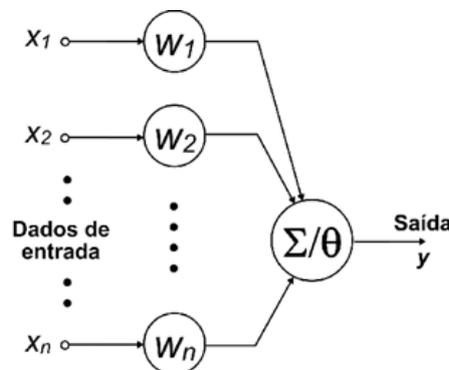
a necessidade de especificar uma função particular, ou seja, são eficientes no tratamento de problemas nos quais a relação entre variáveis não é totalmente conhecida.

O neurônio artificial, ou nó neural, é um processador simples, que capta as informações exteriores ou de outros nós, toma uma única decisão sobre elas e passa o resultado para o próximo nó neural. As redes neurais são formadas pela combinação de muitos nós, tendo assim, a capacidade de tomar decisões complexas.

Segundo Braga *et al.* (2007), o modelo de neurônio artificial proposto por McCulloch e Pitts (MP43) é uma simplificação do que se sabia na época a respeito do neurônio biológico, que resultou no modelo matemático com  $n$  terminais de entrada (dendritos) que recebem os valores  $x_1, x_2, \dots, x_n$  (que representam a ativação dos neurônios anteriores) e um terminal de saída  $y$  (representando o axônio).

A representação dos comportamentos sinápticos tem pesos acoplados nos sinais de entrada  $w_1, w_2, \dots, w_n$ , cujos valores podem ser positivos ou negativos, dependendo de as sinapses correspondentes serem inibitórias ou excitatórias. O efeito de uma sinapse particular  $i$  no neurônio pós-sináptico é dado por  $x_i w_i$ , a Figura 14 é uma descrição deste modelo (BRAGA *et al.*, 2007).

Figura 14 Neurônio MCP, no qual a  $\Sigma$  representa a soma ponderada das entradas e a função de ativação



Fonte: Braga *et al.* (2007)

O disparo de um neurônio biológico acontece quando a soma dos impulsos que ele recebe ultrapassa seu limiar de excitação (*threshold*). Esse comportamento no modelo artificial é representado por um mecanismo, que faz a soma dos valores  $x_i w_i$  recebidos pelo neurônio (soma ponderada) e decide se o neurônio deve ou não disparar (saída igual a 1 a 0), comparando a soma adquirida ao limiar ou *threshold* do neurônio. A ativação do neurônio no modelo de McCulloch e Pitts é obtida por meio de uma função de ativação, que ativa ou não a saída, o que vai determinar isso, é a soma ponderada dos valores de entrada.

De acordo com Braga *et al.* (2007), uma função de ativação é responsável por gerar a saída  $y$  do neurônio a partir dos valores dos vetores de peso  $w = (w_1, w_2, \dots, w_n)^T$ , e de entrada  $x = (x_1, x_2, \dots, x_n)^T$ . A função de ativação de um neurônio MCP, apresentada na equação X, é do tipo grau deslocado do limiar de ativação  $\theta$  em relação à origem, ou seja, a saída  $y$  será 1 para  $\sum_{i=1}^n x_i w_i \geq \theta$  e 0 para  $\sum_{i=1}^n x_i w_i < \theta$ . Na Figura 15 é mostrado os modelos mais comuns de funções de ativação. Entre elas a função degrau (Figura 15a), para  $\theta=3$ . Uma aproximação contínua da função degrau,

cuja derivada é conhecida em sua forma analítica (Figura 15b) e na equação x. Essa função, além de ser diferenciável, possui uma região semilinear, importante na aproximação de funções contínuas. Conforme o tipo de problema a ser abordado, neurônios com função de ativação lineares, como mostrada na Figura 15c e na equação, podem também ser utilizadas. Nas redes neurais artificiais do tipo RBF (*Radial Basics Functions*) utilizam neurônios com funções de ativação radiais, como a função gaussiana apresentada na Figura 15d e na equação.

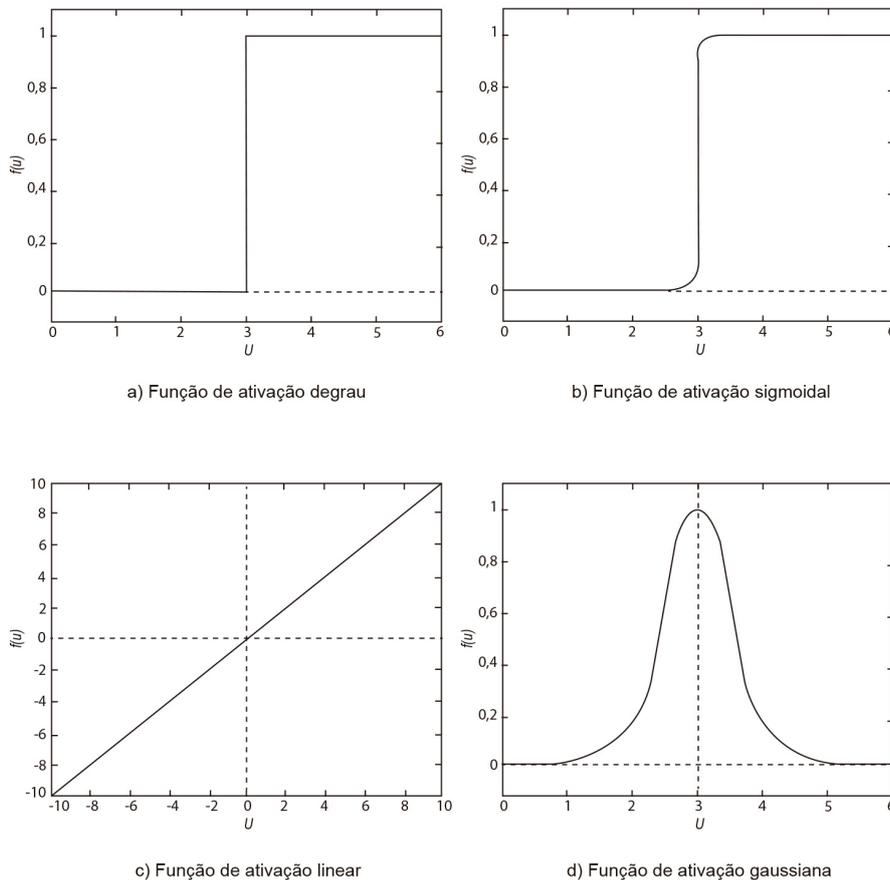
$$f(u) = \begin{cases} 1 & \sum_{i=1}^n x_i w_i \geq \theta \\ 0 & \sum_{i=1}^n x_i w_i < \theta \end{cases} \quad (2.20)$$

onde  $\sum_{i=1}^n x_i w_i$  e  $\theta$  é o limiar (*threshold*) da função de ativação.

$$f(u) = \frac{1}{1 + e^{-\beta u}} \quad (2.21)$$

onde  $\beta$  é a inclinação da função.

Figura 15 - Exemplos de função de ativação



$$f(u)=u \tag{2.22}$$

$$f(u) = e^{-\frac{(u - \mu)^2}{r^2}} \tag{2.23}$$

Onde  $\mu$  é o centro (ponto médio) e  $r$  o raio de abertura da função.

### 2.8.1 Arquitetura de Redes Neurais Artificiais

A capacidade individual do neurônio é limitada, independente da escolha da função de ativação. Porém, uma rede de neurônios artificiais conectados é capaz de resolver problemas de alta complexidade. A Figura 16 mostra algumas configurações possíveis de neurônios artificiais conectados na forma de redes neurais artificiais.

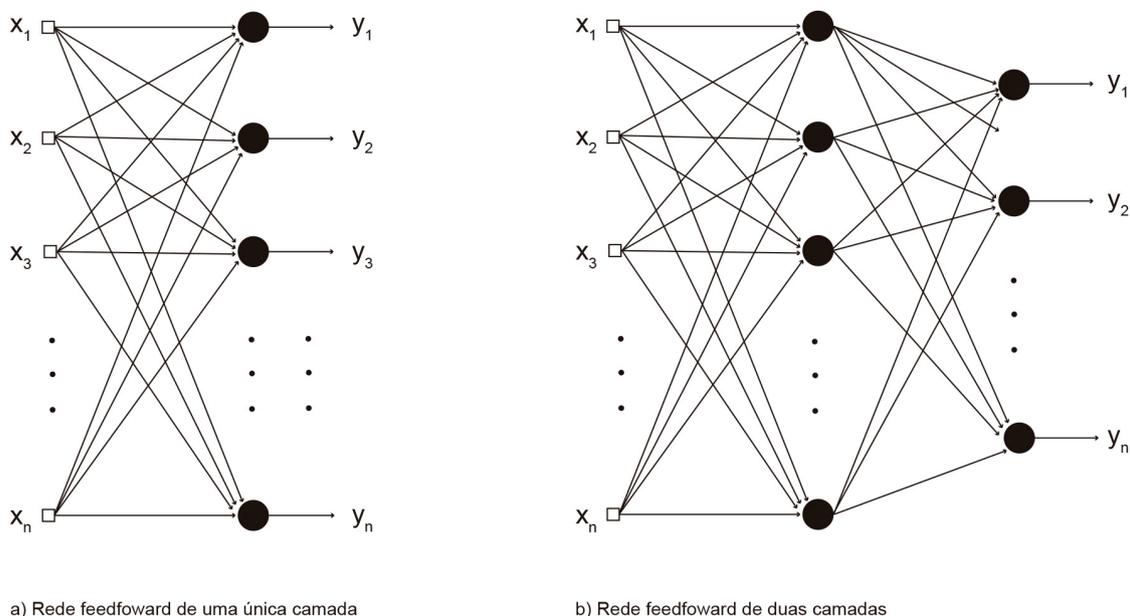
É apresentada uma estrutura mais simples na Figura 16a uma rede neural de camada única alimentada para a frente (*feedforward*). Essas estruturas são eficientes para resolver problemas multivariáveis de múltiplas funções embutidas, mas com algumas restrições de complexidade, por serem de uma única camada.

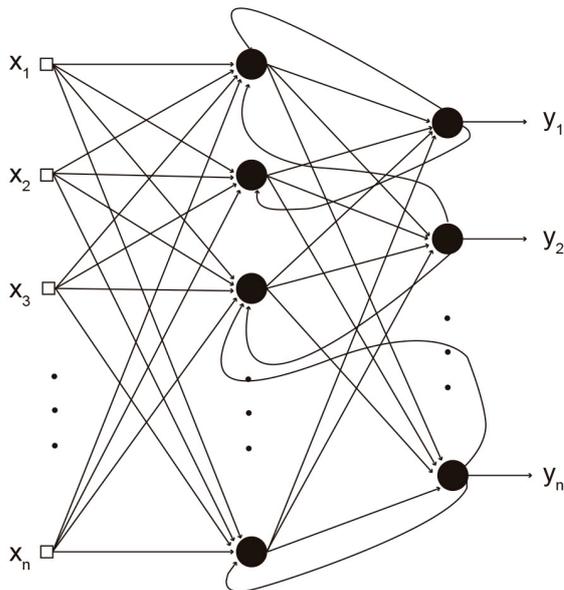
A Figura 16b é similar a Figura 16a, com a diferença de uma camada adicional. Essa camada intermediária aumenta a capacidade computacional e universalidade na aproximação de funções contínuas das redes neurais. As RNAs são consideradas estáticas, sem recorrência na sua estrutura, as suas saídas dependem apenas das entradas atuais.

Na Figura 16c é apresentado uma estrutura de RNA que é utilizada para solucionar problemas que envolvem processamento temporal, como em previsões de eventos, a saída depende somente das entradas, mas também do seu valor atual.

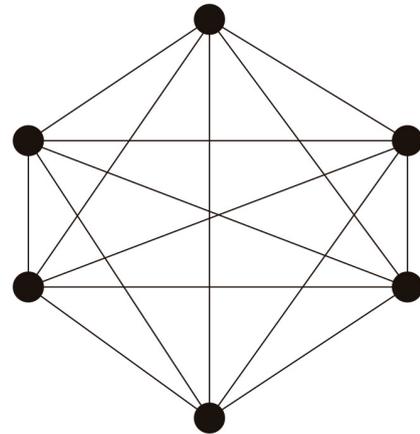
A Figura 16d possui um único nível de neurônio na sua estrutura, em que a saída de cada um deles está conectada às entradas de todos os outros. A rede não possui entradas externas, e sua operação se dá de uma função da dinâmica de mudança de estados dos neurônios, que operam de forma auto associativa (BRAGA *et al.*, 2007).

Figura 16 - Arquitetura de RNAs





c) Rede com recorrência entre saídas e camadas intermediárias



d) Rede com recorrência auto-associativa

Fonte: Braga *et al.* (2007)

### 2.8.2 Treinamento das Redes Neurais Artificiais (RNA)

Para alcançar os objetivos com as RNAs, elas devem ser treinadas. O treinamento de uma rede neural artificial constitui-se em fazê-la adotar valores, pesos e limiares baseado em amostragem, de modo que, nas próximas amostras apresentadas a rede ela seja corretamente classificada. Ou seja, são apresentadas amostras/dados na entrada da rede e direcionados a uma resposta desejada, fazendo com que a rede seja obrigada a modificar seus pesos e limiares. De modo que, qualquer valor apresentado à rede depois que ela estiver devidamente treinada produzirá uma saída ou resultado igual ou próximo do desejado (SILVA *et al.*, 2010).

Geralmente, para treinar e verificar se os pesos estão adequados na RNA, é necessário dividir as amostras existentes entre treinamento e validação da rede. Recomenda-se que a divisão seja 60% a 90% amostras para treinamento e 40% a 10% para testes. Denomina-se época de treinamento a cada vez que apresentamos uma amostra para ajuste dos pesos sinápticos e limiares da rede. De acordo com Silva *et al.* (2010), os principais tipos de treinamento são:

- (a) Supervisionado: Deve-se dispor das amostras e das respectivas saídas desejadas para que os pesos e limiares sejam ajustados continuamente pelo algoritmo de aprendizagem.
- (b) Não Supervisionado: A saída deve se auto organizar em relação às particularidades do conjunto de amostras e, assim identificar subconjuntos similares. Seus pesos e limiares são ajustados pelo algoritmo de aprendizagem de modo a refletir estas particularidades.
- (c) Com Reforço: Similar ao treinamento supervisionado, con-

tudo seu algoritmo visa ajustar os pesos e limiares baseando-se em informações procedentes da interação com o sistema mapeado, visando reforçar as respostas satisfatórias.

(d) Lote de Padrões (Offline): Apresenta-se primeiramente todo o conjunto de amostras para então se ajustar os pesos e limiares da rede.

(e) Padrão por Padrão (Online): Os pesos e limiares são ajustados após a apresentação de cada amostra permitindo que a mesma seja descartada posteriormente. Este tipo de treinamento é empregado quando o sistema a ser mapeado sofre variações ao longo do tempo. Observe que devido às características do sistema variante, este tipo de treinamento somente fornecerá respostas precisas após a apresentação de um número significativo de amostras.

### 2.8.3 Rede Neuro-Fuzzy

Segundo Rodrigues (2015), o termo Redes Neuro-*Fuzzy* refere-se à combinação de redes neurais artificiais com sistemas de inferência *fuzzy*, onde são incorporadas as técnicas de aprendizado automático de redes neurais artificiais com a capacidade de representação próxima do raciocínio humano oferecido pelo sistema *fuzzy*. Portanto, na fase de treinamento supervisionado, os dados são apresentados aos pares entrada/saída e como resultado existe um modelo linguístico da representação do conhecimento extraído dos dados na forma de um sistema de inferência *fuzzy* (JANG & SUN, 1995).

As redes neuro-*fuzzy* são de natureza híbrida, por isso, possuem características das redes neurais e dos sistemas de inferência *fuzzy*, ou seja, além do aprendizado matemático a partir de dados que fornece conhecimento implícito, as regras podem ser inseridas no sistema de inferência a partir do conhecimento explícito fornecido por especialista, gerando regras otimizadas a partir dos dados (RODRIGUES, 2015).

O aprendizado da rede pode ser de dois tipos, aprendizado online e aprendizado *offline*. No aprendizado *online* a rede modifica-se dinamicamente enquanto os dados são exibidos, de modo que ao fornecer mais dados para a rede ela não precisa ser treinada novamente com os dados anteriormente apresentados. Já no aprendizado *offline* a rede só é modificada após a apresentação de todos os dados do conjunto de treinamento e, caso novos dados tenham que ser apresentados, todos os conjuntos de treinamento deve ser apresentado novamente pra a rede (KASABOV & SONG, 2002).

De acordo com Jang (1993), a grande motivação de utilizar redes neuro-*fuzzy* é fornecer um mecanismo formal para converter experiência (dados) e conhecimento específico humano em uma representação do conhecimento de maneira explícita na forma de um sistema de inferência *fuzzy*.

## Caracterização da área de estudo

### 3.1 Localização e aspectos demográficos

A bacia hidrográfica do Rio Monjolinho (BHRM) representada na Figura 17, inserida nos municípios de São Carlos (maior parcela) e Ibaté (menor parcela), possui uma área de aproximadamente 273,77km<sup>2</sup>. Está localizada entre as coordenadas geográficas 48°5'52,9"W; 21°57'9,6"S e 47°49'29,2"W 22°6'10,1"S. Seu principal afluente é o Rio Monjolinho, que possui aproximadamente 43,3km de extensão e deságua no rio Jacaré-Guaçu. Segundo dados do IBGE (2017), o município de São Carlos tem uma área de 1.137,303km<sup>2</sup>, a área urbanizada é de aproximadamente 70km<sup>2</sup>, com 246.088 habitantes e densidade populacional de 216, 45 hab./km<sup>2</sup>. Tem como vizinho os municípios de Brotas, Ribeirão Bonito, Ibaté, Santa Lúcia, Itirapina, Luís Antônio, Analândia, Descalvado, Araraquara, Américo Brasiliense e Rincão.

### 3.2 Contexto Histórico

A cidade de São Carlos está localizada no interior do Estado de São Paulo, sendo a 13<sup>a</sup> maior cidade do interior do estado em número de residentes, famosa por suas universidades, por fazer parte de um importante centro industrial regional, polo em tecnologia e agropecuária (destacando-se na produção de cana-de-açúcar, laranja, leite e frango). Originalmente habitada por índios Guaianases, sua formação deu-se por pequenos grupos de posseiros, que possuíam pequenas porções de terra.

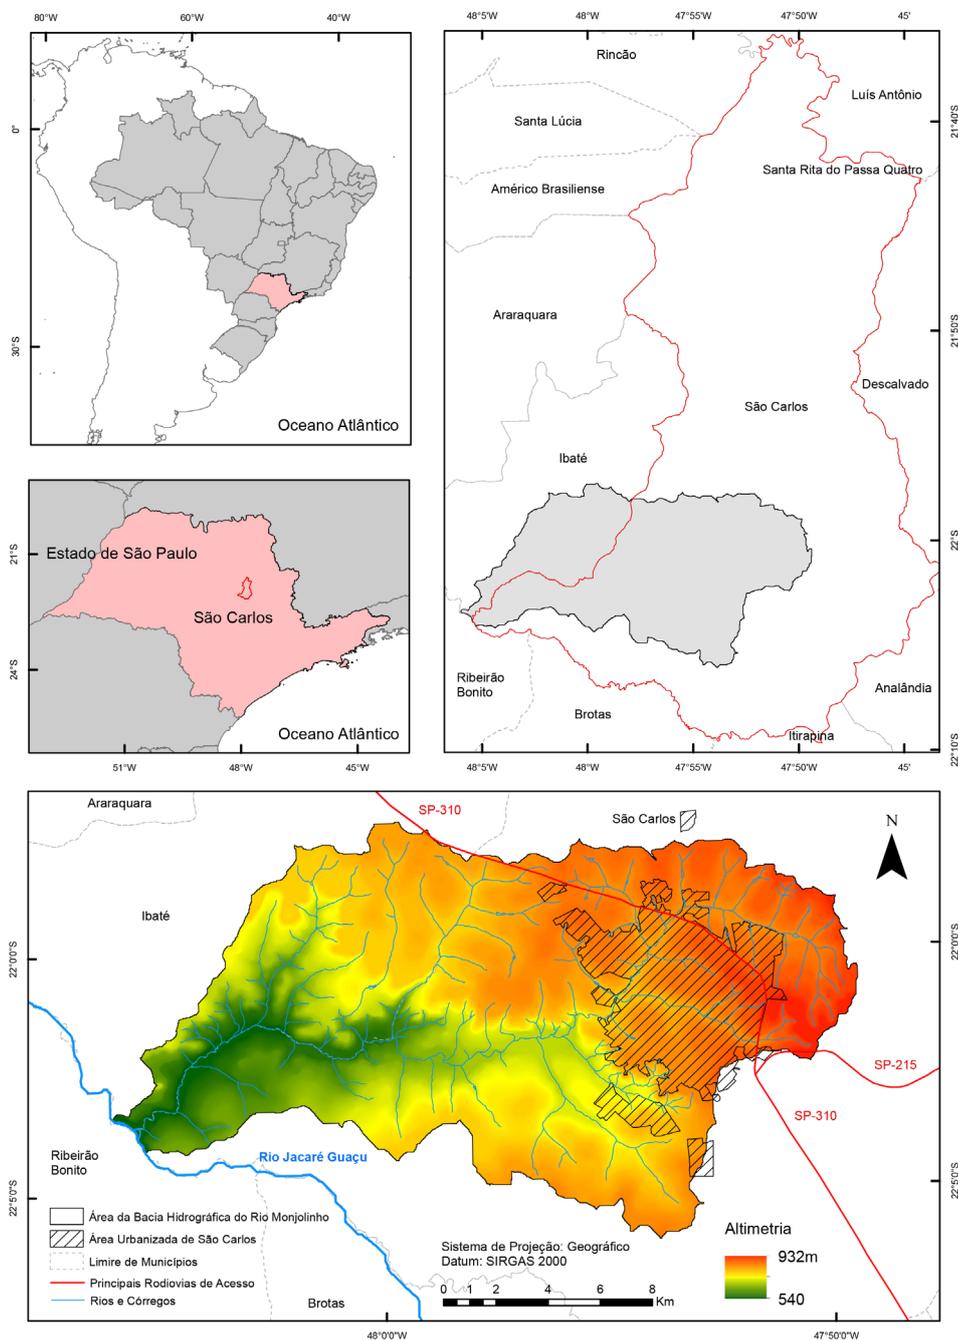
### 3.3 Rede de Drenagem

O Município de São Carlos situa-se na região centro-leste do Estado de São Paulo, inserido em duas Unidade de Gerenciamento de Recursos Hídricos<sup>1</sup> do Rio Mogi Guaçu (UGRHI – 09) e Tietê-Jacaré (UGRHI – 13). O Rio Monjolinho é afluente do Rio Jacaré Guaçu, que deságua no Rio Tietê, que tem um curso de 1.100 quilômetros e atravessa o estado de São Paulo de leste para oeste, desaguardo no Rio Paraná, o segundo maior rio da América do Sul.

1 UGRHI - Unidade Hidrográfica de Gerenciamento de Recursos Hídricos - Agrupamento de Municípios na Bacia Hidrográfica a qual o Município pertence, de acordo com a Lei Estadual 9034/1994.

Com 43,24 quilômetros de extensão, sua nascente está a leste do município de São Carlos, na cota aproximada de 900 metros, na parte rural da cidade, poucos quilômetros após adentrar a área urbana, correndo em direção ao norte passa pelo campus da Universidade Federal de São Carlos (UFSCar), depois segue no sentido sudoeste até sua foz no Córrego do Gregório, passa pelo município vizinho, Ibaté, desaguardo no Rio Jacaré Guaçu numa altitude aproximada de 534m. A sub-bacia do Rio Monjolinho compreende uma área de 273,77km<sup>2</sup> com perímetro de 84,75km. Possui 40 afluentes, sendo 19 pela margem direita e 21 pela margem esquerda (CAMPAGNA *et al.*, 2008).

Figura 17 - Localização Geográfica da bacia hidrográfica do Rio Monjolinho



Elaboração: Autor (2018)

De acordo com a classificação de Strahler (1952), o rio Monjolinho é um curso de 5ª. As bacias hidrográficas possuem uma classificação que nos permite entender suas hierarquias e seu funcionamento, que pode ser feito em escala local em uma microbacia (topografia, tipo de solo, tipo de ocupação) ou podendo, até mesmo, chegar em uma mesobacia (escala continental). O padrão de drenagem é dendrítico, sem nenhuma orientação evidente no canal (CHRISTOFOLETTI, 1980).

### **3.4 Geologia**

A bacia hidrográfica do rio Monjolinho está inserida no contexto geológico continental, na Bacia Sedimentar do Paraná, na província do planalto ocidental paulista. A Bacia Sedimentar do Paraná abrange parte dos Estados brasileiros: São Paulo, Mato Grosso, Mato Grosso do Sul, Minas Gerais e Goiás. Os grupos que compõem essas litologias são: Grupo Bauru, representado por duas formações, Formação Itaqueri (arenitos com cimento argiloso, arenitos grosseiros conglomeráticos, com lentes gadas de folhelhos) e Formação Adamantina (arenitos finos a muito finos, podendo apresentar cimentação e nódulos carbonáticos com lentes de siltitos arenosos e argilitos); Grupo São Bento, com a Formação Serra Geral (Derrames de basaltos, textura afaníticas, com intercalações de arenitos intertrapeanos), Formação Botucatu (arenitos eólicos de granulação fina a média) e Formação Pirambóia (arenitos finos a médios com grãos arredondados, nível de folhelhos e arenitos argilosos); e o Grupo Passa Dois, representado pela Formação Corumbataí, representado por siltitos, argilitos e folhelhos (MURO, 2000; LIMA, 2016; COSTA, 2017; FAILACHE, 2015 e 2018).

Nas Figuras 18 e 19 são apresentados os perfis geológicos. A seção geológica de Catanduva a São Carlos e o perfil morfológico-estrutural do Ribeirão do Feijão - Córrego do Monjolinho.

#### **3.4.1 Formação Itaqueri**

A Formação Itaqueri está sobreposta às Formações Serra Geral e Botucatu, ocupando as cotas mais elevadas da área de estudo e está posicionada no reverso das cuestas arenítico-basálticas, frequentemente próximo as drenagens. De acordo com a classificação do IPT (1981) a formação é caracterizada por arenitos, siltitos e argilitos de coloração marrom-avermelhada, com grãos angulosos, granulação média conglomerática, matriz variável, por vezes argilosa, mal selecionado e raramente apresenta estratificação cruzada.

#### **3.4.2 Formação Serra Geral**

A origem das rochas basálticas desta formação encontra-se associada a atividades vulcânicas do tipo fissural que ocorreram a partir do período Jurássico Superior. A Bacia Sedimentar do Paraná abrange toda a região centro-sul do Brasil estendendo-se por Argentina, Uruguai e Paraguai, a Formação Serra Geral está relacionada aos derrames e intrusivas que recobrem uma área de 1.200.000km<sup>2</sup>. São caracterizadas por Rochas Extrusivas Básicas, por exemplo, o basalto, com presença de corpos intrusivos de subsuperfície na forma de diques e sills, intercalados localmente por arenitos eólicos. São rochas eruptivas básica compactas, de coloração escura, com granulometria que varia de muito fina a menos fina e com

a presença de minerais ferromagnesianos (CAMPANELLI, 2012).

De acordo com Aguiar (1989) na Formação Serra Geral são apresentados paredões verticais, com coberturas espessas de colúvios no sopé das encostas e, de maneira secundária, morros suavemente abaulados, provenientes do aplainamento dado ao relevo após os derrames basálticos. Na BHRM, a Formação Serra Geral aflora ao longo da porção central da bacia, podendo ocorrer em alguns trechos de domínio da Formação Botucatu, do ponto de vista estratigráfico, de maneira irregular devido à presença de dunas (MACIEL, 2000).

### 3.4.3 Formação Botucatu

A Formação Botucatu é constituída principalmente por arenitos quartzosos de granulação fina a média, de coloração vermelha, rósea ou amarelo-clara, bem selecionados, podendo conter feldspato alterado e cimentado por sílica ou por óxido de ferro, que lhe confere a coloração rosa-avermelhada. Como estrutura característica desses arenitos, ocorre estratificação cruzada tangencial de grande porte (BIGARELLA *et al.*, 1961).

Os arenitos dessa formação podem ser de dois tipos, os muito friáveis, que ocupam as áreas mais planas e algumas vezes apoiam a drenagem, e fazem parte da zona de recarga direta do aquífero Botucatu; e podem ocorrer na forma silicificada, por processo de precipitação da sílica, formando corpos conglomeráticos na base, bem como fácies lacustres localizados nas escarpas, sua espessura em média varia de 50 e 70 metros, e pode alcançar 150 metros (FAILACHE, 2018). A principal formação que constitui o Aquífero Guarani é o Aquífero Botucatu. Devido à alta porosidade, com índices muito baixos de silte e argila, sua composição é favorável ao transporte e armazenamento de água (PARAGUASSU, 1972; COSTA, 2017; FAILACHE, 2018).

### 3.4.4 Formação Pirambóia

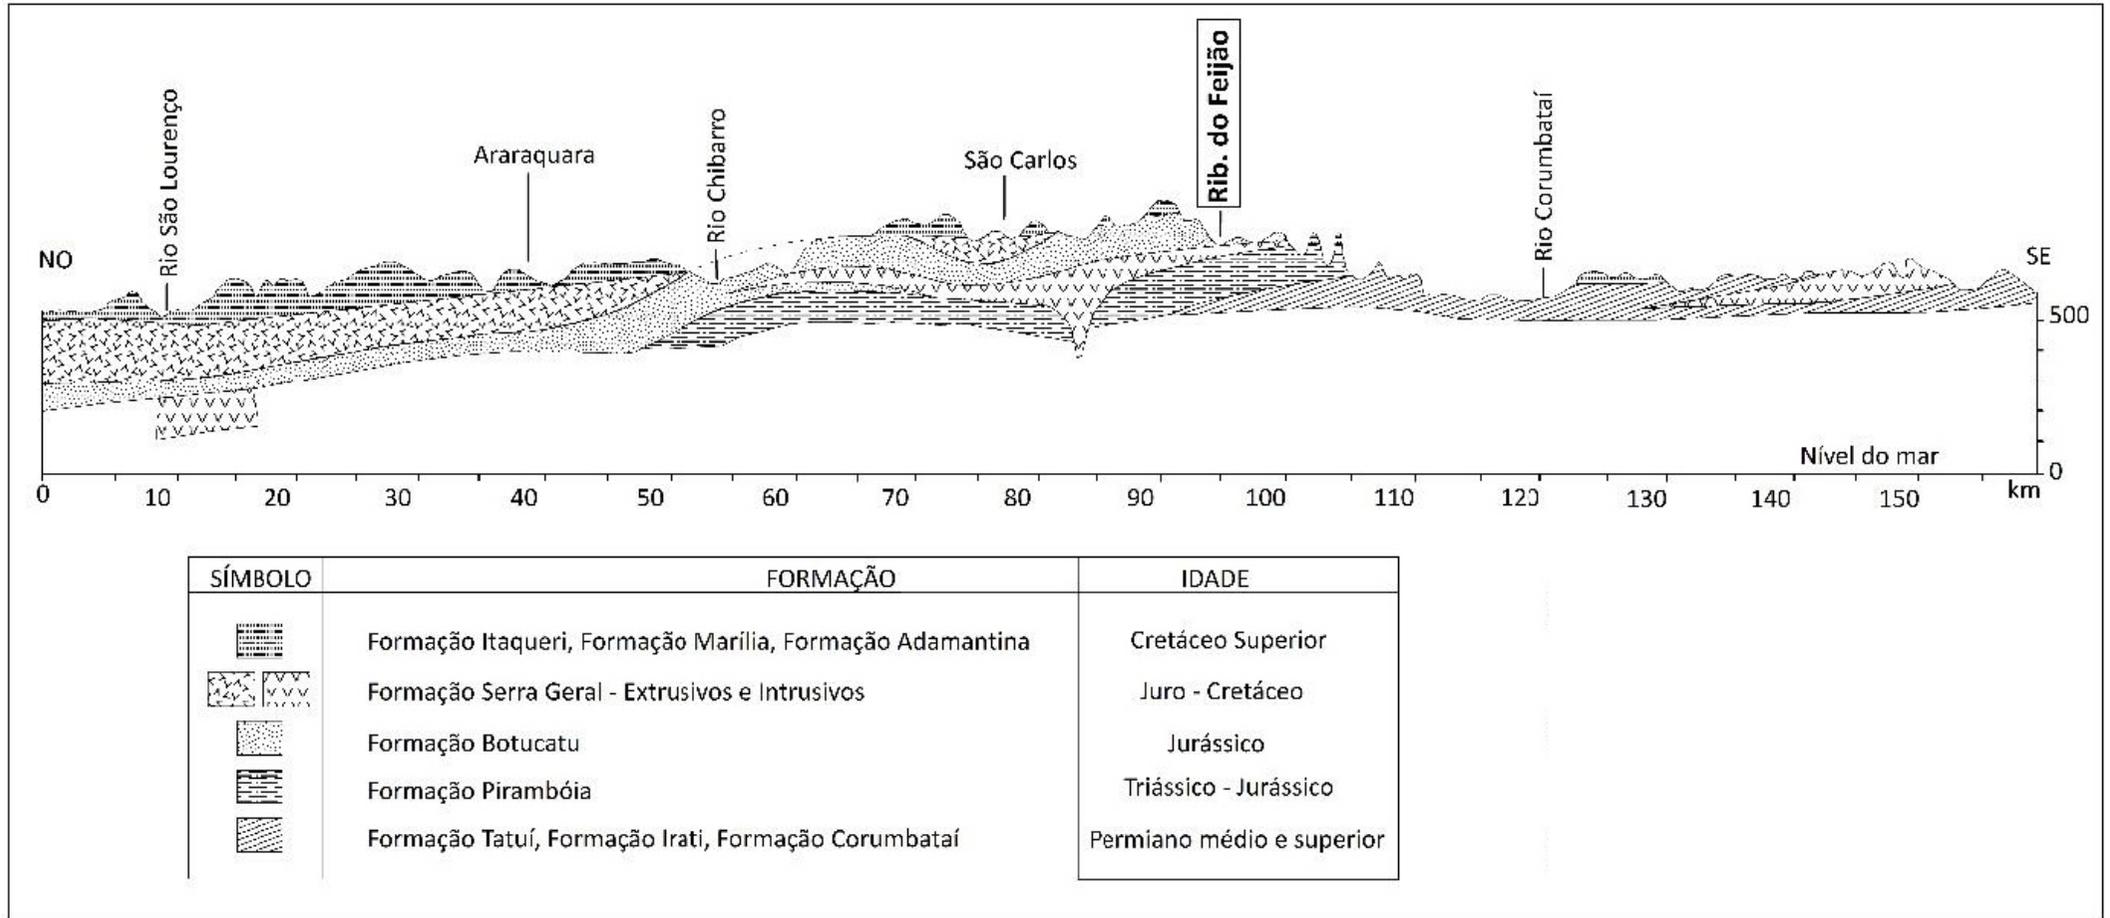
Com menor expressão na área de estudo, a Formação Pirambóia ocorre de forma discreta no lado sudoeste da bacia hidrográfica do Rio Monjolinho, resultante da deposição em ambiente fluvial (SOARES, 1973). Essa formação é representada por arenitos de granulometria fina a média, de coloração amarela e com predominância de finos, frequentemente recoberta por solos arenosos, com grau de intemperismo muito semelhante ao da Formação Botucatu (ZUQUETTE, 1981).

O contato entre as Formações, Botucatu e Pirambóia é de difícil visualização, o qual pode ocorrer de modo gradual ou por contato erosivo (FAILACHE, 2018). De acordo com Zuquette (1981) a faixa intemperizada é pouco espessa, com aproximadamente 1 metro, e vem aumentando. É mais comum em áreas onde o arenito apresenta-se fraturado, portanto, sujeito a maior percolação de água. Observa-se que o grau de faturamento não é tão intenso quanto da Formação Botucatu.

### 3.4.5 Formações Superficiais

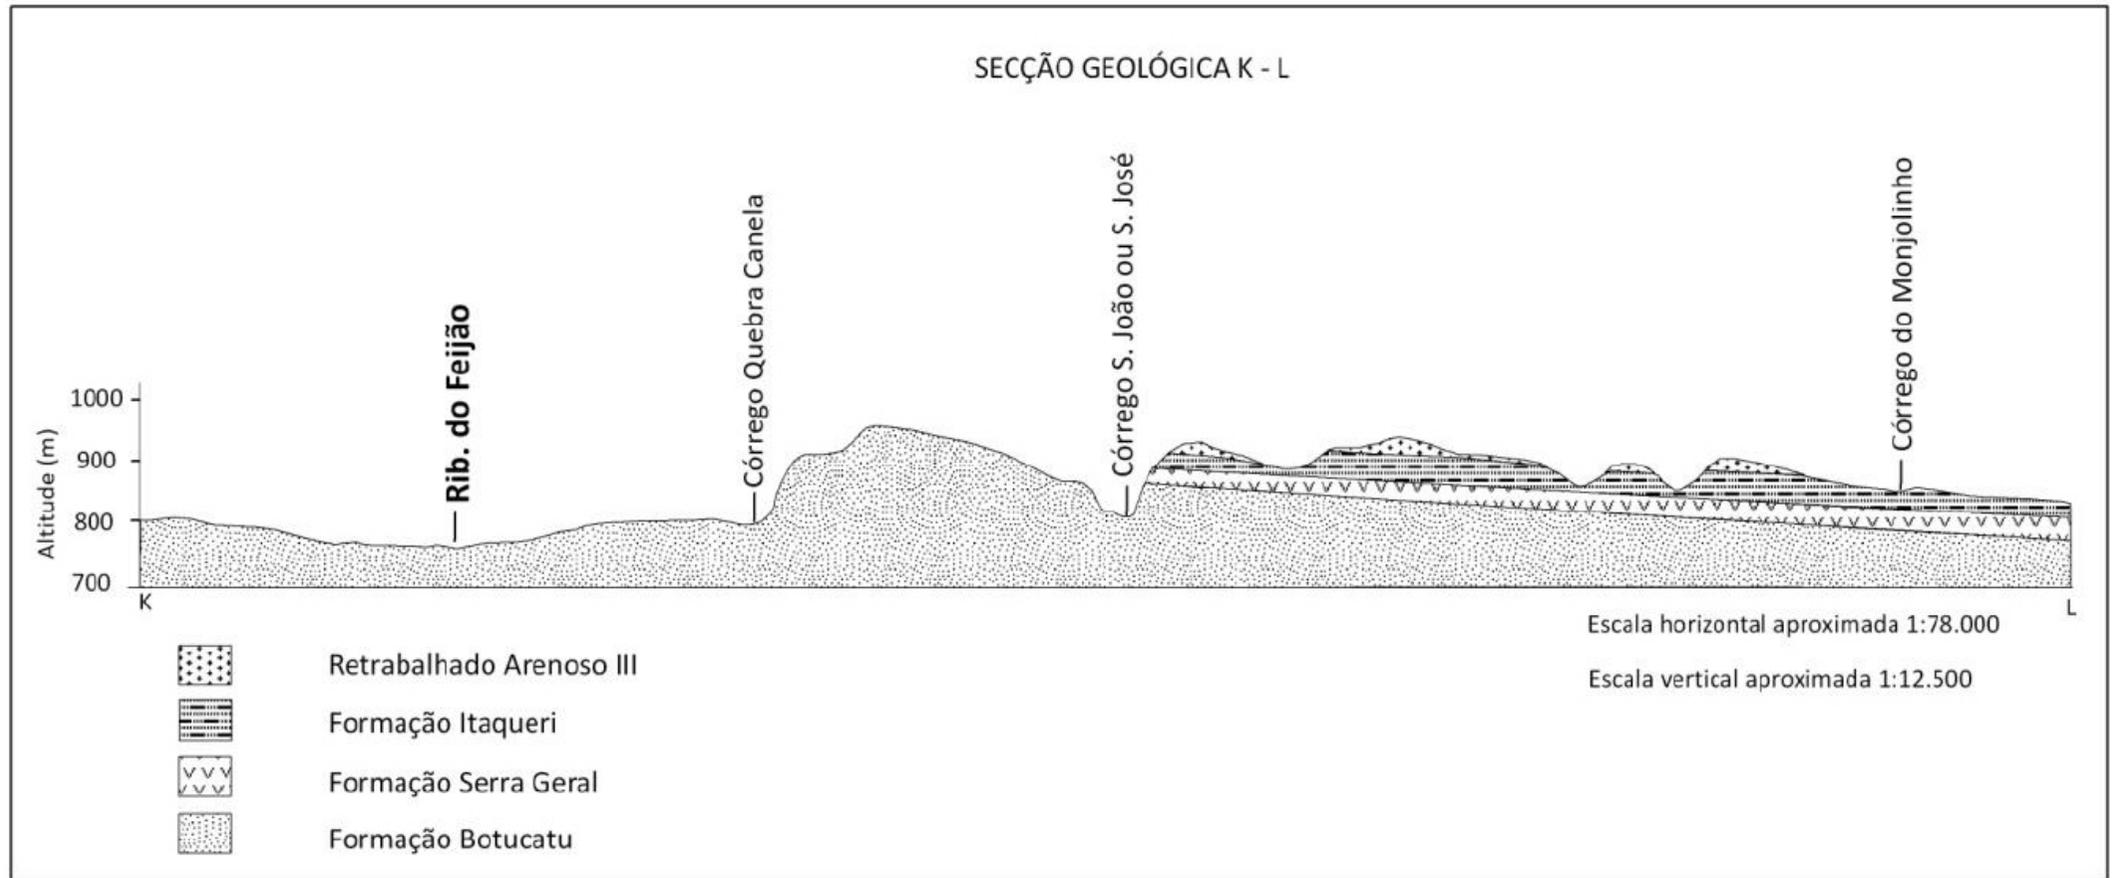
São formações da Era Cenozóica e estão distribuídas na área da bacia sobrepostas às formações mais antigas, estes materiais apresentam textura arenosa, devido as litologias adjacentes, encontrando-se dispostos na forma de depósitos

Figura 18 - Seção Geológica de Catanduva a São Carlos



Fonte: DAEE (1974) apud Costa, 2017

Figura 19 - Perfil morfológico-estrutural Ribeirão do Feijão - Córrego do Monjolinho



Fonte: Nishiyama (1991) *apud* Costa, 2017

aluvionar ou coluvionar (COSTA, 2017). Esses depósitos recentes caracterizam-se por materiais sedimentares e matéria orgânica depositados pela ação hidrográfica ao longo das planícies aluvionares.

Na foz do Rio Monjolinho são identificadas Suítes Básicas (rochas intrusivas magmáticas básicas) que afloram em decorrência dos processos erosivos das rochas sobrejacentes (CAMPANELLI, 2012).

### 3.5 Materiais Inconsolidados

Os materiais inconsolidados foram cartografados por Zuquette (1981), Aguiar (1989), Nishiyama (1991), Muro (2000), Campanelli (2012) e Failache (2108), foram classificados em residuais, quando não sofreram nenhum transporte ou retrabalhamento após a decomposição da rocha matriz, e os materiais retrabalhados que sofreram algum tipo de transporte após a decomposição. A seguir serão descritos os dez tipos de materiais encontrados na bacia hidrográfica do Rio Monjolinho:

- Residual da Formação Itaqueri;
- Residual da Formação Serra Geral;
- Residual Intrusivas Básicas;
- Retrabalhado Arenoso I;
- Retrabalhado Arenoso II;
- Retrabalhado Coluvionar;
- Retrabalhado Botucatu;
- Aluvião.

O material Residual da Formação Itaqueri ocorre em altitudes inferiores a 800 metros, nos vales que correm as drenagens. Este material possui mais de 50% de seus grãos menores que 0,074mm, com espessura superior a 1 metro, coloração avermelhada e alto grau de plasticidade (ZUQUETTE, 1981). De acordo com Muro (2000), essa formação é constituída principalmente por areia fina, com aproximadamente 60%, areia média de 2 a 20%, silte de 5 a 28% e argila de 10 a 63,5%), o coeficiente de permeabilidade (K20) deste tipo de material inconsolidado varia desde  $10^{-5}$  a  $10^{-2}$ cm/s.

Os materiais Residuais da Formação Serra Geral ocorrem em diferentes pontos da área de estudo, podendo ser encontrados nas encostas íngremes, com pouca espessura e apresentam-se em fragmentos da rocha matriz. Quando encontrados em áreas mais planas possuem camadas espessas e sem fragmentos de rocha aparente. São materiais muito colapsíveis, com umidade elevada e com grãos inferiores às 0,074mm (ZUQUETTE, 1981). As proporções referentes às diferentes frações granulométricas que compõem os materiais inconsolidados são: de 10 a 35% para areia fina, silte entre 20 a 45% e argila entre 25 a 60%. O coeficiente de permeabilidade (K20) deste tipo de material inconsolidado varia desde  $10^{-6}$  a  $10^{-3}$ cm/s, diminui de acordo com a profundidade do perfil (MURO, 2000).

Na porção norte da bacia hidrográfica do Rio Monjolinho são encontrados os

materiais inconsolidados Sedimentos Arenosos I. Esses materiais possuem em sua composição granulométrica maior porcentagem de areia fina, com quantidades significativas das frações de silte e argila (CAMPANELLI, 2012). A variação na quantidade de materiais finos é mais acentuada no sentido horizontal do que no vertical. A coloração destes materiais varia de amarelo a vermelho, com espessura entre 50 centímetros e 5 metros. Esses sedimentos recobrem as formações geológicas, Formação Botucatu, Formação Serra Geral e Grupo Bauru, e são encontradas linhas de seixos separando esses materiais (ZUQUETTE, 1981). A permeabilidade é de  $10^{-2}$  a  $10^{-3}$ cm/s (AGUIAR, 1989).

Os materiais inconsolidados do tipo Retrabalhado Arenoso I são predominantemente arenosos e recobrem os materiais residuais da Formação Botucatu, possuem contribuição da Formação Serra Geral e das formações provenientes do Grupo Bauru. Possuem perfil homogêneo e suas drenagens superficiais não são frequentes, com surgimento de voçorocas em alguns locais. Muro (2000) classificou esses materiais como, predominantemente areia fina (60 a 80%), areia média de 5 a 25% e argila aproximadamente 10%, o coeficiente de permeabilidade (K20) destes materiais é de  $10^{-3}$ cm/s.

Na área de estudo, associado aos magmatitos básicos está o material Retrabalhado Arenosos II, que apresenta maior fração de finos com expressiva quantidade de areia advinda dos arenitos da Formação Botucatu. A variação na porcentagem de argila é de 15 a 40%, com coloração avermelhada a amarelada. Na sua composição mineralógica, a fração de areia contém quartzo, magnetita e ilmenita; a fração de argila é composta por caulinita, gibsita e óxidos de ferro (MURO, 2000). O coeficiente de permeabilidade (K20) varia de  $10^{-5}$  a  $10^{-3}$ cm/s (AGUIAR, 1989).

Os materiais Inconsolidados do tipo Retrabalhado Coluvionar são provenientes das encostas de basalto, onde ocorre uma mistura com as areias da Formação Botucatu, que apresenta um perfil espesso, variando de 10 a 20 metros de altura e possui uma coloração avermelhada (CAMPANELLI, 2012). As áreas de ocorrência desse tipo de material são marcadas por instabilidades ocasionadas por uma série de fatores, por exemplo, as atividades antrópicas. Sua textura é bastante variada, com pontos onde predominam as argilas e em outros areia fina argilosa (MURO, 2000). O coeficiente de permeabilidade (K20) é aproximadamente  $10^{-3}$ cm/s (AGUIAR, 1989).

As formações Aluvionares ocorrem nas cotas mais baixa da bacia hidrográfica, no fundo dos vales e na proximidade das drenagens. São depósitos fluviais que possuem grandes quantidades de matéria orgânica e coloração escura, materiais sedimentares de textura fina e argila. Para Aguiar (1989) estes materiais caracterizam-se por apresentarem coeficiente de permeabilidade (K20) superior a  $10^{-3}$ cm/s.

Os materiais inconsolidados do tipo Retrabalhado Botucatu são originados a partir dos materiais arenosos da Formação Botucatu que, de alguma forma, foram transportados. Foram retrabalhados por abrasão seletiva em clima semiárido e árido de ambiente desértico (CAMPANELLI, 2012).

As Rochas Sedimentares que afloram na bacia hidrográfica do Rio Monjolinho podem ser visualizadas expostas rente à superfície.

### 3.6 Águas Subterrâneas

É considerada água subterrânea toda água que preenche os poros vazios das rochas, fratura, falhas ou fissuras. Estas cumprem uma fase do ciclo hidrológico, uma vez que constituem uma parcela da água precipitada. Após a precipitação, parte da água que atinge o solo se infiltra e percola no seu interior, pela zona não saturada até atingir a zona saturada.

As águas subterrâneas desempenham um papel fundamental no desenvolvimento humano, na área de estudo desempenha um papel estratégico de abastecimento público e privado, atendendo as necessidades da população.

No estado de São Paulo, a água subterrânea distribui-se em diferentes unidades aquíferas de acordo com os diferentes tipos de matérias geológicas, o que determinará a forma de circulação da água, na sua capacidade de transporte e armazenamento, refletindo na sua produtividade (COSTA *et al.*, 2018).

A região de São Carlos está assentada sobre mananciais rasos e profundos da Formações Serra Geral, Itaqueri e Botucatu/Pirambóia, com maior importância ambiental (FAILACHE, 2018).

De acordo com a classificação do IPT (1981), a Formação Botucatu, sobrejacente, é formada por arenitos de granulação fina a média, uniforme, com boa seleção de grãos foscas com alta esfericidade. São avermelhados e exibem estratificação cruzada tangencial de médio a grande porte, característica de dunas caminhanças. Localmente, sobretudo nas partes mais baixas do pacote, intercalam-se arenitos de deposição subaquosa. Constituem corpos lenticulares de arenitos heterogêneos, de granulação média a grossa, passando a arenitos conglomeráticos, cujos seixos são em maioria de quartzo e quartzito.

A Formação Pirambóia é constituída por arenitos geralmente de granulação fina à média, possuindo fração argilosa maior na parte inferior que na superior da formação, onde localmente ocorrem arenitos grossos, conglomeráticos. Predomina a estratificação plano-paralela destacada pela alternância de lâminas mais ou menos ricas em argila e silte, ou ainda mostra estratificação cruzada de dimensões média a grande do tipo tangencial. Não são raras as marcas de onda ou corrente (IPT, 1981).

### 3.7 Geomorfologia

A área de estudo faz parte da província geomorfológica das Cuestas Basálticas, representando a borda dos derrames basálticos, onde predominam relevos de degradação, em planos dissecados (ALMEIDA, 1964). Está posicionada entre as províncias do Planalto Ocidental e a Depressão Periférica, situadas num dos planaltos do reverso da cuesta interna (ZUQUETTE, 1981). A altitude varia de 600 metros até mais de 1000 metros, com declividade plana variando em média de 2 a 20%.

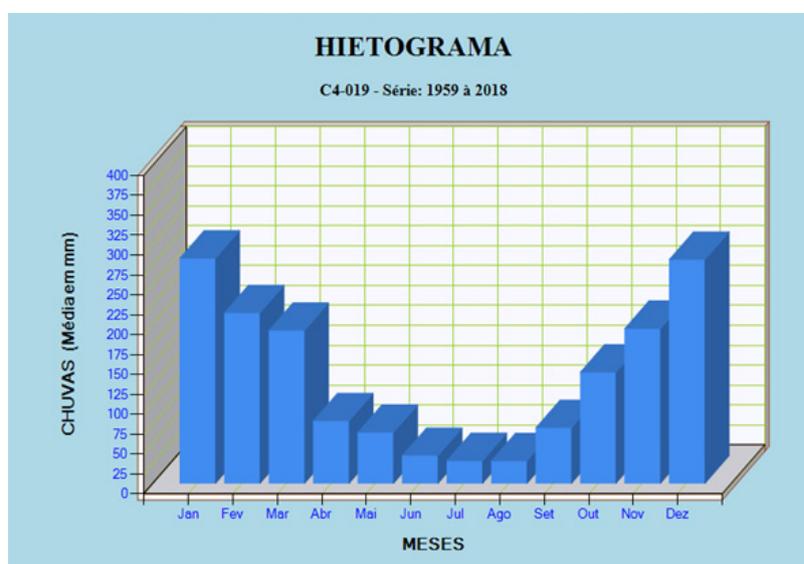
### 3.8 Clima

Segundo o sistema de classificação do clima de Köppen (1948), o município estudado é do tipo Cwa, isto é, clima mesotérmico úmido subtropical de inverno seco, com temperaturas médias do mês mais frio inferior a 18°C e a do mês mais

quente ultrapassam os 22°C. Para Mendonça e Danni-Oliveira (2007), o macro tipo climático da região tem apresentado tais características: heterogeneidade térmica, com médias anuais que vão de 20°C ao sul do município e 26°C mais ao norte do município. No período mais seco do ano, de junho a agosto, o município passa por um déficit hídrico, diferente do período chuvoso de setembro a maio.

Os sistemas atmosféricos oceânicos tropicais e polares têm grande influência no clima da região, justificando alta pluviosidade e as variações térmicas ao longo do ano (COSTA *et al*, 2015). A precipitação pluviométrica (Figura 20) média anual, de 1959 a 2018, é de 1512mm, com precipitação média mensal de 109,9mm, umidade relativa de 66% (DAEE, 2018).

Figura 20 - Média mensal para os anos 1959 a 2018 (DAEE, 2018)



Fonte: (DAEE, 2018)

### 3.9 Vegetação

Segundo Silva *et al.* (2000), os tipos de vegetação que ocorrem na BHRM são: (a) Floresta Estacional Semidecidual Submontana (mata), localizada nas escarpas da bacia hidrográfica, condicionada pelas estações climáticas com intensas chuvas de verão seguida por estiagens acentuadas e outra subtropical sem período seco, com seca fisiológica provocada pelo frio de inverno, com temperaturas inferiores a 15°C; (b) Floresta Estacional Semidecidual Aluvial (mata ciliar), são as matas de galeria ou mata ciliar que ocorrem ao longo dos cursos d'água; (c) Capoeiras, correspondem a vegetação secundária, gramíneas e arbustos esparsos; (d) Savana Florestada (Cerradão), faz parte do subgrupo de formação fisionomia típica e característica, restrita a áreas areníticas lixiviada com solos profundos e; (e) Savana Arborizada (Cerrado).

A vegetação original predominante é o Cerrado, associada aos terrenos arenosos, com baixa fertilidade, caracterizada por plantas de pequeno porte, desuniformes e associadas principalmente às gramíneas; nas encostas com solos da Formação Serra Geral, estão associadas a vegetação de médio porte e arbustos (ZUQUETTE, 1981). Atualmente, boa parte da vegetação original deu espaço a cultivos, pastagem, reflorestamentos e a urbanização.

## Materiais e métodos

Para desenvolver a proposta do trabalho, a elaboração de Cartas de Susceptibilidade a Erosão utilizando técnicas de análise multicritério (AHP e ANFIS), teve como ponto inicial a leitura de trabalhos anteriores, que abordam o tema, esses trabalhos foram selecionados por meio de fontes analógicas (biblioteca, acervo do laboratório de pesquisa e particular) e bases de dados bibliográficos (Periódicos Capes, *Google Acadêmico*, *Scopus* e *Web of Science*).

Os métodos adotados envolvem cinco etapas diferentes, apresentadas no fluxograma, Figura 21, e detalhadas a seguir. A primeira etapa foi a revisão de trabalhos que contemplam o tema da pesquisa, conceitos sobre mapeamento de processos erosivos, análise multicritério, técnica AHP (*Analytic Hierarchy Process*), Lógica Fuzzy, Sistema de Inferência *Fuzzy* (FIS), Sistema de Inferência Neuro-*Fuzzy* Adaptativo (ANFIS) e Redes Neurais Artificiais (RNA's).

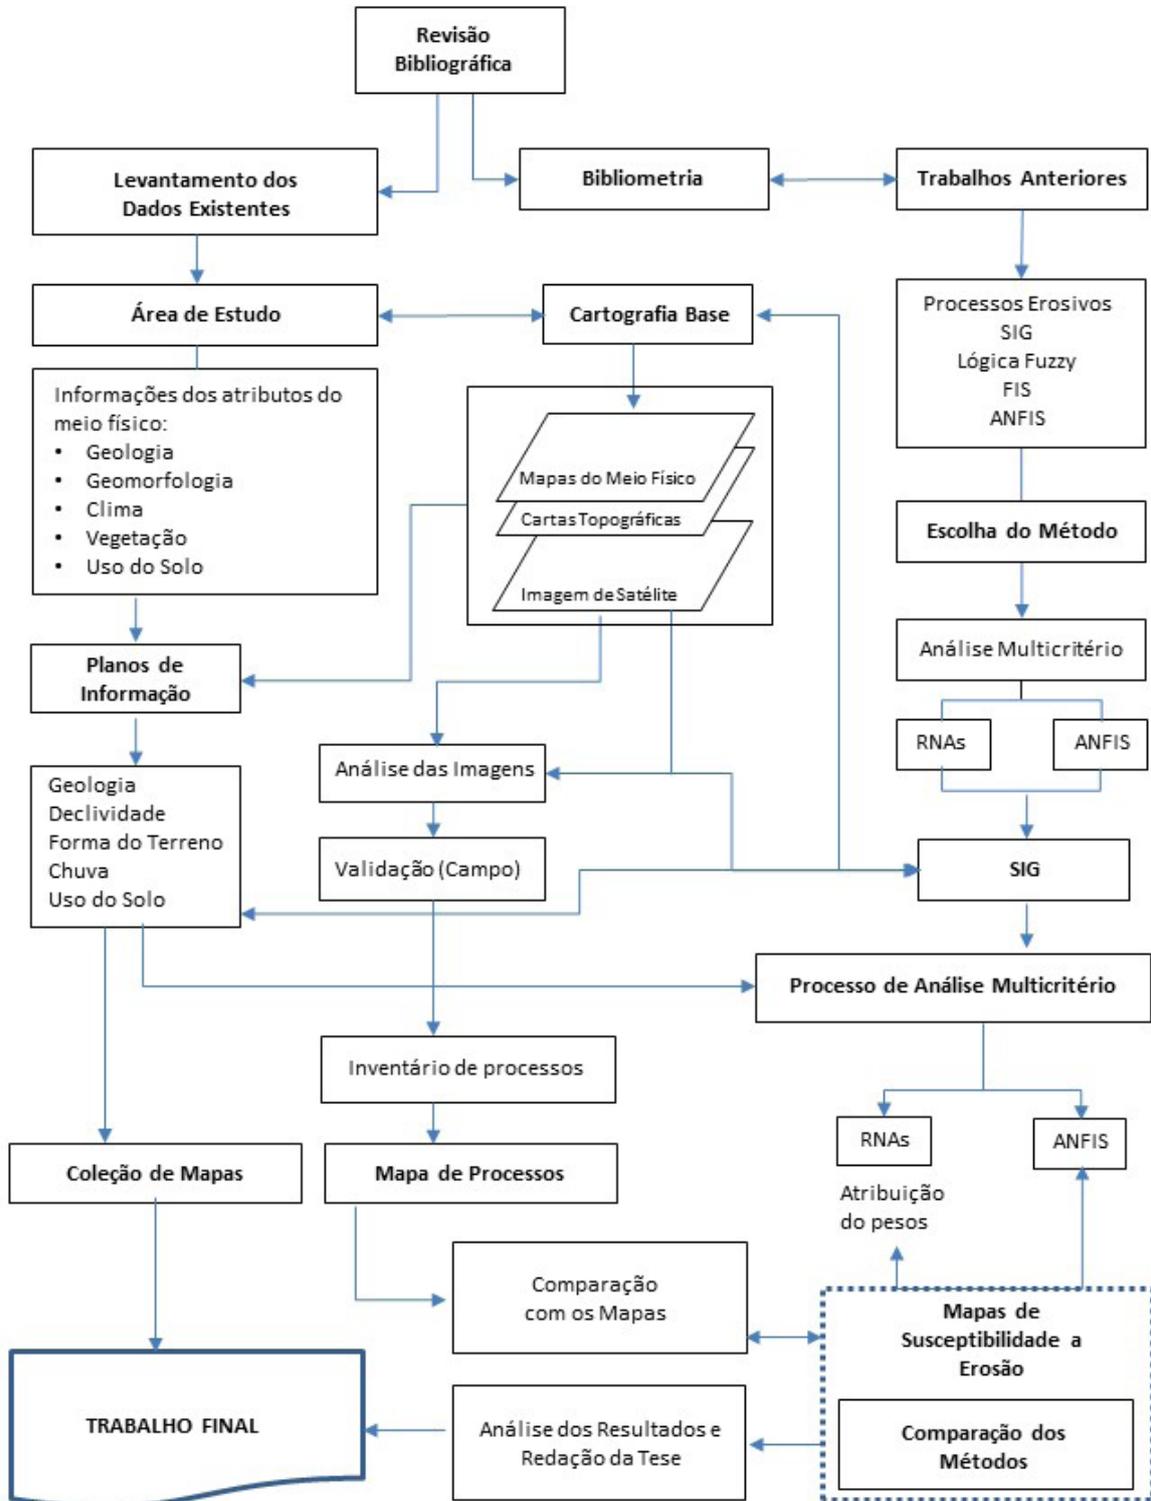
A segunda etapa buscou-se reunir trabalhos pretéritos na área, para elaboração do banco de dados. Os dados cartográficos foram tratados e padronizados, em ambiente SIG, foram utilizadas informações como curvas de nível, pontos contados, hipsometria, declividade, Modelo Digital do Terreno (MDT), Formas do Terreno, informações sobre a Geologia, Materiais Inconsolidados, Chuva e Cobertura e Uso do Solo.

Para desenvolver a etapa três a identificação dos processos erosivos, será utilizado imagem de satélite. Junto com a identificação dos processos, a elaboração de um inventário de campo, com intuito de amparar o mapeamento feito por interpretação da imagem de satélite e posteriormente a validação dos dados.

A etapa seguinte foi definir quais os atributos que possuem fatores determinantes para que os processos erosivos aconteçam na bacia hidrográfica do Rio Monjolinho. Todos os fatores foram adicionados a um banco de dados em ambiente SIG, sendo eles, geologia, textura do solo, inclinação do terreno, formas do terreno, cobertura e uso do solo e influência das chuvas.

Na etapa cinco os dados serão processados em ambiente SIG, onde serão atribuídos os pesos por atributos e gerado o mapa susceptibilidade a erosão utilizando a técnica AHP, em seguida será aplicada o método ANFIS para um possível melhoramento da consistência desses dados. Após a elaboração dos mapas, pelas diferentes metodologias, serão analisados os resultados e comparados, por meio de técnicas visuais e estatísticas.

Figura 21 - Fluxograma das etapas do trabalho



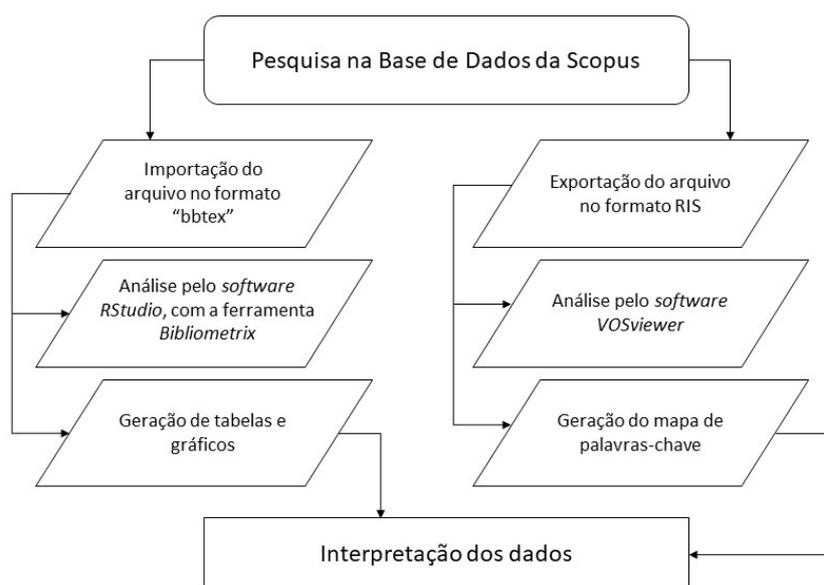
Elaboração: Autor (2018)

#### 4.1 Análise Bibliométrica

Para realizar análise bibliométrica proposta no trabalho, com a intenção de elaborar uma revisão bibliográfica mais atual e com os trabalhos mais citados pelo mundo, foi utilizado como ferramenta a base de dados *Scopus*. De acordo com Oliveira e Menezes (2018) a *Scopus* é uma das maiores bases de dados de resumos e citações de literatura científica revisada por pares, oferecendo ferramentas para rastrear, analisar e visualizar pesquisas em diversas áreas do conhecimento.

Para realizar a pesquisa, foram utilizados os seguintes termos em inglês: "AN-FIS" OR "Adaptative Network based Fuzzy Inference Systems" AND "Landslide susceptibility" OR "Remote sensing" OR "Erosion", com intuito de delimitar o tema. A busca das publicações é por meio de título, resumo, palavras-chave do autor e palavras-chave designadas pela base de dados (Romanelli *et al.*, 2018). O tema compreendeu o período de 2004 a 2019. Foram recuperados 99 dados de publicações científicas. Na Figura 22, é apresentada a síntese da metodologia utilizada.

Figura 22 - Síntese da metodologia utilizada



Fonte: adaptado de Oliveira e Menezes (2018)

Para a análise bibliométrico seguiu-se a metodologia utilizada por Oliveira e Menezes (2018); Romanelli *et al.* (2018) e Souza *et al.* (2019), de acordo os autores o trabalho pode ser dividido em e etapas:

- pesquisa de documentos disponíveis no banco de dados;
- análise bibliométrica dos documentos encontrados e;
- seleção e análise de documentos com base nos objetivos do estudo.

Após a realização da fase de coleta de dados, utilizou-se os softwares livres, RS-

studio e VOSviewer. No programa RStudio, utilizou-se o pacote *Bibliometrix* (2016), que fornece várias rotinas para importar dados bibliográficos dos bancos de dados do *Web of Science*, *Scopus* e do *Clarivate Analytics*, realizando análises bibliométricas e construindo matrizes de dados.

Todas as análises, cálculos e gráficos foram realizadas utilizando a ferramenta “*Analyzing Results*” fornecida da *Scopus*. Mapas de colaboração baseados em co-autoria e análise de co-ocorrência foram desenvolvidos utilizando o software *VOSviewer*, para entender a colaboração entre os países, instituições de pesquisa e autores.

#### 4.2 Levantamento e Avaliação dos Dados Pré-existentes

Após conhecer todos os fatores determinante para que ocorra os processos erosivos, delimitou-se os produtos necessários, para levantamento e avaliação do material, eles estão relacionados com atributos do meio físico. Os dados levantados foram:

1. Mapa Topográfico na escala 1:50.000 do IBGE;
2. Mapa Hipsométrico do banco de dados do *Aster GDEM*;
3. Mapa de Declividade do banco de dados *Aster GDEM*;
4. Mapa Formas do Terreno do banco de dados do *SRTM*;
5. Mapa de Substrato Geológico, escala 1:75.000 da UBCs;
6. Mapa de Material Inconsolidado, Failache (2018);
7. Imagens dos Satélites *Sentinel-2* (2018) e *LandSat 8* (2018).

A avaliação dos dados foi em relação a escala e qualidade de representação dos materiais e confiabilidade dos dados apresentados. Os diferentes métodos de obtenção e construção dos produtos são descritos nos itens a seguir.

#### 4.3 Processamento dos Dados

Nesta fase os dados pré-existentes foram preparados e processados para a elaboração de todos os mapas utilizados durante a pesquisa. Os dados foram inseridos em ambiente SIG, para organização, tabulação, georreferenciados, vetorização de documentos cartográficos e processamento das imagens de satélite, com o auxílio dos softwares *ArcGIS*® 10.5 e *SNAP (Sentinel Application Platform)* 7.0.0 da Agência Espacial Europeia (ESA). A tabulação de dados de chuva e geotécnicos (materiais inconsolidados) foi utilizado o software *Microsoft Excel*® 2016, e para a construção da rede neural o software *Matlab*® 2019a.

O procedimento adotado para a elaboração do banco de dados (georreferenciamento, inserção de imagens e vetorização) estão descritos a seguir:

1. Foram adicionados ao banco de dados documentos cartográficos e imagens no formato matricial;

2. Padronização do sistema de coordenadas e sistema de referência (coordenadas geográficas, SIRGAS2000);
3. Processamento dos dados obtidos por diferentes sensores;
4. Vetorização dos elementos das cartas do IBGE, para a elaboração dos mapas, cadastral, substrato geológico e material inconsolidado;
5. Organização do BD no *software ArcGIS*®10.5.

#### 4.4 Elaboração de Documentos Cartográficos

Para a construção de um mapa de susceptibilidade a erosão são necessários diferentes atributos, que interferem diretamente nos processos erosivos, uns com mais, outros com menos influência, mas o conjunto de fatores é o que vai determinar o grau da susceptibilidade. Foram elaborados documentos cadastrais e intermediários aos cruzamentos. O processo de elaboração de cada um dos documentos está descrito a seguir nos itens 4.4.1 a 4.4.10.

##### 4.4.1 Mapa de Documentação

O mapa de documentação foi elaborado a partir da articulação de quatro cartas topográficas do Instituto Brasileiro de Geografia e estatística (IBGE), são as folha de Araraquara (SF-22-X-D-VI-4); folha de São Carlos (SF-23-Y-A-I-1); folha de Ibaté (SF-23-V-C-IV-3); folha de Ribeirão Bonito (SF-22-Z-B-III-2); na escala 1:50.000.

A cartas de São Carlos e Ibaté foram georreferenciadas dentro do *ArcGIS*® 10.5, utilizando o sistema de projeção UTM 23S, Datum Córrego Alegre, as cartas de Araraquara e Ribeirão Bonito utilizaram o sistema projeção UTM 22S, Datum Córrego Alegre. Após a junção das Cartas o sistema de projeção foi alterado para geográfico, devido a diferença de fusos.

O passo seguinte foi extrair as informações, no formato vetorial. As informações extraídas foram, curvas de nível (20m), pontos cotados de altitude, a rede de drenagem, contendo os principais cursos d'água, lagos e represas. Esses dados serviram para delimitar a bacia hidrográfica do Rio Monjolinho, assim como, definir a ordem (Strahler, 1952) e o padrão de drenagem (CHRISTOFOLETTI, 1980).

##### 4.4.2 Dados Topodata INPE

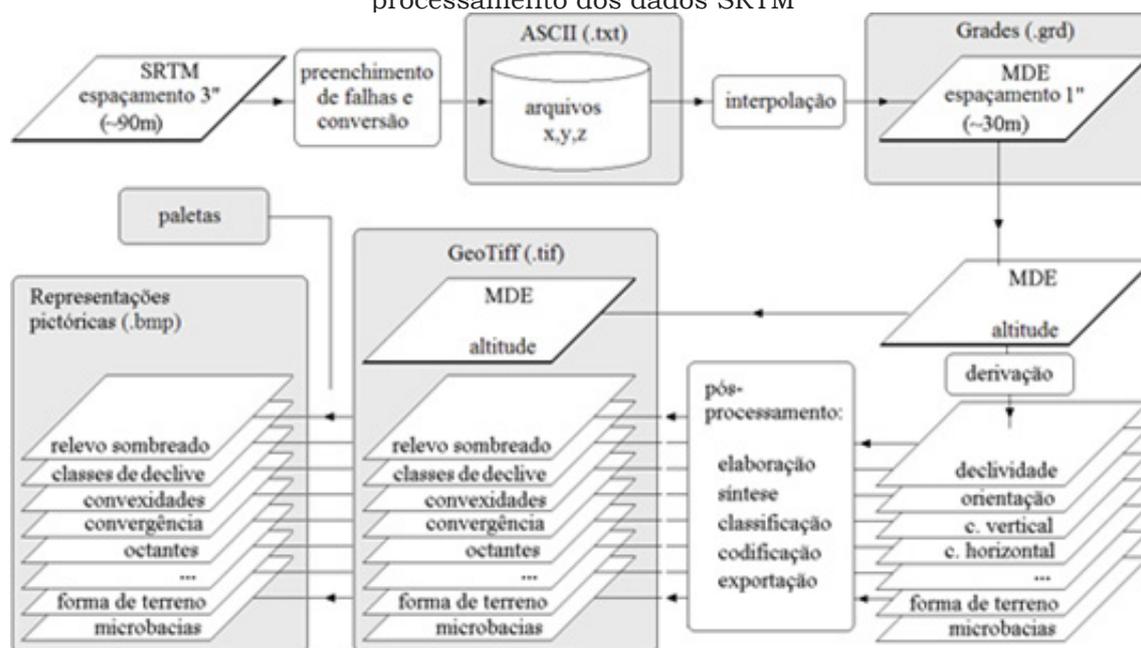
Algumas informações relacionadas a estrutura da terra foram retiradas do projeto Topodata (Banco de Dados Geomorfométricos do Brasil) do Instituto Nacional de Pesquisas Espaciais (INPE). O projeto oferece o Modelo Digital de Elevação (MDE) e suas derivações locais básicas em cobertura nacional, ora elaborados a partir dos dados SRTM disponibilizados pelo USGS na rede mundial de computadores. As etapas de processamento e disponibilização dos dados SRTM (preenchimento de falhas, refinamento, derivação e pós-processamento), foram de acordo com o fluxograma abaixo (Figura 23):

As etapas de produção dos dados estão descritas de acordo com INPE (2018):

*“Após o preenchimento de falhas dos dados originais SRTM, estes*

foram convertidos em arquivos ASCII (.txt) estruturados em colunas x,y,z, que constituem um primeiro conjunto de dados, ainda com espaçamento (resolução) de 3 arco-segundos. Deste arquivo foram interpoladas as grades de altitude, em um Modelo Digital de Elevação (MDE) refinado então para 1 arco-segundo, sob formato de Surfer grid (.grd). Um terceiro conjunto de arquivos, disponibilizado em formato GeoTiff (.tif), contém este MDE refinado e suas derivações (variáveis) geomorfológicas locais, algumas das quais classificadas em intervalos ou combinações de interesse. Estes mesmos planos de informação foram preparados sob representações pictóricas não georreferenciadas, num quarto conjunto de arquivos (.bmp), para rápida visualização em editores comuns. Além dos arquivos de dados associados a cada folha (ou quadrícula), paletas correspondentes aos esquemas de cores usados nestas representações foram também disponibilizadas para facilitar sua visualização em diferentes programas de SIG.”

Figura 23 - Arquivos do TOPODATA produzidos ao longo do processamento dos dados SRTM

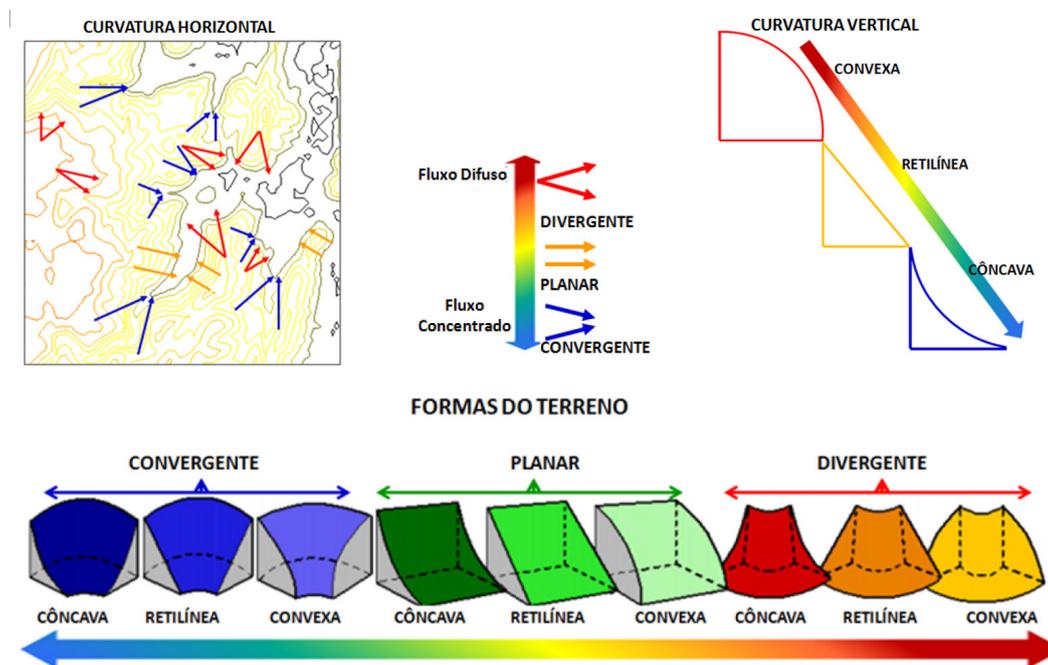


Fonte: <http://www.dsr.inpe.br/topodata/dados.php> (2018)

#### 4.4.3 Mapa Formas do Terreno

O Mapa de Formas do Terreno foi resultado do processamento dos dados do SRTM-TOPODATA, em ambiente SIG, os dados de curvatura vertical e curvatura horizontal, foram convertidos em um modelo temático. As formas do terreno resultam da combinação entre as curvaturas vertical e horizontal. Como produto final da associação da curvatura vertical (côncavo, retilíneo e convexo) e curvatura horizontal (convergente, planar e divergente), estabelecendo-se nove classes (Figura 24) distintas para as formas do terreno (VALERIANO, 2008).

Figura 24 - Variáveis geomorfológicas, derivadas da altimetria



Fonte: Adaptado de Valeriano (2008)

#### 4.44.4 Modelo Digital de Elevação e Carta de Declividade

A carta de declividade foi elaborada a partir das imagens *ASTER* GDEM, obtidas no site do Serviço Geológico Americano (*United States Geological Survey* - USGS), são produtos elaborados pela NASA e o Ministério da Economia, Comércio e Indústria do Japão (METI) para construção de uma modelo digital de elevação global de livre acesso.

Para obtenção dos dados de elevação da superfície o sensor opera no modo estereoscópico com as bandas 3N (*nadir*) e 3B (*backward*) correspondentes a faixa do infravermelho próximo (0,78 – 0,86  $\mu\text{m}$ ). Com resolução espacial de 30 metros recobre todo globo terrestre (YAMAGUCHI *et al.*, 1999). A carta de declividade gerada para a área de estudo foi gerada com cinco classes (%), 0-2, 2-5, 5-12, 12-20, >20.

#### 4.4.5 Mapa Hipsométrico

O Mapa Hipsométrico ou de altitude, é mais um produto derivado do modelo de digital do terreno. Para esse trabalho foram definidas 5 classes, que variam em aproximadamente 70 metros de altitude. A representação da elevação do terreno foi por meio de um sistema de graduação de cores de modo contínuo, para aproximar-se do real.

#### 4.4.6 Mapa de Substrato Geológico

O mapa de substrato geológico utilizado é parte da base de dados das Unidades

Básicas de Compartimentação do Meio Físico, do Estado de São Paulo (2014). Elaborado pela FUNCATE – Fundação de Ciência, Aplicações E Tecnologia Espaciais, contratada pela Coordenadoria de Planejamento Ambiental da Secretaria de Meio Ambiente do Estado de São Paulo (CPLA/SMA) para a realização dos trabalhos. A delimitação de Unidades Básicas de Compartimentação do Meio Físico (UBC) é um dos produtos do projeto intitulado “Delimitação de sub-bacias, estruturação de base de dados do meio físico e delimitação de unidades homogêneas do uso e ocupação do solo urbano”, que conta com financiamento do Fundo Estadual de Recursos Hídricos (FEHIDRO), sob o código 2010- CORHI-112, executado por essa Coordenadoria em parceria com o Instituto Geológico (IG).

#### 4.4.7 Mapa de Materiais Inconsolidados

Para elaborar o Mapa de Materiais Inconsolidados da bacia hidrográfica do Rio Monjolinho foram utilizados os seguintes mapeamentos geológicos-geotécnicos:

1. Mapa de Materiais Inconsolidados para o Município de São Carlos, Muro (2000);
2. Carta dos Materiais de Cobertura elaborada por Zuquette (1981);
3. Mapeamento Geológico-geotécnico da Folha de Ribeirão Bonito (Zuquette, S/D);
4. Mapa de Materiais Inconsolidados para a bacia hidrográfica do Rio Monjolinho, Campanelli (2012);
5. Mapas de Materiais Inconsolidados das folhas topográficas de Araraquara e São Carlos, Failache (2018).

A elaboração deste mapa seguiu os mesmos procedimentos adotados, georreferenciamento dos documentos analógicos, transformando em arquivo de formato raster, em seguida a delimitação dos polígonos atribuindo suas características geotécnicas.

#### 4.4.8 Mapa Pluviométrico

Para elaborar o mapa de precipitação, para o ano de 2018, foram utilizados dados de dez estações pluviométricas distribuídas pelo município de São Carlos, que contemplam toda a extensão da bacia hidrográfica do Rio Monjolinho, os dados de localização estão na Tabela 1.

A primeira parte do procedimento é o tratamento dos dados, após o *download* das informações foi necessário separar o período que seria utilizado, no caso o ano de 2018, em seguida as células que não possuíam valores de coleta foram preenchidas por meio de métodos estatísticos, mas para esse trabalho foi utilizado o método de Ponderação Regional. Nesse método são selecionados 3 pontos ou mais que possuam no mínimo 10 anos de dados e que se localizem em uma região climática semelhante ao ponto a ser preenchido. A equação (4.1) utilizada foi:

$$y = \frac{1}{3} \left( \frac{x_1}{xm1} + \frac{x_2}{xm2} + \frac{x_3}{xm3} \right) ym \quad (4.1)$$

Onde  $y$  = precipitação do posto a ser estimada;  $x_1$ ,  $x_2$ ,  $x_3$  = precipitações correspondentes ao ano que se deseja preencher, observadas em 3 estações vizinhas;  $y_m$  = a precipitação média do posto  $y$ ; e  $x_{m1}$ ,  $x_{m2}$ ,  $x_{m3}$  = precipitações médias das 3 estações circunvizinhas.

Em seguida a média anual dos 10 pontos foram calculadas e adicionadas em uma tabela com as suas respectivas coordenadas geográficas.

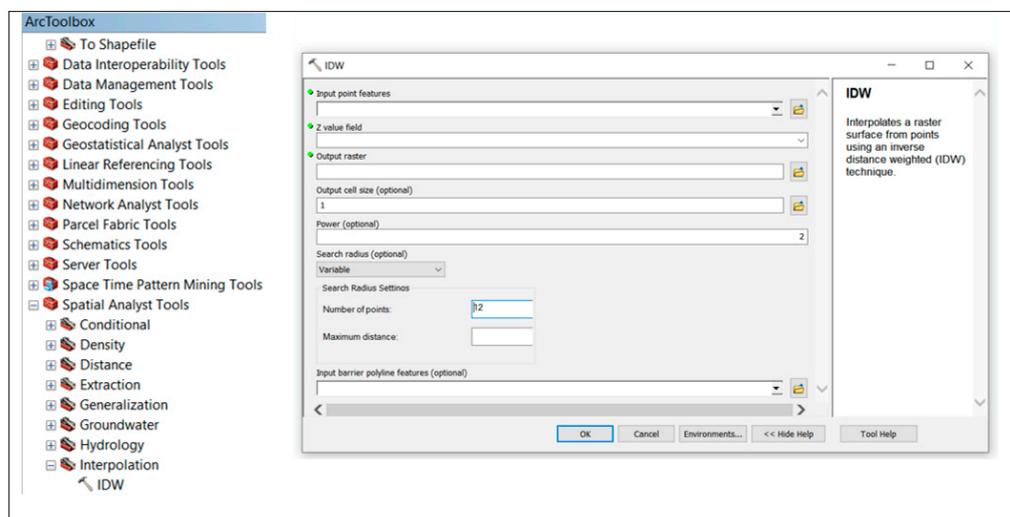
Tabela 1 - Locais de extração dos dados pluviométricos

<b>Dados de Localização dos Pluviógrafos da BHRM (2018)</b>		
<b>Fonte</b>	<b>Longitude</b>	<b>Latitude</b>
USP	-47,9277	-21,9984
USP	-47,9351	-22,0045
INMET	-47,8833	-22,0167
ANA	-47,8864	-22,1522
DAEE	-47,7683	-21,7481
DAEE	-47,7858	-21,8856
DAEE	-47,8164	-21,6967
DAEE	-47,8758	-21,9867
DAEE	-47,9277	-21,9984
DAEE	-47,9351	-22,0045
USP	-47,8833	-22,0167
USP	-47,8864	-22,1522
INMET	-47,7683	-21,7481

Fonte: Autor (2018)

Dentro ambiente SIG foram adicionados os seguintes dados: (a) tabela de pontos e; (b) limite da área de estudo no formato *Shapefile* (shp), que foi utilizado como uma máscara para gerar a interpolação dos dados e as isoietas. A interpolação é feita utilizando a ferramenta o *ArcGIS*® 10.5, que está no *ArcToolbox>Spatial Analyst Tools>Interpolation>DW*, como está ilustrado na Figura 25. Os campos são preenchidos com os pontos gerados a partir da tabela com os dados de chuva, muito importante especificar o campo da tabela que estão os valores pluviométricos, o local de saída do raster e o tamanho do pixel, foi adotado 30 metros. Para gerar as isoietas foi utilizado a ferramenta de curvas com barreiras que está na caixa de ferramentas (*ArcToolbox>Spatial Analyst Tools>Surface>Contour with Barriers*).

Figura 25 – Ferramenta IDW, no Toolbx do ArcGIS®



Organização: Autor (2019)

#### 4.4.9 Mapa Cobertura e Uso do Solo

O mapa de uso e cobertura foi elaborado utilizando imagens de satélite *Landsat 8*, para o ano de 2018, as imagens foram disponibilizadas pelo site *Earth Explorer (U.S. Geological Survey)*. Com resolução espacial de 30 metros, composição colorida RGB das bandas 4, 5 e 6 com fusão com a banda pancromática 8 de 15 metros (*UNITED STATES – USGS, 2018*).

As imagens foram processadas em ambiente SIG, em seguida foram vetorizados polígonos sobre os diferentes tipos de cobertura e uso do solo, que também foram validados em campo. Foram classificados 12 diferentes tipos, são eles: cana-de-açúcar, linha de transmissão, infraestrutura urbana, malha viária, mineradora, vegetação natural, pastagem, rio, represas, silvicultura, solo exposto e área urbana.

#### 4.4.10 Mapas de Processos Erosivos

O mapa de processos erosivos foi elaborado a partir de interpretação da imagem do satélite *Sentinel-2*. Após a identificação de processos erosivos em escritório, os dados serão confrontados com os obtidos em campo, com o auxílio de um inventário de campo detalhado (pontos de coleta, tipo de processo, ativo, inativo, estável).

Foi utilizado o *Software SNAP* da Agência Espacial Europeia para o processamento da imagem, o aplicativo foi desenvolvido pela própria ESA, responsável pelo programa de lançamento do satélite *Sentinel-2*. O *software* é capaz de gerar composições coloridas, mosaicos e classificação de imagens.

### 4.5 Mapeamento Utilizando o Método ANFIS

Para elaborar o mapa de susceptibilidade a erosão os alguns passos fundamentais foram seguidos, primeiro elaborar uma base de dados espaciais com atributos do meio físico que interferem diretamente nos processos erosivos, utilizar a relação

entre esses atributos condicionantes aos processos, seguido de uma validação dos resultados.

Os processos erosivos foram detectados na bacia hidrográfica do Rio Monjolinho por meio de interpretação de imagens *Sentinel-2*, com resolução espacial de 12,5 metros e trabalhos de campo para a elaboração do inventário. Além de, todos os relatórios e registros históricos, e dados arquivados.

As observações em campo são para confirmar os processos e o estágio que se encontram. Com base nessas descrições do local, arquivadas no banco de dados do SIG, os locais das erosões serão plotados o mais próximo do possível do real. O mapa e o inventário de processos erosivos foram úteis para entender os diferentes fatores de acionamento que controlam diferentes tipos de processos erosivos.

Segundo Ercanoglu & Gokceoglu (2002), para desenvolver um método de avaliação de susceptibilidade de uma área, a determinação dos fatores condicionantes para os processos é crucial. De fato, as avaliações de processos em escalas regionais devem ser práticas e aplicáveis para a área de estudo. Para o primeiro requisito desta declaração, os parâmetros de entrada devem ser representativos, confiáveis e obtidos facilmente. Neste estudo, foi selecionado os parâmetros de entrada considerando as observações de campo. No total, sete fatores condicionantes serão considerados nas análises realizadas.

Os atributos considerados básicos que influenciam no processo de erosão são: altitude, declividade, forma do terreno, geologia, textura do solo, chuvas e cobertura e uso do solo. Esses atributos foram selecionados com base na literatura e experiência em outros trabalhos. Todos os atributos que foram empregados nesta pesquisa foram transformados em um banco de dados espaciais usando um SIG.

Foi considerado de modo substancial os dados de declividade do terreno. Ercanoglu & Gokceoglu (2002) em seu trabalho comenta que existe uma relação física entre a ocorrência de transportes de terra e o gradiente de inclinação. O aumento no gradiente de inclinação resulta em um aumento das forças motrizes. Portanto, a configuração da declividade junto com as formas do terreno desempenha um papel importante na susceptibilidade de um local ao processo erosivo. Isso faz com que esses fatores sejam importantes na preparação do mapa de susceptibilidade.

Após a elaboração dos mapas de todos atributos condicionantes, foram convertidos em uma grade raster com 30m×30m para a aplicação do modelo neuro-fuzzy. Vão ser utilizados, o pacote de *software ArcGIS*<sup>®</sup> 10.5 e o *Matlab*<sup>®</sup>, como ferramentas básicas de análise para gerenciamento espacial e manipulação de dados.

A metodologia, proposta neste trabalho, tem como apoio os trabalhos dos seguintes autores: OH & PRADHAN, 2011; JANG, 1993; JANG & SUN, 1995; TAKAGI-SUGENO, 1985; PRADHAN *et al.*, 2010, que de alguma maneira utilizaram um modelo de rede neural ANFIS.

#### **4.5.1 O sistema de inferência neuro-fuzzy adaptativo**

A construção das bases, utilizando a ANFIS, serve para a elaboração de um conjunto de regras *fuzzy IF-THEN* com os pares de entrada e saída estipulados de acordo JANG (1993) e JANG & SUN (1995). De acordo com Oh & Pradhan (2011) o método ANFIS é conhecido por empregar redes neurais, mas com as vantagens do sistema de inferência *fuzzy*. Embora a missão de regras *fuzzy IF-THEN* seja mo-

delar o conhecimento especializado, e a rede neural é para otimizar as funções de associação para minimizar a taxa de erro na saída.

O sistema neuro-*fuzzy* deve aprender o comportamento do sistema a partir de um grande conjunto de dados e de gerar automaticamente regras difusas e conjuntos difusos para um nível de precisão pré-especificado, além de possuir uma capacidade de generalização que supera as principais desvantagens do uso da lógica difusa (JANG, 1993; DIXON, 2005; OH & PRADHAN, 2011).

#### 4.5.2 Preparação dos dados de treinamento

Para desenvolver o modelo ANFIS, os dados são particionados em pelo menos dois subconjuntos, como dados de treinamento e teste. Antes de executar o programa ANFIS, o local de treinamento deve ser selecionado. Os dados de treinamento incluem todos os dados pertencentes ao domínio do problema. Esse subconjunto é usado no estágio de treinamento do desenvolvimento do modelo para atualizar os pesos da rede. Por outro lado, os dados do teste devem ser diferentes daqueles usados na fase de treinamento. O principal objetivo deste subconjunto é verificar o desempenho da rede usando dados não treinados e confirmar sua precisão. Nenhuma regra matemática exata para determinar o tamanho mínimo requerido desses subconjuntos existe (OH & PRADHAN, 2011).

Algumas sugestões para as porções dessas amostragens são encontradas na literatura, é considerado que aproximadamente 80% dos dados inteiros são o suficiente para treinar a rede, e o restante é normalmente tratado para testar a arquitetura final do modelo (SWINGLER, 1996; TUNUSLUOGLU *et al.*, 2008; PRADHAN *et al.*, 2010).

Neste estudo, serão selecionadas áreas de ocorrência e áreas sem processos erosivos evidentes para o treinamento. De acordo com Oh & Pradhan (2011) as células das duas classes (com e sem ocorrência de processos) são selecionadas aleatoriamente pra o treinamento, 80% dos casos são selecionados para a calibração do ANFIS e os outros 20% são utilizados para teste de validação. Durante a fase de treinamento, as áreas serão classificadas em áreas “com potencial erosivo” e áreas “sem potencial” erosivos.

#### 4.5.3 Aplicação da razão de frequência para mapeamento de suscetibilidade a erosão

Os atributos relacionados a processos erosivos como altitude, declividade, forma do terreno, geologia, cobertura e uso do solo, chuvas e textura do solo serão convertidos de dados do tipo vetor para tipo raster e reclassificados (OH & PRADHAN, 2011).

Para os dados de curvatura do plano será utilizado as 9 classes propostas por Valeriano (2008), reclassificadas de acordo com a forma de acumulação e tipo de transporte. Em seguida, a relação espacial entre os locais de escorregamentos e cada um dos fatores de condicionamento aos processos erosivos será calculada pelo método de razão de frequência (LEE & PRADHAN, 2006).

#### 4.5.4 Aplicação do ANFIS ao mapeamento de suscetibilidade à erosão

Os valores de razão de frequência de cada um dos atributos devem ser computados, após isso, o método ANFIS será empregado para calcular a suscetibilidade a erosão na bacia hidrográfica do Rio Monjolinho. O modelo ANFIS que será utilizado, é o mesmo proposto no trabalho de Oh & Pradhan (2011), um modelo ANFIS tipo 3, é um método global de mínimos quadrados utilizado para identificar o parâmetro dos consequentes lineares do modelo *fuzzy* Takagi-Sugeno (SUGENO, 1985; TAKAGI & SUGENO, 1983). A saída do modelo é atribuída a partir dos valores do índice de suscetibilidade a erosão com base na técnica de taxa de frequência.

Na sequência, cada atributo que condiciona os processos de erosão, serão recalculados pela ANFIS. A Figura 27, mostra o fluxograma da modelo conceitual da ANFIS em ambiente SIG e o processo de elaboração do mapa de suscetibilidade a erosão. São utilizados dois softwares (*ArcGIS*<sup>®</sup> e *Matlab*<sup>®</sup>) durante o processo.

O *ArcGIS*<sup>®</sup> foi utilizado na produção de dados de inventário, dados de entrada de erosão e o mapa de suscetibilidade a erosão. O *Matlab*<sup>®</sup> é empregado para construir, treinar e testar os modelos ANFIS. Além disso, a seleção do conjunto de dados de treinamento é fundamental para este estudo.

#### 4.5.5 Validação do mapa de suscetibilidade à erosão

Para verificação dos métodos de cálculo de suscetibilidade a erosão, são necessários dois pressupostos básicos. Uma é que os processos erosivos estão relacionados a informações espaciais, como topografia e tipos de solo, e a outra é que as futuras erosões serão desencadeadas por um fator específico, como chuvas ou uso do solo (CHUNG & FABBRI, 2003).

Para uma comparação eficaz dos mapas de suscetibilidade a erosão derivados do ANFIS, todos os mapas de suscetibilidade a erosão serão avaliados comparando-os separadamente com os dados do teste de erosões. Todos os escorregamentos que não foram utilizados na fase de treinamento serão selecionados como locais de teste. No final, oito mapas de suscetibilidade a erosão serão gerados (funções de pertinência derivadas do ANFIS, denominadas triangular, trapezoidal, gaussiana1, gaussiana2, sino generalizada, sigmoidal1, sigmoidal2 e polinomial *MFs*) para ser validadas contra o conjunto de dados de erosão existentes.

### 4.6 Elaboração da matriz de dados

Os dados aplicáveis no *Matlab*<sup>®</sup> foram extraídos de uma matriz de pontos criados pelo *software ArcGIS*<sup>®</sup>. Após a elaboração dos mapas base com os atributos, todos foram padronizados no formato raster com tamanho do pixel de 30x30m, e normalizados com os valores entre 0 e 1, utilizando a ferramenta *Fuzzy* (*ArcToolBox*>*Spatial Analyst*>*Overlay*>*Fuzzy membership*). Para obter as informações de cada ponto foi criado uma grade regular de 100x100m junto com o centróide de cada polígono, por toda a extensão da área de estudo. A ferramenta utilizada está na caixa de ferramentas: *ArcToolBox*>*Data Management Tools*>*Samplig*>*Create Fishnet*. O resultado é um mapa com uma grade regular e um ponto no centróide, como é mostrado na Figura 26.



## 4.7 Estrutura dos dados de entrada no Matlab

Os modelos de treinamento no *software Matlab*<sup>®</sup> foram realizados em duas fases, a primeira fase utilizou três designs de treinamentos, *Perceptron*, *Perceptron Multicamadas* e *ANFIS*, na segunda fase foi utilizado apenas o *design Perceptron*, visto que, apresentou os melhores resultados após ajustes nos testes da primeira fase.

### 4.7.1 Preparação dos dados

Foram 7 entradas de dados:

- 1) Declividade;
  - 2) Elevação;
  - 3) Geologia;
  - 4) Pluviometria;
  - 5) Cobertura do solo;
  - 6) Materiais Inconsolidados;
  - 7) Forma do Terreno.
- Um dado de saída: Erosão.

Dados extraídos no *software ArcGIS*<sup>®</sup> formato Shapefile com resolução de 30x30m por *pixel*;

O processamento no *MATLAB*<sup>®</sup>:

- Passo 1: Remoção de tuplas com dados inválidos (por exemplo, valores -9999);
- Passo 2: Contagem do número de ocorrências de tuplas repetidas;
- Passo 3: Remoção de tuplas repetidas.

Ao final destas etapas, foram obtidos 13.152 linhas de dados para treinamento.

Problema encontrado: dessas 13.152 linhas de dados, apenas 355 eram correspondentes à classificação de erosão revelando que existe um desbalanceamento na proporção do número de casos para cada classe, sendo que a classe Erosão possui valores “Verdadeiro” ou “Falso”, ou seja, existe erosão ou não existe erosão. Parte da solução do problema está no Passo 2 e 3.

### 4.7.2 Balanceamento dos dados

O desbalanceamento dos dados é um problema porque o número de amostras de cada classe é muito importante em qualquer técnica de estimativa estatística, e o aprendizado de máquina (também conhecido como teoria da classificação e regressão) não é diferente.

Duas possíveis soluções para esse problema são: a primeira, obter mais dados de erosão ou a segunda reamostrar os dados. Foi escolhida a segunda opção devido a falta de informações da primeira.

Portanto, para os 355 dados de erosão foram selecionados 355 dados não contendo erosão. Os dados com maior número de ocorrências foram considerados mais relevantes para o treinamento, por isso a importância do Passo2. Outros 355 dados de “não erosão” foram selecionados aleatoriamente e adicionados ao conjunto, totalizando 710 de “não erosão” e 355 de “erosão” mantendo uma proporção de 2 para 1.

### 4.7.3 Conjuntos de Treinamento, Validação e Teste

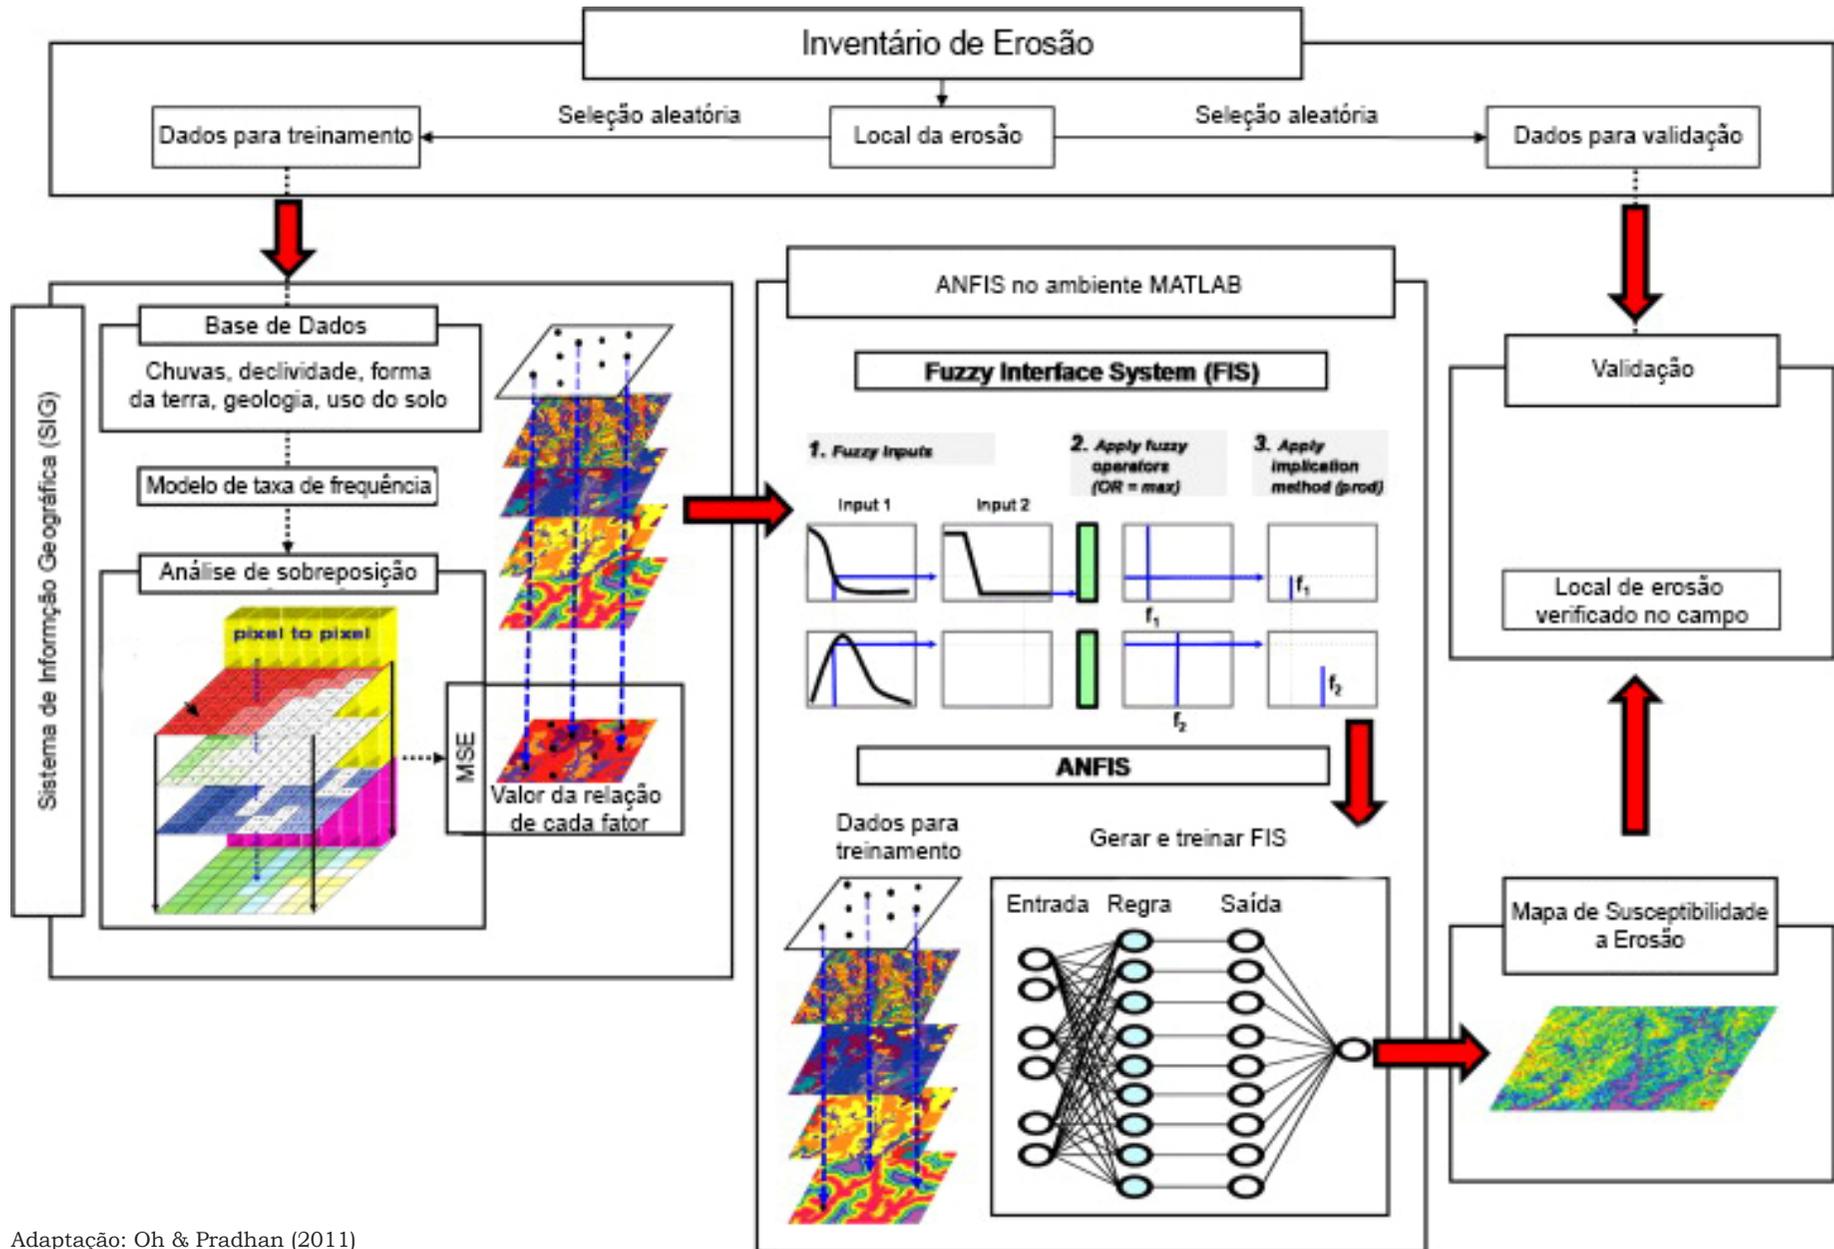
Conjunto de treinamento: esse conjunto de dados é usado para ajustar os pesos da rede neural.

Conjunto de validação: esse conjunto de dados foi utilizado para minimizar o ajuste excessivo. O conjunto não está ajustando os pesos da rede com esse conjunto de dados, apenas está verificando se qualquer aumento na precisão do conjunto de dados de treinamento produz realmente um aumento na precisão de um conjunto de dados que não havia sido mostrado para a rede antes, ou pelo menos a rede não treinou, ou seja, conjunto de dados de validação. Se a precisão do conjunto de dados de treinamento aumentar, mas a precisão do conjunto de dados de validação permanecer a mesma ou diminuir, você estará ajustando demais sua rede neural e o treinamento deve ser interrompido.

Conjunto de testes: esse conjunto de dados é usado apenas para testar a solução final, a fim de confirmar o poder preditivo real da rede.

Todos os documentos do *Matlab*<sup>®</sup> estão no apêndice da tese, tratamento dos dados, estruturação, entrada e treinamento das redes neurais artificiais. Na Figura 28 é mostrado em detalhes o método ANFIS para o mapeamento de susceptibilidade a erosão.

Figura 28 - Fluxograma do modelo conceitual da ANFIS em ambiente SIG



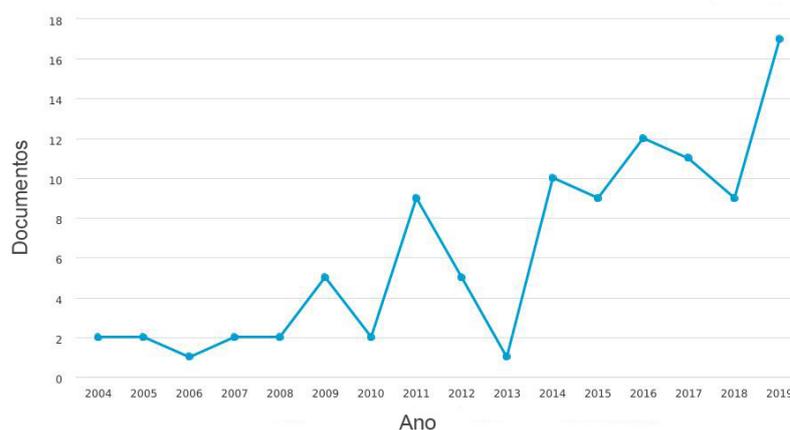
## Resultados e discussões

Neste capítulo são apresentados os resultados obtidos na análise bibliométrica, dos produtos cartográficos básicos, do inventário de campo e das simulações analíticas visando à caracterização dos processos erosivos. A elaboração desses documentos foram fundamentais para gerar o conjunto de dados de treinamentos utilizados para treino e validação da rede neural. Também são apresentados os resultados das etapas de treinamento das redes neurais, *Perceptron*, *Perceptron* Multicamadas e o ANFIS para o mapeamento de processos erosivos.

### 5.1 Análise Bibliométrica para o método ANFIS

Os indicadores bibliométricos, gráficos e tabelas, foram retirados da base de dados da Scopus, sobre o tema ANFIS, utilizando outras palavras-chaves relacionadas ao tema da pesquisa, como erosão, geoprocessamento, sensoriamento remoto, lógica *fuzzy* e redes neurais artificiais. As publicações referentes a palavras chaves utilizadas na busca da base da Scopus são do período entre 2004 a 2019, num total de 99 trabalhos, distribuídos em diferentes veículos de divulgação (revistas, capítulos de livros, anais de congressos) o principal são as revistas, periódicos de divulgação científica. Como mostra a Figura 29, o número de trabalhos aumentou de 2004 para 2019, com uma média anual de 6,25%, mas fazendo um outro tipo de análise com base no gráfico temos por exemplo, a diminuição das publicações no ano de 2006, 2010 e 2013, mas com um aumento expressivo de 2014 até 2019 somando 68 trabalhos nesses últimos 6 anos.

Figura 29 - Número de publicações por ano



Em relação aos autores, países e periódicos mais ativos no tema, pode-se concluir que as maiores publicações são produzidas na Austrália, Coréia no Sul, China e Iran, com foco a método de geoinformação para mapeamento e prevenção a deslizamentos de terra. A Austrália apresenta o maior número de trabalhos e a maior média de citação por artigo em periódicos conceituados no assunto.

Coréia no Sul, China e Iran, possuem diversas publicações, que apresentam uma elevada média de citação por artigo, mostrando também que possuem trabalhos bem conceituados. Entre os autores, foram listados os 10 mais produtivos, indicando seu país de origem, e vínculo institucional como mostrado na Tabela 2. Entre eles, o autor Biswajeet Pradhan (Pradhan, B.) da Universidade Tecnológica de Sidnei, na Austrália é o mais ativo entre os pesquisadores, possui o mais número de publicações relevantes no tema, citações e colaborações com os outros autores de destaque no assunto.

Tabela 2 - Número de artigos publicados por autor, seu país de origem e instituição de filiação

Autor	Publicações	Cidade, País	Instituição
Pradhan, B.	8	Sydney, Austrália	University of Technology Sydney
Panahi, M.	6	Daejeon, South Korea	Kangwon National University
Chen, W.	4	Xi'an, China	Xi'an University of Science and Technology
Jaafari, A.	4	Tehran, Iran	Research Institute of Forests and Rangelands
Aghdam, I.N.	3	Tehran, Iran	Islamic Azad University
Cawkwell, F.	3	Cork, Ireland	University College Cork
Green, S.	3	Fermoy, Ireland	Moorepark Food Research Centre
Lee, S.	3	Daejeon, South Korea	Korea Institute of Geoscience and Mineral Resources
Petković, D.	3	Vranje, Nis, Serbia	University of Niš
Shahabi, H.	3	Sanandaj, Iran	University of Kurdistan

Organização: Autor (2020)

Na tabela 3, estão as revistas que mais publicam trabalhos relacionados a sistema de inferência neuro-*fuzzy* adaptativo, sendo que as revistas mais relevantes no tema possuem uma média de 3,2 trabalhos publicados no período de análise, num total de 32 artigos. As publicações estão distribuídas em revistas de áreas distintas, embora sejam geralmente da área de geociências, ciências ambientais, sensoriamento remoto, computação e geotecnia.

Tabela 3 - Revistas que mais publicaram no período analisado

Revista	Publicações
Catena	4
Environmental Earth Sciences	4
IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing	4
Journal of the Indian Society of Remote Sensing	4
Applied Mechanics and Materials	3
Bulletin of Engineering Geology and The Environment	3
Computers and Geosciences	3
International Journal of Remote Sensing	3
Expert Systems With Applications	2
International Geoscience and Remote Sensing Symposium IGARSS	2

Organização: Autor (2019)

Quando analisado no gráfico (Figura 30), é observado que existe uma frequência de publicação por ano, quatro das cinco revistas principais publicaram pelo menos um artigo por ano no período de 2014 a 2018, a revista *Catena* não publicou em 2018, mas publicou 2 em 2019. A revista *Applied Mechanics And Materials* chegou a publicar três no mesmo ano (2014). Com essas informações podemos afirmar que há um interesse dos principais veículos de divulgação científica em publicar trabalhos dessa natureza.

Figura 30 - Gráfico de frequência de publicações



Fonte: *Scopus* (2019)

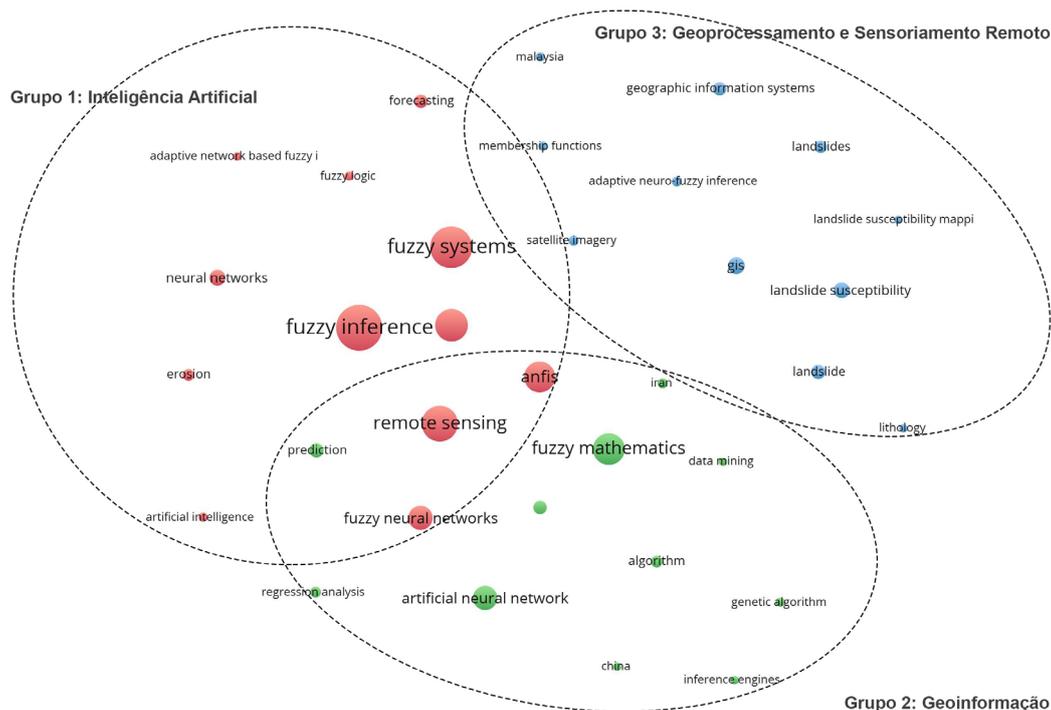
Relacionadas as principais palavras-chave utilizando o *software VOSviewer* foi encontrado 1196 palavras nos resumos e título das publicações relacionadas ao tema de análise. Foram classificadas as palavras que se repetiram pelo menos 8 vezes. Em seguida, essas palavras foram separadas em três grupos (Figura 31), que são: (1) Inteligência Artificial, representado pelos círculos vermelhos, que relaciona as técnicas de inteligência artificial e lógica *fuzzy*; (2) Geoinformação, representado pelos círculos verdes, representa as técnicas matemáticas e computacionais; (3) Geoprocessamento e Sensoriamento Remoto, representado pelos círculos azuis, relacionado a trabalhos com diferentes aplicações para mapeamentos do meio físico.

Verificou-se que, o tamanho do círculo e o tamanho das fontes tem relação com o número de repetições que a palavra aparece citada nos resumos e título dos artigos. Portanto, as palavras mais ocorrência são: “*fuzzy inference*” (inferência difusa), “*fuzzy systems*” (sistema difuso), “*remote sensing*” (sensoriamento remoto) e “*anfis*” (sigla de sistema de inferência neuro difuso adaptativo), que fazem parte do grupo 1. No grupo dois são as palavras: “*fuzzy mathematics*” (matemática difusa), “*artificial neural networks*” (redes neurais artificiais) e “*prediction*” (predição). E no grupo 3, as principais foram: “*gis*” (sigla de sistema de informações geográficas) e “*landslide susceptibility*” (susceptibilidade a deslizamentos de terra).

As palavras do grupo 1 estão relacionadas com os trabalhos principalmente nas áreas de sensoriamento remoto que utilizam de alguma maneira técnicas computacionais, aplicando os métodos de inteligência artificial, machine learning, entre outros métodos para classificação de áreas de modo automático, supervisionadas

com grande quantidade de informações. No grupo 2, grupo dois são palavras ligadas as técnicas matemáticas, modelos, conjuntos de regras, tipo de algoritmos que funcionam por trás das diversas abordagens adotadas.

Figura 31 - Grupos de palavras-chave



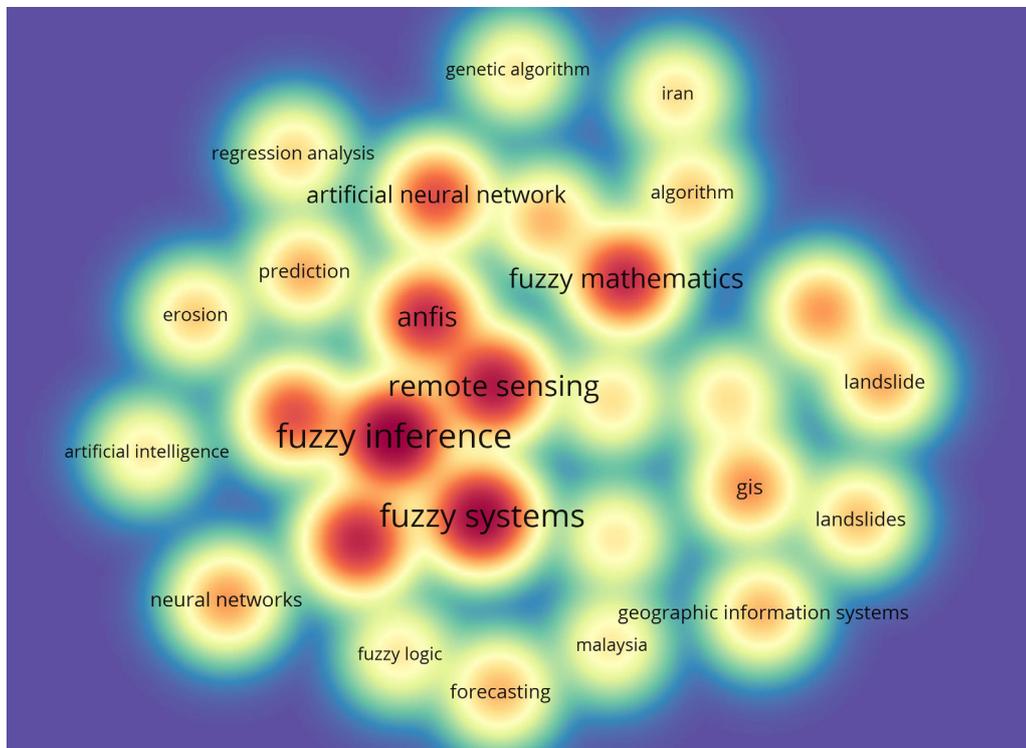
Fonte: Gerado com VOSviewer (2019)

O terceiro grupo possui o conjunto de palavras que mais representa o tipo de análise proposto, são as palavras que mais aparecem nas busca em relação ao mapeamento de áreas susceptíveis utilizando o método ANFIS, que são: sistema de informações geográficas (*gis*), porque todo o processo de mapeamento é feito em ambiente SIG, desde os dados primário de entrada até o mapa final; mapa de susceptibilidade a deslizamentos de terra (*landslide suceptibility mapping*), maioria dos trabalhos encontrados são para este tipo de processo, característico dos países que mais publicam no área; e inferência neuro-*fuzzy* adaptativo (*adaptative neuro-fuzzy inference*), método que combina lógica *fuzzy* e redes neurais artificiais, principal palavra-chave na busca.

Analisando a Figura 32, observa-se que os termos: *fuzzy inference*, *fuzzy systems*, *remote sensing*, *anfis*, *fuzzy mathematics*, *artificial neural networks*, têm uma alta frequência nos artigos e coincidem com os trabalhos mais citados e de grande relevância. Dentre eles estão as metodologias para mapeamento e análises multicritérios, são muito utilizadas, tornando o processo rápido e confiável. O trabalho de Jang (1993) um dos precursores, utilizou um modelo adaptado do sistema neuro-*fuzzy* para elaborar mapa de susceptibilidade a deslizamento de terra, sendo utilizado por outros autores consagrados, destaque para os trabalhos de OH & PRADHAN, (2011) e SEZER *et al.* (2011).

Em grande parte dos trabalhos, o sistema de inferência neuro-*fuzzy* adaptativo (ANFIS) foi utilizado para o mapeamento da susceptibilidade de áreas propensas ao deslizamento de terras. O modelo ANFIS é aplicado e validado, utilizando *software* que de manipulação de matrizes (*Matlab*<sup>®</sup>) e de sistema de informações geográficas (SIG). O método ANFIS utilizado, baseia-se no conhecimento especializado, aplicando o sistema de inferência *fuzzy* (FIS) e o aprendizado por Redes Neurais Artificiais (RNAs). De acordo com Jang (1993) a metodologia pode ser utilizada em qualquer local com mínimas mudanças.

Figura 32 - Distribuição de densidade das palavras de maior ocorrência. As cores indicam a densidade de termos, sendo que quanto maior o tamanho da letra, e mais próximo do vermelho, maior a ocorrência da palavra dentro dos artigos



Fonte: Gerado com *VOSviewer* (2019)

## 5.2 Mapa cadastral e mapas temáticos base

Nesse tópico são apresentados os resultados dos mapas intermediários, de onde foram extraídas as informações necessárias para a elaboração do mapa de suscetibilidade a erosão. São mapas base elaborados em ambiente SIG.

Os mapas temáticos são representações gráficas da superfície terrestre ilustradas de acordo com algum critério preestabelecido (ZUQUETTE, 2004). Para designar os diferentes aspectos do espaço geográfico, utilizam-se as legendas e os símbolos a elas correspondentes para representar no espaço determinados fenômenos.

Mais do que apenas realizar descrições espaciais sobre determinadas atividades ou fenômenos naturais, os mapas temáticos também possuem o mérito de apresentarem formas distintas de leitura e interpretações da realidade, ofertando ao seu leitor uma melhor compreensão das manifestações sociais e da natureza, como as atividades culturais de uma região ou os índices pluviométricos de um país. Portanto, a produção dos mapas temáticos vai muito além da representação das áreas e suas formas, trata-se de reinterpretações dessas informações para melhor descrever dados e fenômenos.

### 5.2.1 Mapa de Documentação

O mapa de documentação é resultado de outros produtos digitalizados e vetorizados. Para elaborar a base topográfica foram utilizadas as folhas topográficas do IBGE, na escala de 1:50.000, equidistância das curvas de nível 20 metros do ano de 1972. O mapa serviu para auxiliar nas visitas em campo, também foi adicionado ao mapa base topográfico uma imagem do satélite *Sentinel-2*, que trouxe informações que facilitaram a navegação em campo.

As cartas foram digitalizadas e georreferenciadas no sistema de projeção UTM, referência horizontal Córrego Alegre - MG, referencial vertical Marégrafo de Imbituba-SC, Fusos 22° e 23°S, em seguida reprojetaadas para coordenadas geográficas (para evitar o conflito de fusos) no sistema Sirgas2000). Das cartas foram extraídas as curvas de nível, estradas, pontos cotados e a hidrografia. Também estão representadas as coordenadas das visitas *in situ*, para verificação dos pontos de erosão.

O modelo do terreno foi utilizado por ser uma das variáveis para avaliar o escoamento superficial e a infiltração do terreno. Segundo Rubim (1966) apud Pejon (1992) o escoamento superficial só ocorre quando a intensidade da precipitação é maior que a capacidade de infiltração do solo. Ou seja, em relação a forma do terreno, quanto mais inclinado for o relevo menor é a chance de a água infiltrar no solo, favorecendo escoamento superficial. Por esse motivo, a opção por adicionar no mapa de documentação um relevo sombreado (Figura, 33) para compreender o funcionamento das encostas nesse processo.

Outros fatores de interferências no escoamento superficial que devem ser considerados em conjunto com o relevo, e que influenciam e aumentam o tempo de concentração de água no local, por exemplo, os cordões de nível para agricultura, o tipo da vegetação, a interceptação da água da chuva pela copa das árvores. A cobertura vegetal que pode interceptar a precipitação de acordo sua densidade, entre outros fatores que estão apresentados nos mapas a seguir.

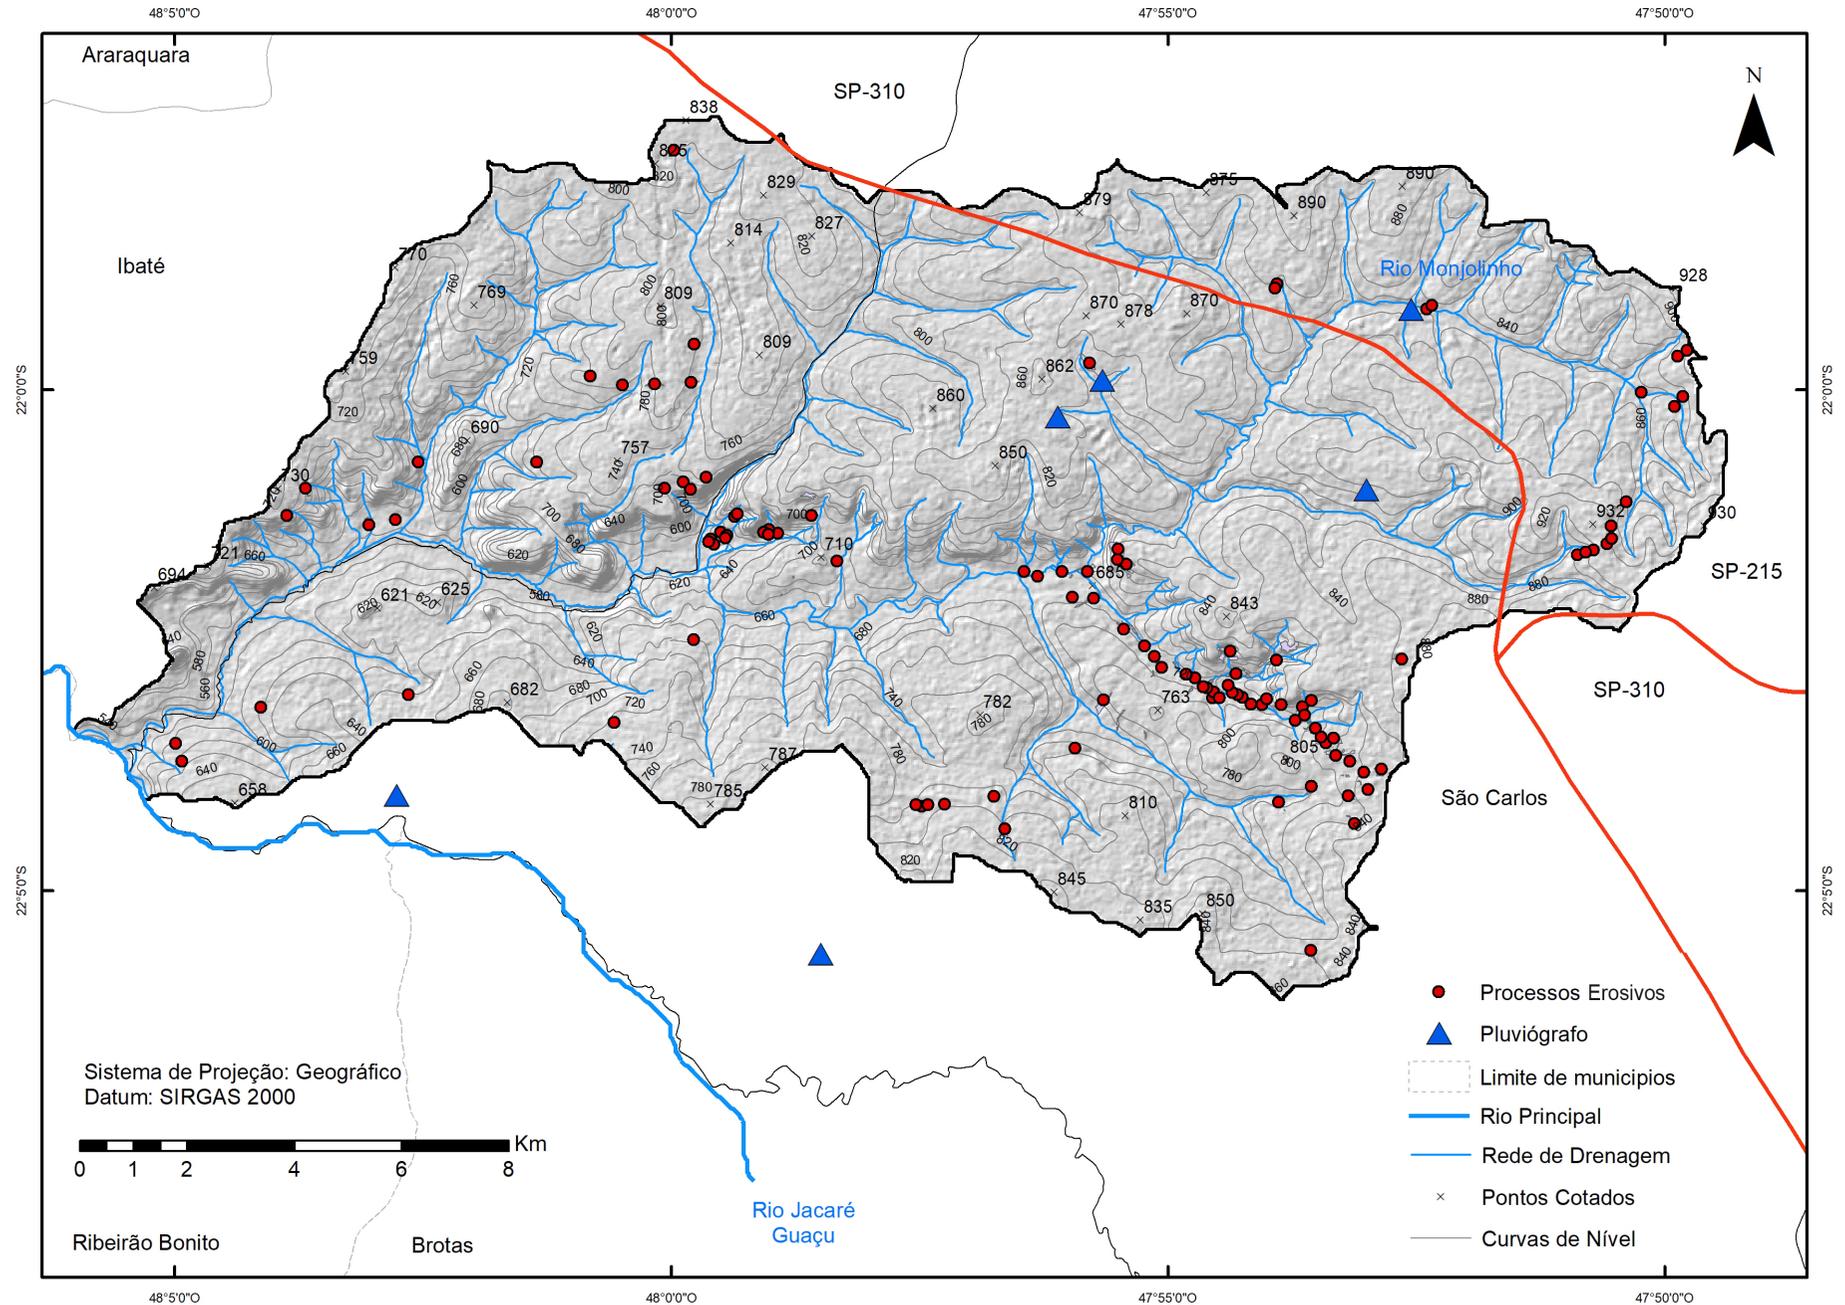


Figura 33 - Mapa de documentação BHRM

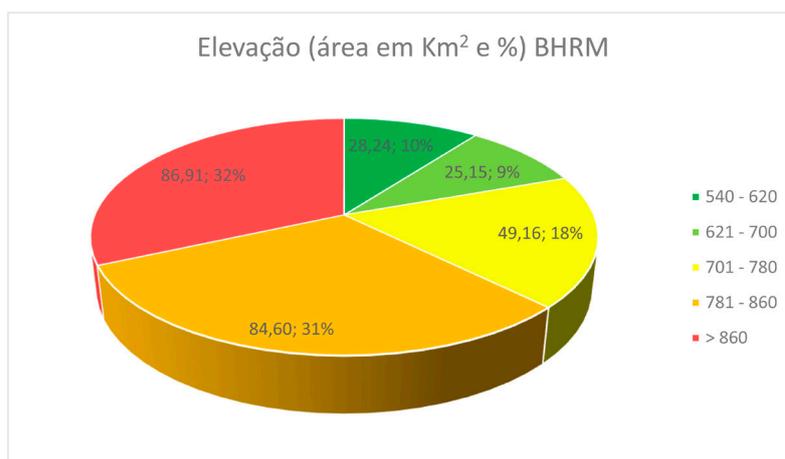
Fonte: Autor (2019)

### 5.2.2 Mapa Hipsométrico

A hipsometria (medidas de altitude) é um dos métodos adotados para se fazer a análise e interpretação de compartimentos do relevo de uma determinada região ou bacia hidrográfica. É obtida por meio da generalização das curvas de nível de uma carta ou mapa topográfico, estando estas em intervalos regulares ou não, sendo divididas em classes altimétricas, estão representadas no mapa por um sistema de graduação de cores. Mapas físicos, apontam a localização e a distribuição de elementos naturais, dividindo-se em vários subtipos, como os mapas topográficos, os hidrográficos, os de variações de altitudes, climáticos, dentre tantos outros. Com eles, é possível realizar ações de planejamento de atividades econômicas ou de formas de ocupação e transformação dos solos.

Para a bacia Hidrográfica do Rio Monjolinho foram definidas cinco classes temáticas, que estão distribuídas nos intervalos 540-620, 621-700, 701-780, 780-860 e maior que 860 metros. Com variação média de 80 metros, as cotas mais altas encontram-se ao leste da bacia hidrográfica somando 63% do total da bacia, coincidindo com a área urbana do município. As cotas diminuem na direção oeste, em direção da sua foz, desaguando no Rio Mogi Guaçu. A Figura 34 contém as informações da elevação da área em quilômetros quadrados e porcentagem. Para produzir esses diferentes tipos de mapas, foram utilizadas técnicas e ferramentas de localização geográfica, as escalas ou até a distorção de determinadas características do espaço. Nesse sentido, mais do que apenas representações, os mapas funcionam como documentos e representações do real. O mapa hipsométrico da BHRM está representado na Figura 35, com cinco classes de altitude.

Figura 34 - Gráfico com elevação em porcentagem e área em Km<sup>2</sup> da BHRM



Fonte: Autor (2019)

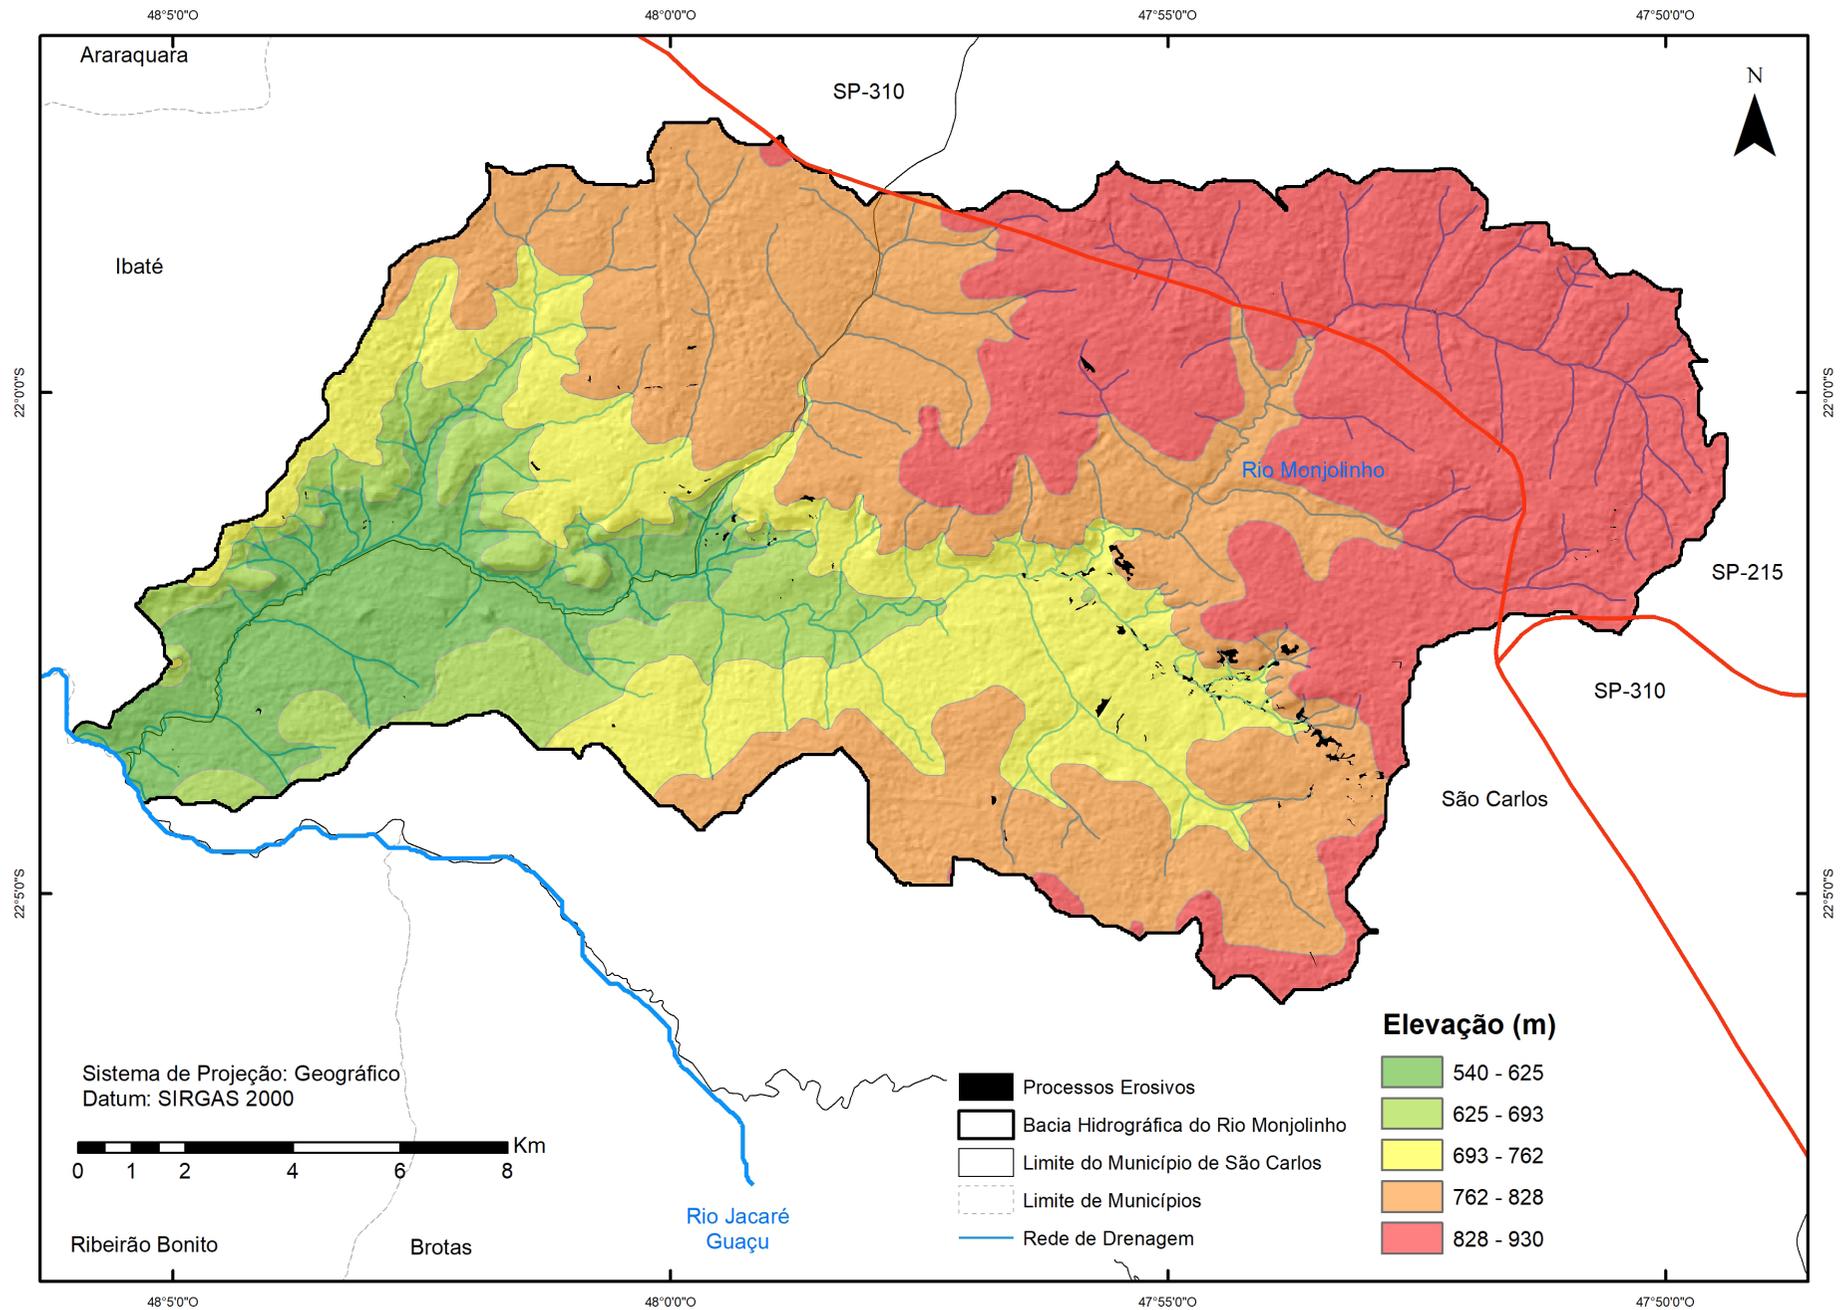


Figura 35 - Mapa Hipsométrico BHRM

### 5.2.3 Mapa Pluviométrico

O mapa pluviométrico foi elaborado a partir dos dados de 10 estações distribuídas pelo município de São Carlos. Com precipitações médias mensais que variam de 76 a 193mm por ano, os dados são apresentados na Tabela 4. O índice pluviométrico é uma medida em milímetros, resultado do somatório da quantidade da precipitação de água (chuva) num determinado local durante um dado período de tempo, utilizando um pluviógrafo.

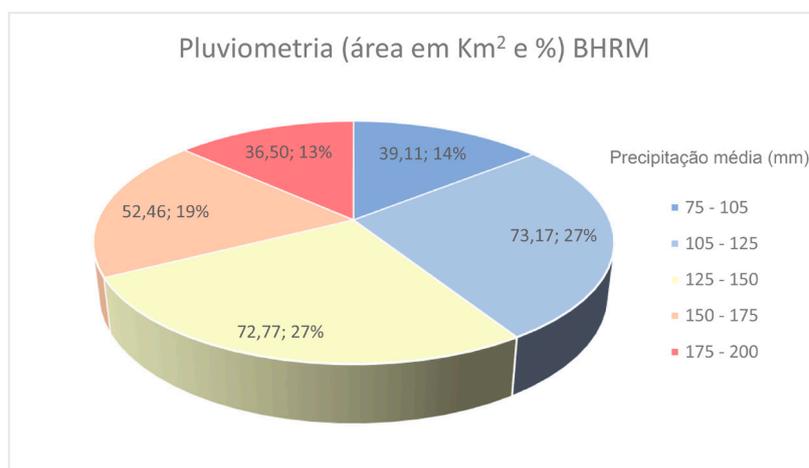
Tabela 4 - Precipitação mensal da BHRM (2018)

Dados de Precipitação da Bacia Hidrográfica do Rio Monjolinho (2018)			
Ponto	Nome da Estação	Precipitação Média 2018 (mm)	Fonte
1	USP Área 2 - Entrada	192,53	USP
2	USP Área 2 - Eng. Aeronáutica	162,03	USP
3	UFSCar	76,03	INMET
4	Ribeirão do Feijão	103,79	ANA
5	Santa Eudóxia	93,92	DAEE
6	Fazenda da Barra	123,74	DAEE
7	Porto Cunha Bueno	100,93	DAEE
8	São Carlos SAAE	106,58	DAEE
9	Fazenda Santa Barbara	115,62	DAEE
10	Fazenda Água Branca	91,02	DAEE

Elaboração: Autor (2019)

A distribuição da precipitação na área de estudo é apresentada na Figura 36, o gráfico mostra que as chuvas entre 105 e 150mm representam a maior parte das chuvas com 54%, que também coincidem com a maioria dos processos erosivos, a Figura 37 mostra essa representação no espaço. As chuvas com maiores intensidade de 150 a 200mm somam 32%.

Figura 36 - Gráfico precipitação média anual para o ano de 2018 na BHRM



Fonte: Autor (2019)

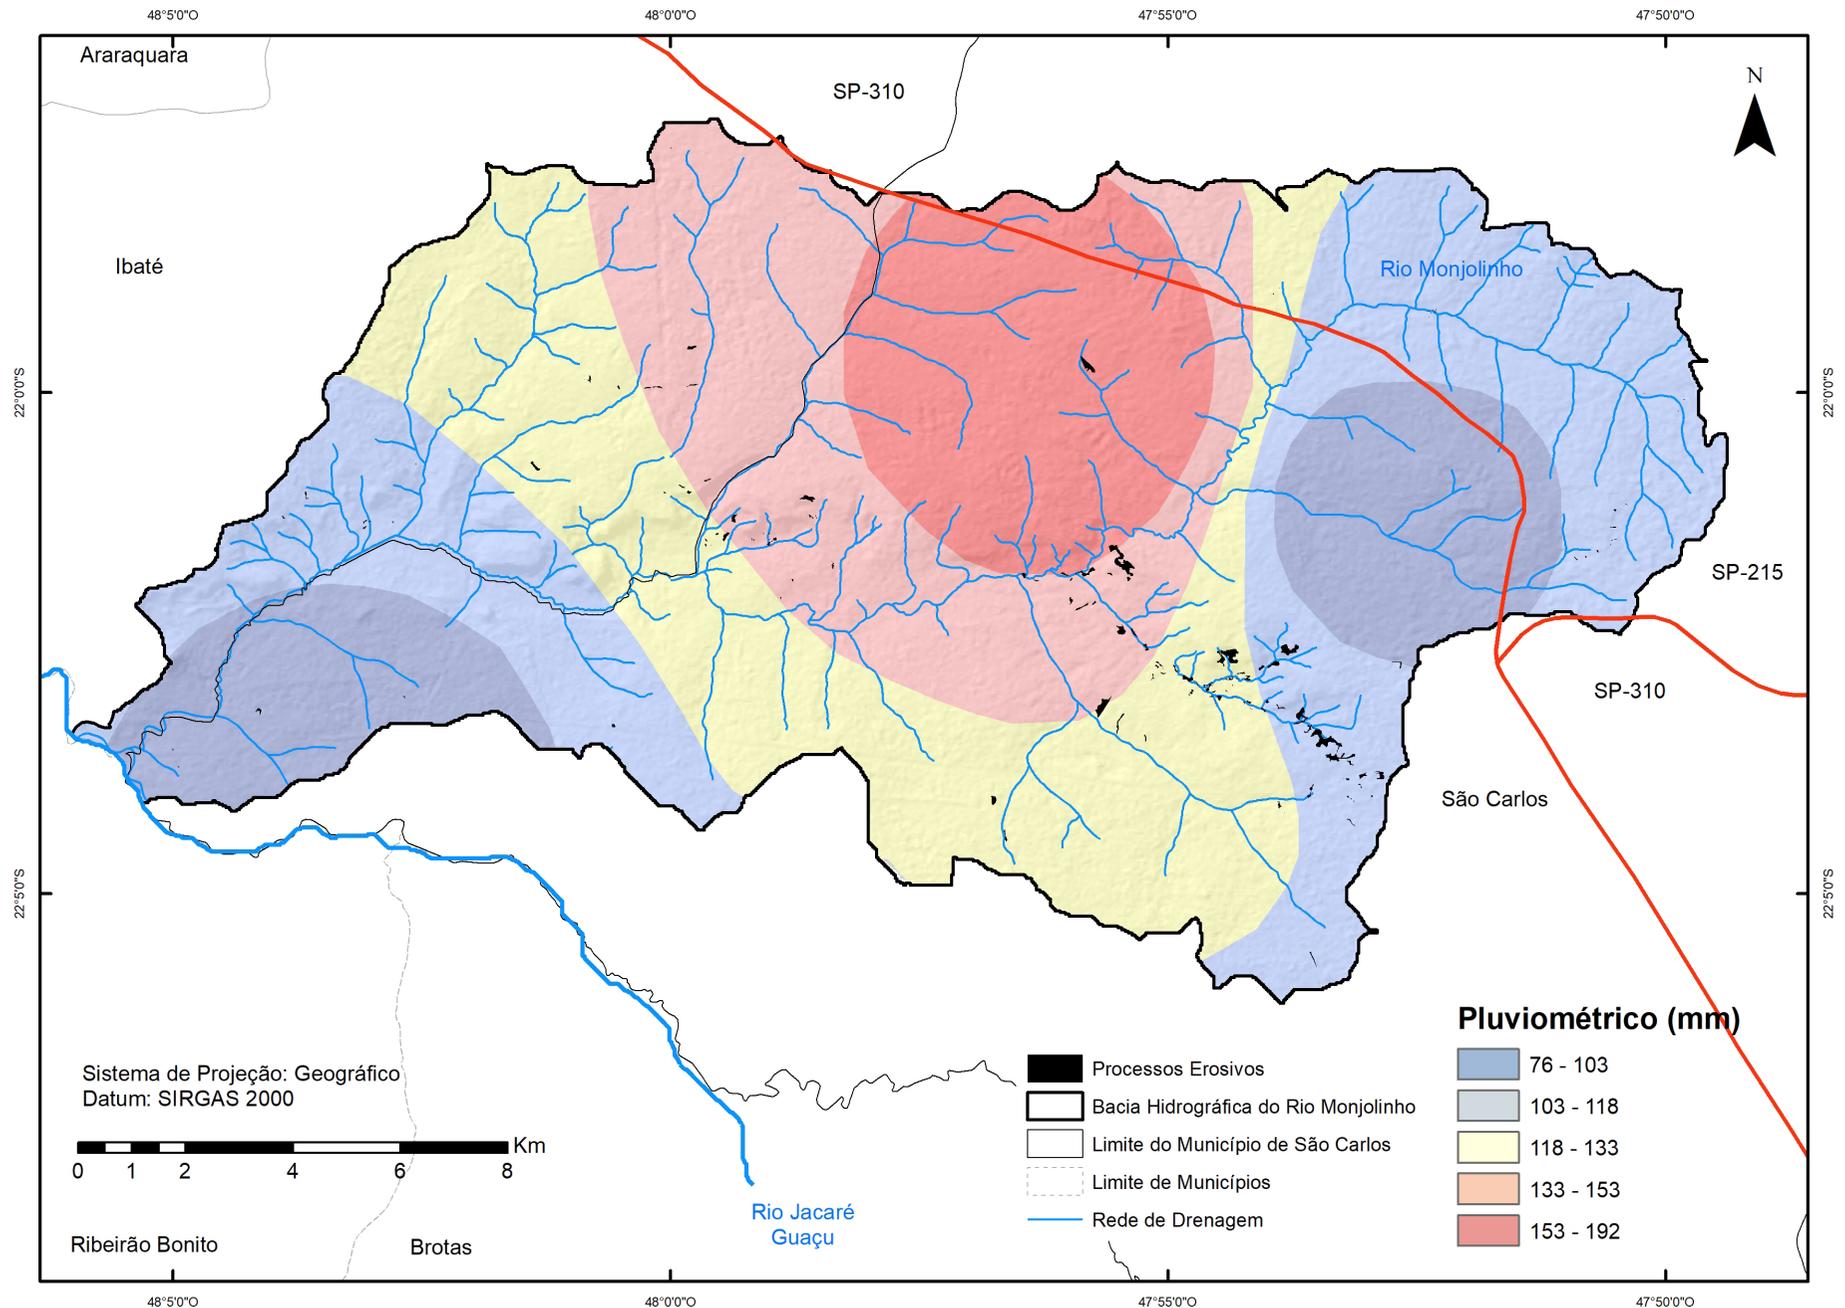


Figura 37 - Mapa Pluviométrico

Fonte: Autor (2019)

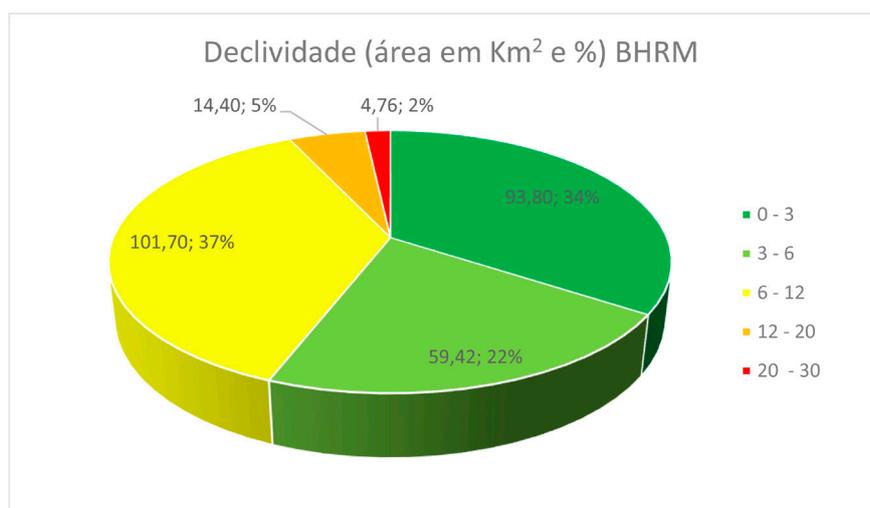
### 5.2.4 Carta de Declividade

A topografia do terreno, especialmente a declividade, é o principal condicionante da sua capacidade de uso, ou seja, a inclinação do terreno vai determinar o tipo de ocupação. Referindo-se ao processo de erosão, alguns autores utilizam o argumento de que o processo é geológico ou natural, que se manifesta como uma ocorrência de modificação na crosta terrestre, reconhecido somente no decorrer de longos períodos de atividade, e que esses processos são benéficos, pois com eles formam-se colinas, planícies e vales férteis. Os problemas aparecem quando o homem destrói os anteparos naturais, acelerando esses processos erosivos.

Os processos erosivos possuem significativa complexidade e a Carta de Declividade é um dos principais mapas de análise nesse sentido. São as declividades que determinam a velocidade do fluxo da água após a precipitação. O modelo digital do terreno foi fatiado em cinco classes de declividades. A escolha destas classes baseou-se principalmente na influência da declividade nos processos erosivos, onde o problema está principalmente no intervalo de 20 a 30% de declividade.

No presente trabalho, as classes de declividade obedeceram a definição estabelecida pela Embrapa (1999). Desse modo, observou-se que 34% da área da bacia predomina o relevo plano, 22% suave ondulado, 37% ondulado, e que as classes mais inclinadas de 12 a 30 somam 7%, apresentados na Figura 38. As regiões mais planas (0 – 6%) apresentam pouca capacidade de transporte devido à baixa velocidade dos fluxos d'água, apresentando assim maior capacidade de infiltração, mas quando se tem uma área com terrenos mais inclinados (6 – 30%), o escoamento das águas atinge maior velocidade, transportando sedimentos maiores, principalmente quando estas áreas estão expostas, ficando vulneráveis as erosões. As classes de declividade estão representadas na Figura 39.

Figura 38 - Classes de declividade para a BHRM



Fonte: Autor (2019)

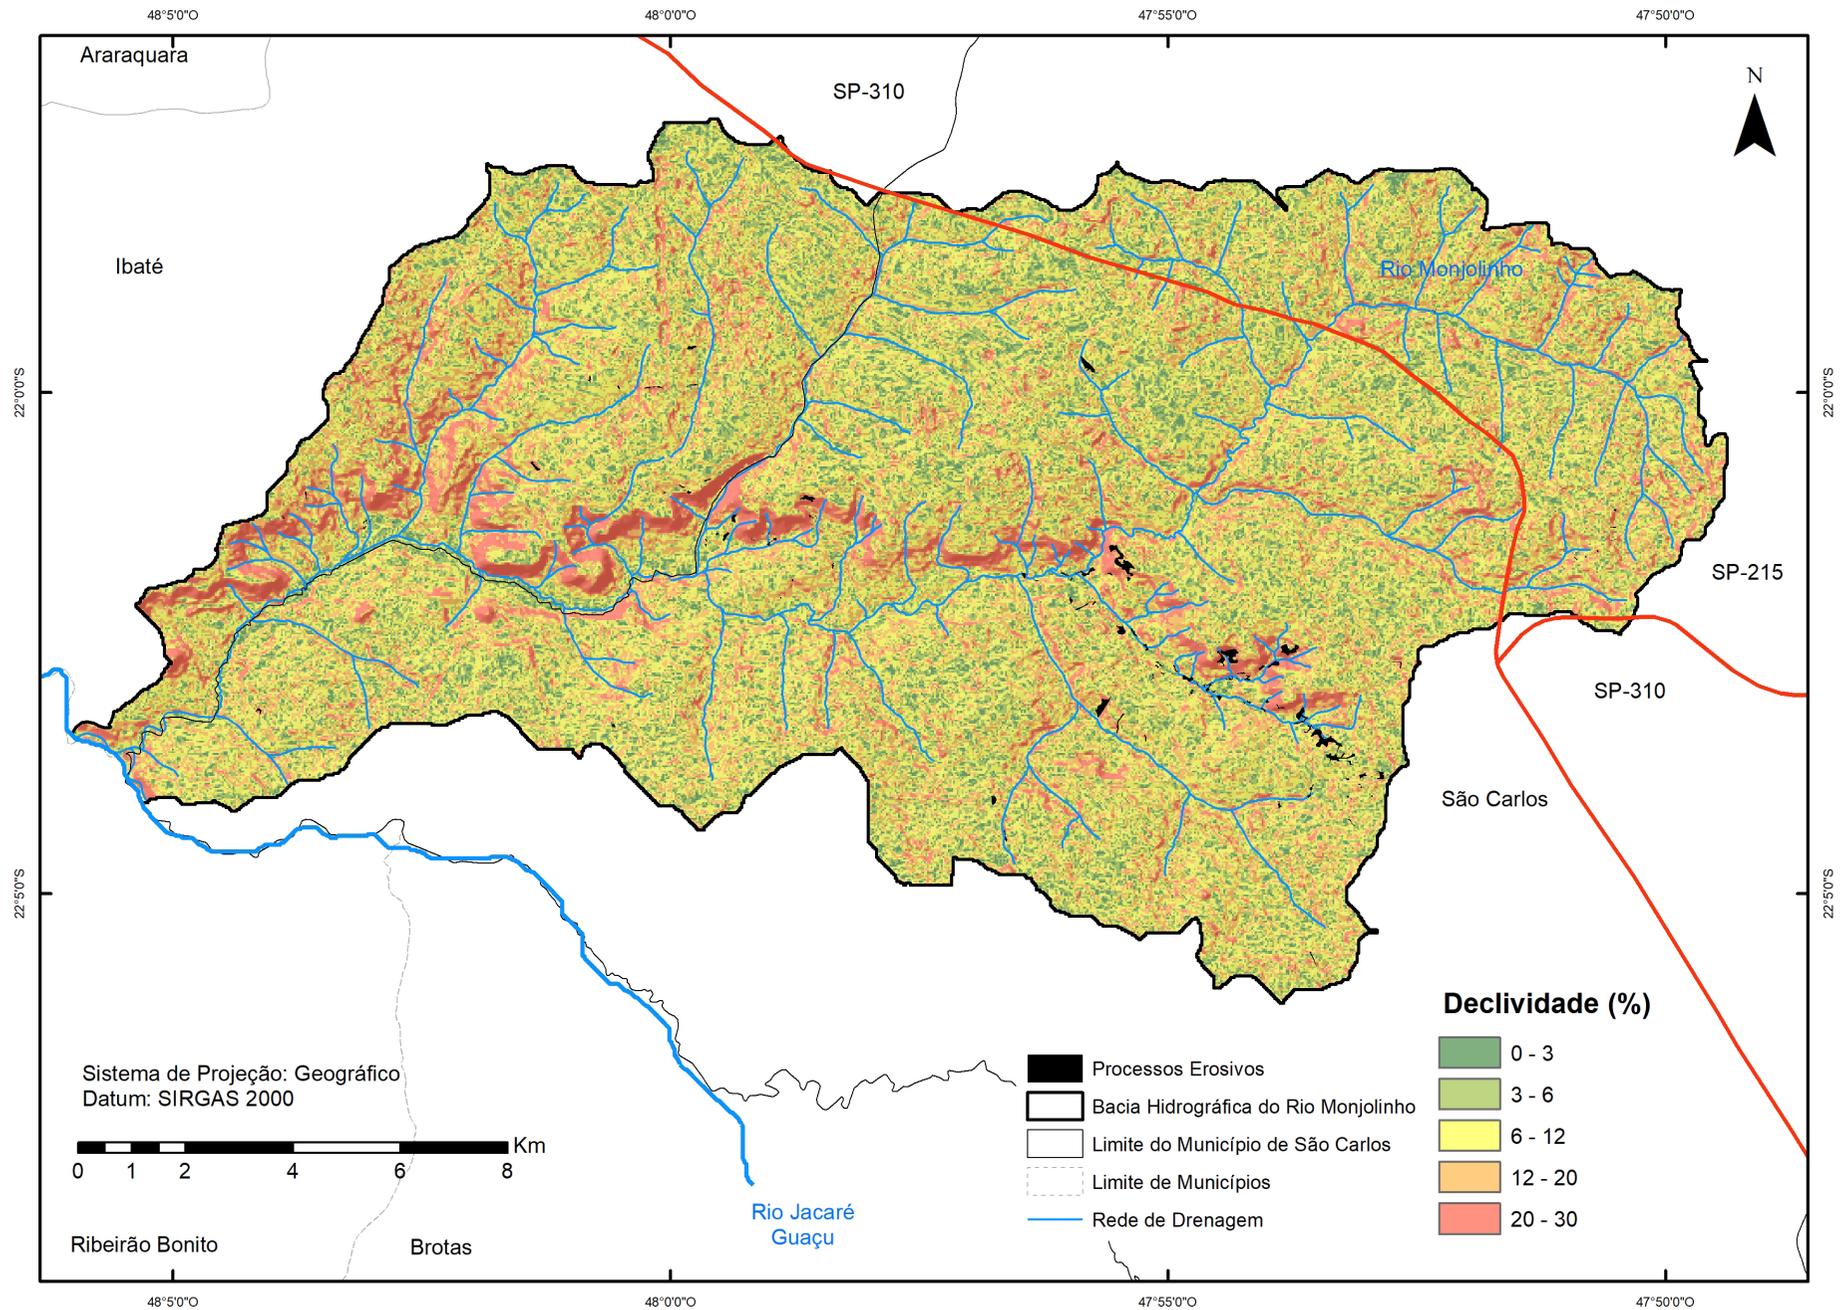


Figura 39 - Carta de Declividade BHRM

Fonte: Autor (2019)

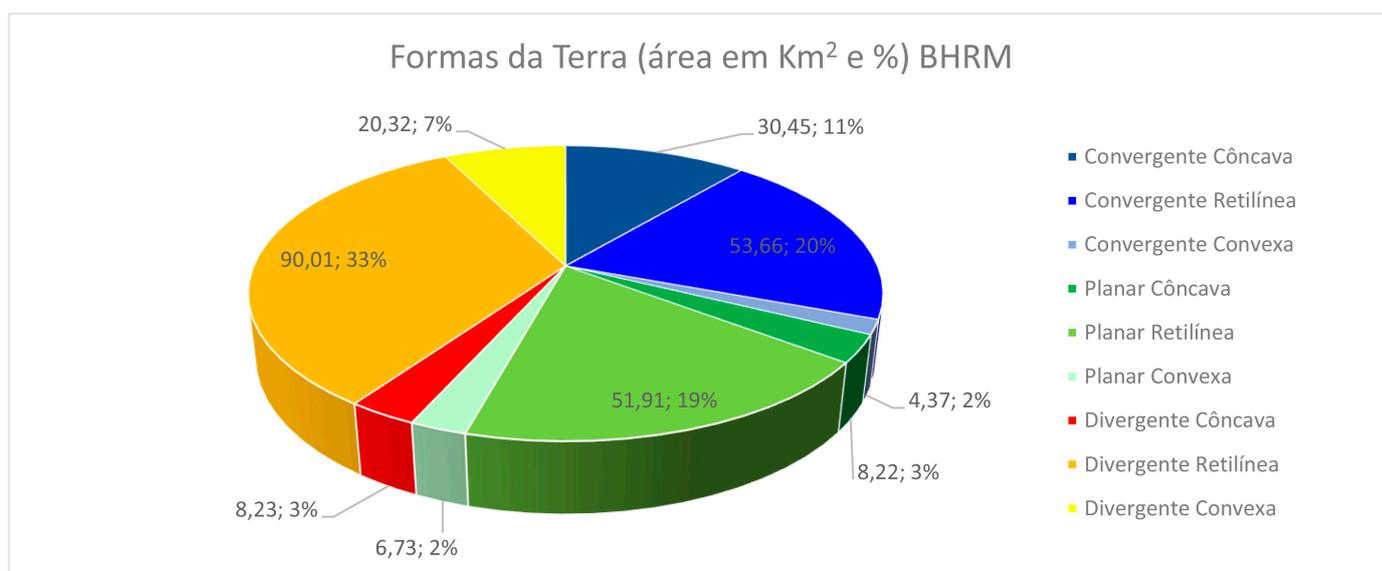
### 5.2.5 Carta de Forma do Terreno

A curvatura do terreno é uma variável de alto poder de identificação de unidades homogêneas do relevo, por referir-se à forma convexo/côncavo do terreno. Bloom (1970) reconheceu que os perfis de encostas geralmente possuem um segmento com o topo convexo e a base côncava, e que alguns perfis de encosta possuem um segmento reto entre as curvas superior e inferior.

Por tanto, os materiais são transportados declives abaixo, passando pelo segmento reto, onde tende a ser coletada nas concavidades, transportados sobre a superfície. Nesse sentido, a curvatura vertical representada como côncava, são locais de acumulação de materiais férteis, são mais antropizadas, por referir-se a um local onde todos os nutrientes são concentrados, são áreas utilizadas principalmente pela agricultura. Nas áreas de curvatura vertical convexa, os solos são menos profundos, o transporte de água favorece o processo erosivo.

A curvatura horizontal do terreno refere-se as características divergente/convergente dos fluxos. Ela também está relacionada à intensidade dos processos de migração e acúmulo de água, minerais e matéria orgânica no solo sobre a superfície. Então, a curvatura horizontal apresenta os fluxos de canais de drenagem para onde ele vai convergir, sendo que, aonde eles se convergem à velocidade da água é maior e seu escoamento superficial tem maior capacidade de transporte, podendo desencadear processos erosivos. As formas convergentes do terreno somam 33%, as formas planares 24% e as formas divergentes representam 43% (Figura, 40). Na Figura 41 é apresentado as formas do terreno na bacia hidrográfica do Rio Monjolinho.

Figura 40 - Gráfico das Formas do Terra da BHRM



Fonte: Autor (2019)

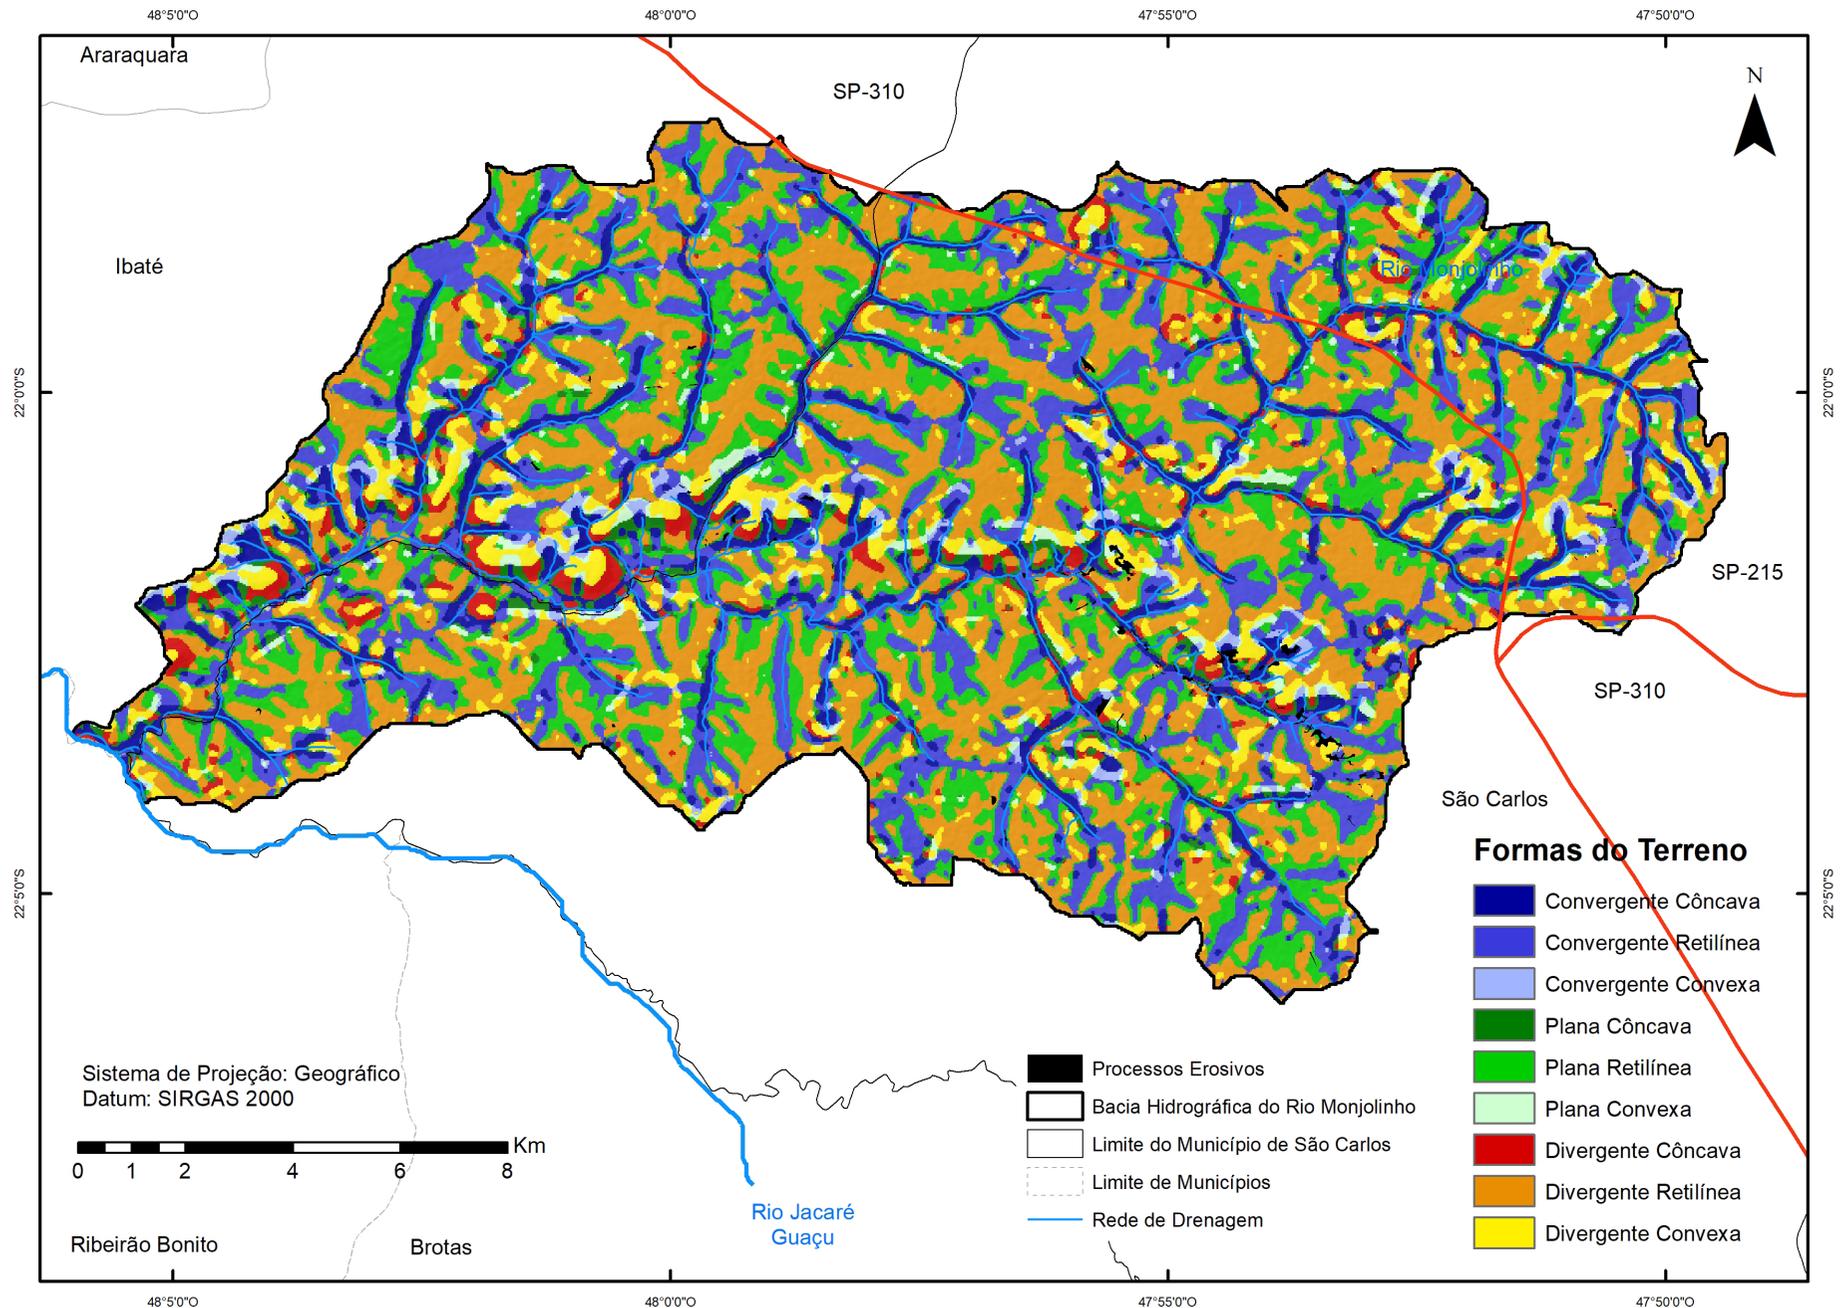


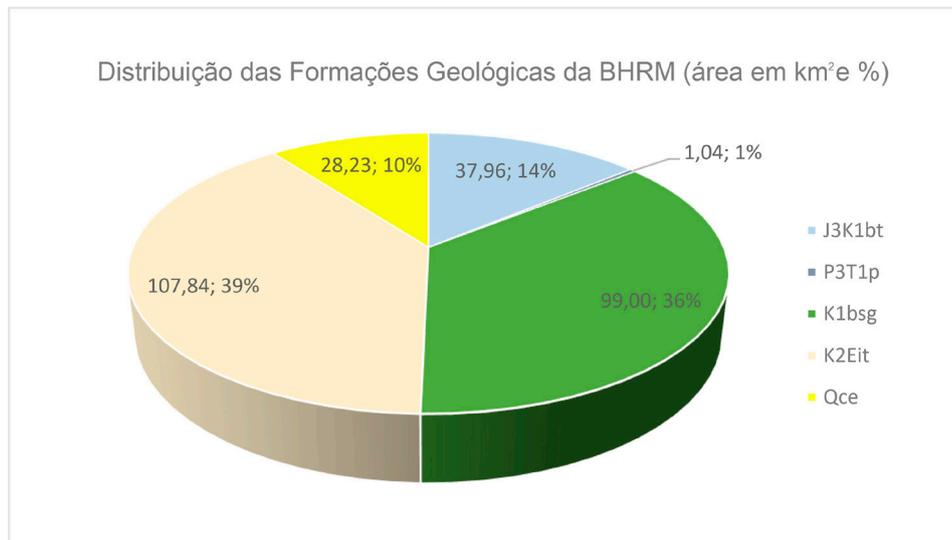
Figura 41 - Mapa de Formas do Terreno

### 5.2.6 Mapa Geológico

As formações geológicas de superfície predominantes ao longo de toda a extensão da bacia hidrográfica do Rio do Monjolinho são: Formação Serra Geral e Formação Botucatu, pertencentes ao Grupo São Bento e Formação Pirambóia, também há ocorrência de Depósitos Recentes do Quaternário. Na Figura 42 verifica-se a distribuição da área em km<sup>2</sup> e em porcentagem das unidades geológicas presentes na área de estudo. O Mapa de Formações Geológicas (Figura 43) foi produzido para a bacia hidrográfica do Rio do Monjolinho, na escala de 1:75.000.

As porcentagens referentes a cada uma das formações geológicas de superfície em relação à área total da bacia hidrográfica do rio do Monjolinho são: Formação Serra Geral (36%), Formação Botucatu (14%), Formação Pirambóia (1%), Quaternário (10%) e Formação Itaqueri (39%).

Figura 42 - Gráfico de distribuição das Formações Geológicas



Fonte: Autor (2019)

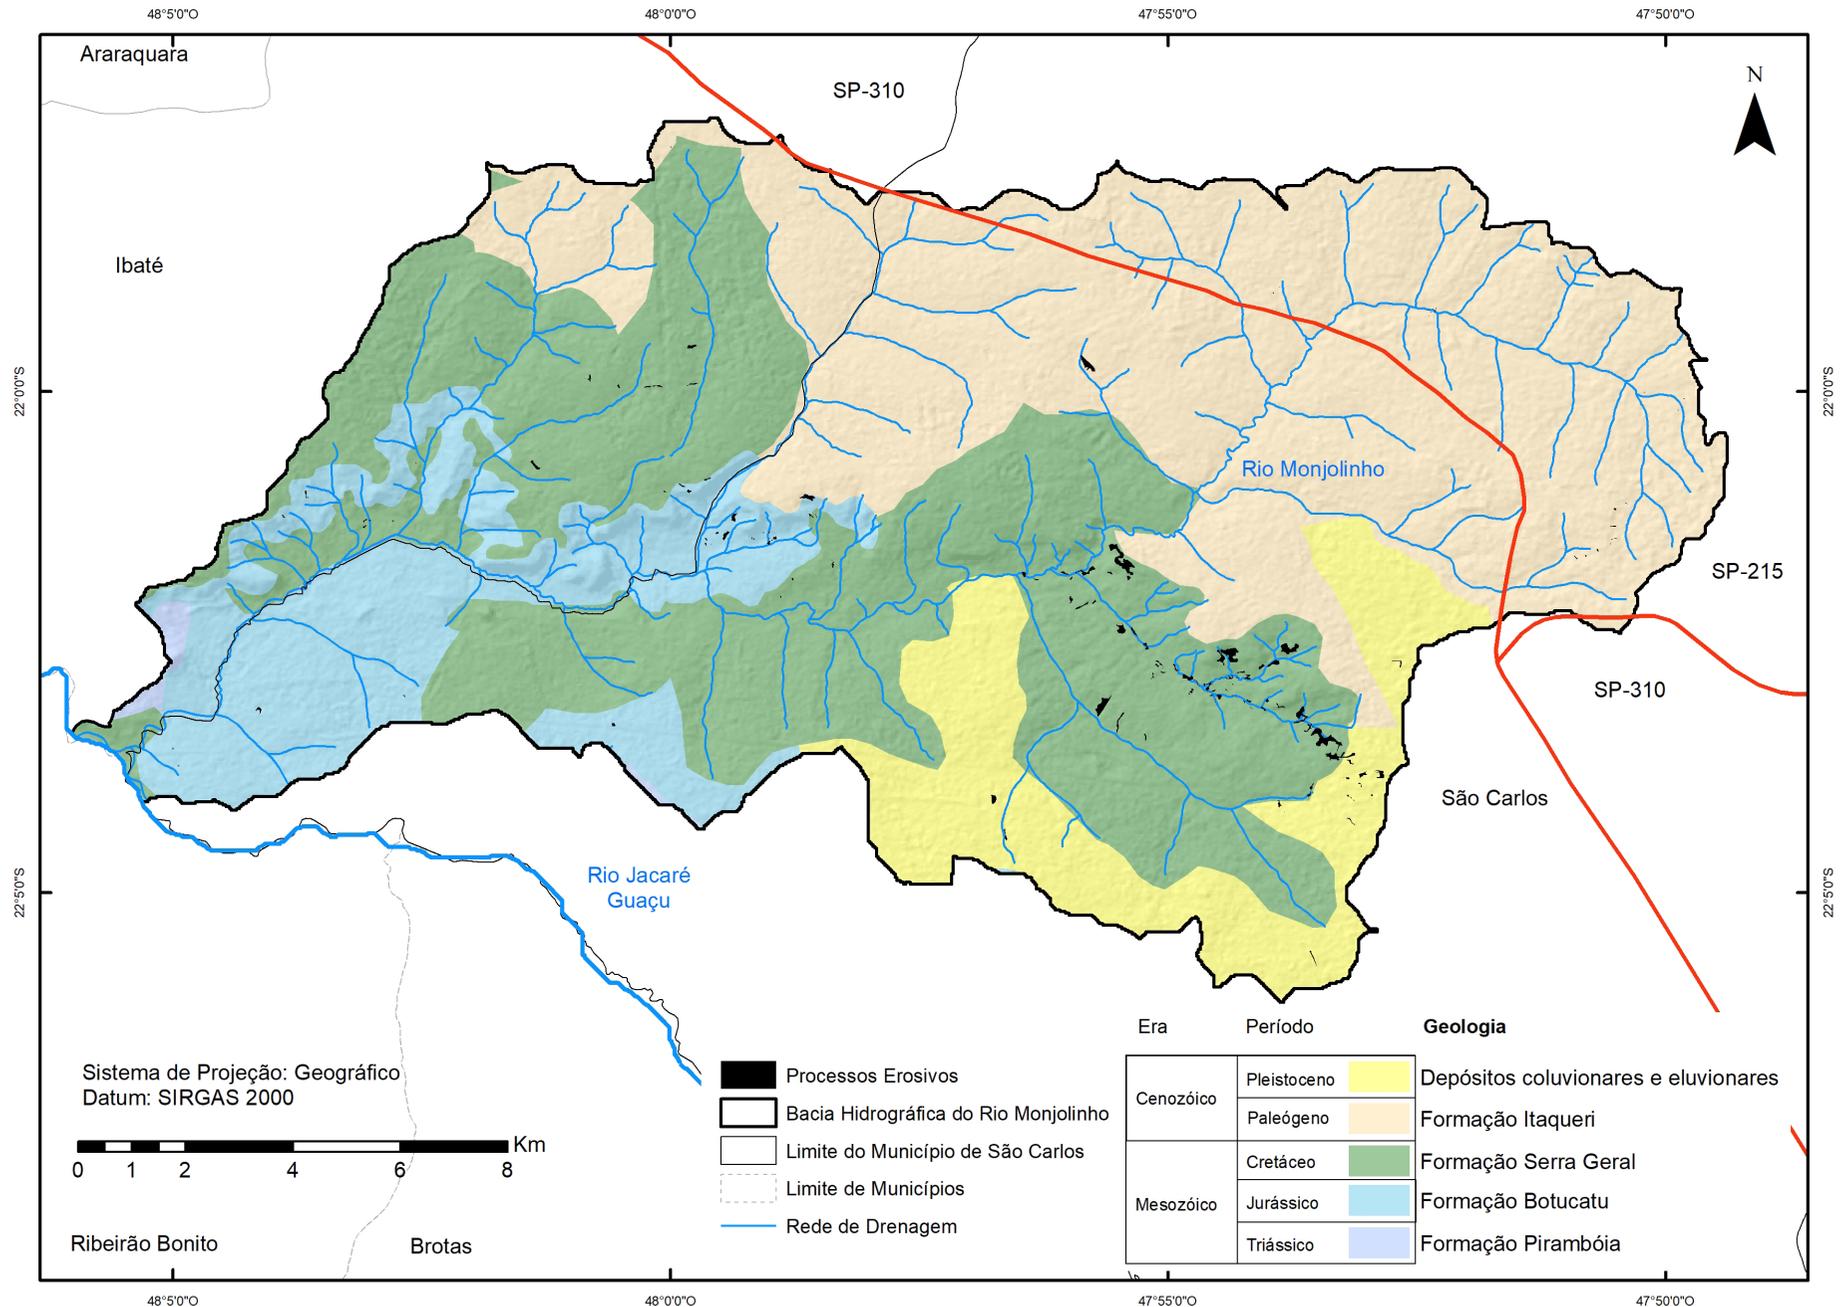


Figura 43 - Mapa Geológico BHRM

Fonte: CPRM (2008)

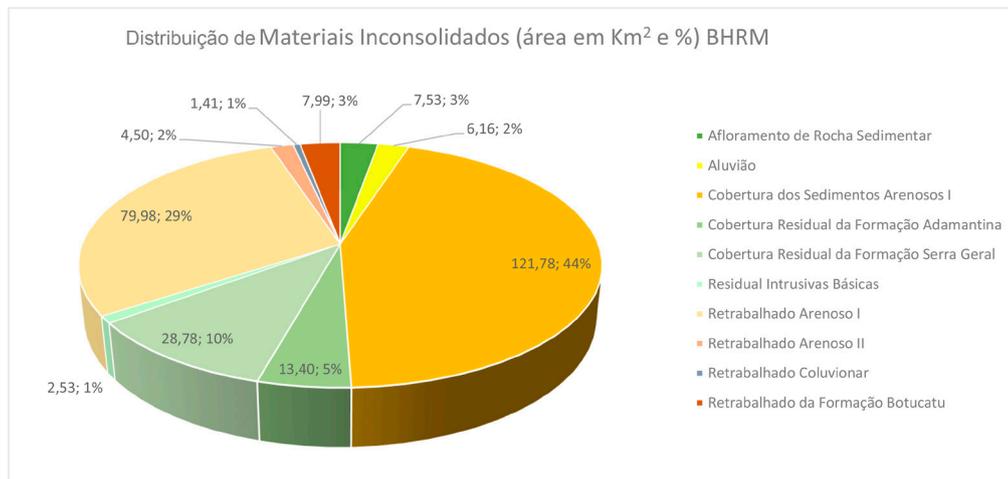
### 5.2.7 Mapa de Materiais Inconsolidados

A distribuição percentual referente a cada um dos tipos de materiais inconsolidados (Figura 44) em relação à área total da bacia são: Cobertura dos Sedimentos Arenosos I (44%), Cobertura Residual da Formação Adamantina (5%), Cobertura Residual da Formação Serra Geral (10%), Residual Intrusivas Básicas (1%), Retrabalhado Arenoso I (29%), Retrabalhado Arenoso II (2%), Retrabalhado Botucatu (3%), Retrabalhado Coluvionar (1%), Aluvião (2%) e Afloramento de Rocha Sedimentar (3%).

O Mapa de Materiais Inconsolidados (Figura 45) foi produzido para a bacia hidrográfica do rio do Monjolinho, na escala de 1:50.000. Esse documento é uma adaptação de trabalhos anteriores, mapeado por outros autores, com trabalhos de campo e ensaios em laboratórios, para obter as principais características dos materiais inconsolidados. A Tabela 5 é um compilado deste material.

Todas as características dos solos têm alguma influência no processo erosivo, umas com menos, outras com mais, como é o caso da textura dos matérias, que podem ser mais arenosos ou argilosos. Os solos arenosos tendem a ser mais erosivos, mas o comportamento mecânico dos solos argilosos pode ser parecido, na presença de grandes concentrações de água, exemplo.

Figura 44 - Gráfico representativo das porcentagens referentes a cada um dos tipos de materiais inconsolidados de ocorrência na bacia hidrográfica do rio do Monjolinho em relação à área total da bacia



Fonte: Autor (2019)

Tabela 5 - Apresentação dos dados das principais características geotécnicas

Ponto	Granulometria (% que passa)			Massa Específica (g/cm <sup>3</sup> )			Índice de Vazio (e)	Unidade
	4,76mm	0,075mm	0,002mm	r	r s	r d		
LM28	100	10	3	-	2,62	1,71	0,53	Botucatu
LM29	100	15	4	-	2,64	1,70	0,74	Botucatu
LM30	100	12	4	-	2,63	1,72	0,72	Botucatu
LM31	100	20	5	-	2,64	1,69	0,62	Botucatu
LM32	100	5	1	-	2,64	1,69	0,68	Botucatu
LM34	100	26	18	-	2,63	1,59	0,83	Retr. Aren. I
LM35	100	23	12	-	2,64	1,78	0,82	Retr. Aren. I
LM36	100	30	14	-	2,63	1,77	0,78	Retr. Aren. I
LM37	100	22	10	-	2,63	1,79	0,85	Retr. Aren. I
LM39	100	75	53	-	2,83	1,14	1,53	S. Geral
LM40	100	80	60	-	2,91	1,38	1,56	S.Geral
LM42	100	45	30	-	2,64	1,64	0,98	Retr. Aren. III
LM43	100	50	35	-	2,64	1,71	1,43	Retr. Aren. III
LM44	100	82	65	-	2,66	1,26	1,51	S. Geral
LM45	100	22	11	-	2,63	1,75	0,78	Retr. Aren. I
LM46	100	75	56	-	2,73	1,50	1,56	S. Geral
LM50	100	69	55	-	2,65	1,59	1,49	S. Geral
LM51	100	35	20	-	2,69	1,45	0,75	Retr. Aren. II
LM52	100	78	59	-	2,83	1,53	1,58	S. Geral
LM53	100	25	18	-	2,63	1,75	1,42	Retr. Aren. I
LM54	100	75	52	-	2,85	1,49	1,32	S. Geral
LM55	100	27	21	-	2,64	1,72	1,49	Retr. Aren. I
LM56	100	80	60	-	2,92	1,54	1,12	S. Geral
LM74	100	87	55	-	2,75	1,55	0,98	S. Geral
LM77	100	10	3	-	2,64	1,73	0,70	Botucatu
LM91	100	85	54	-	2,79	1,55	1,45	S. Geral
LM101	100	65	45	-	2,69	1,52	1,56	S. Geral
LM132	100	23	10	-	2,65	1,57	0,82	Retr. Aren. I
LM146	100	67	46	-	2,72	1,46	0,89	S. Geral
LM148	100	21	10	-	2,65	1,78	0,85	Retr. Aren. I
LM149	100	15	12	-	2,63	1,54	0,78	Retr. Aren. I
LM156	100	23	12	-	2,63	1,64	0,72	Retr. Aren. I
LM157	100	29	20	-	2,63	1,43	0,59	Retr. Aren. I
LM158	100	25	10	-	2,64	1,49	0,74	Retr. Aren. I
LN141	100	17	14	1,70	2,63	1,59	0,65	S. Geral
LN159	100	26	20	1,48	2,65	1,36	0,95	Retr. Aren. I
LN166	100	29	22	1,69	2,64	1,36	0,71	Retr. Aren. I
LN202	100	45	30	1,49	2,64	1,54	1,10	Retr. Aren. III
LN206	100	53	38	1,43	2,67	1,26	1,34	Retr. Aren. III
LN428	100	14	13	1,69	2,62	1,60	0,64	Retr. Aren. I
LN455	100	3	2	1,71	2,62	1,65	0,59	Botucatu
LN495	100	66	45	1,53	2,86	1,14	1,51	S.Geral
LN496	100	40	31	1,52	2,66	1,26	1,11	Bauru
LN504	100	31	21	1,52	2,68	1,35	0,98	Bauru
LN507	100	50	40	1,41	2,65	1,16	1,28	Retr. Aren. III
LN508	100	20	13	1,75	2,64	1,59	0,66	Botucatu
LN509	100	10	4	1,83	2,61	1,73	0,51	Botucatu
LN516	100	27	-	-	-	-	-	Retr. Aren. I

Continuação

LN517	-	-	-	1,58	2,65	1,41	0,88	Retr. Aren. I
LZ01	100	50,32	39	-	2,68	1,67	-	Retr. Aren. III
LZ02	100	52,62	42	-	2,68	1,56	-	Retr. Aren. III
LZ03	100	50,62	40	-	2,65	1,60	-	Bauru
LZ04	100	40,99	29	-	2,64	1,80	-	Bauru
LZ05	100	46	31,50	-	2,68	1,83	-	Bauru
LZ06	100	64,80	39	-	2,89	1,75	-	Bauru
LZ07	95,89	54,27	41,51	-	2,77	1,6	-	Bauru
LZ08	100	43,03	27	-	2,67	1,8	-	Bauru
LZ10	100	39,20	-	-	2,7	1,9	-	Retr. Aren. III
LZ11	100	87	56	-	2,95	1,4	-	S. Geral
LZ12	100	46	31,50	-	2,81	1,83	-	Bauru
LZ13	100	65,84	23	-	3,11	1,38	-	Bauru
LZ14	100	41,40	-	-	2,68	1,85	-	Bauru
LZ15	100	18,60	15	-	2,72	1,99	-	Bauru
LZ16	100	34,50	21	-	2,63	1,97	-	Retr. Aren. II
LZ17	100	35,66	20	-	2,63	1,97	-	Retr. Aren. II
LZ18	100	84,83	51	-	3,09	1,51	-	Retr. Aren. II
LZ19	100	17,05	12	-	2,67	2	-	S. Geral
LZ20	100	15,36	11	-	2,68	2,05	-	S. Geral
LZ21	100	7,14	3,4	-	2,68	1,84	-	Retr. Aren. I
LZ22	100	39	26	-	2,71	1,81	-	Bauru
LZ23	100	30,40	16	-	2,72	1,92	-	Retr. Aren. II
LZ24	100	46,75	33	-	2,71	1,76	-	Bauru
LZ25	100	62	38	-	2,73	1,56	-	Retr. Aren. II
LZ26	100	42,70	27	-	2,71	1,86	-	Retr. Aren. II
LZ27	100	45,24	37	-	2,7	1,74	-	Bauru
LZ28	100	12,07	3	-	2,63	1,87	-	Bauru
LZ29	100	41,82	31	-	2,72	1,89	-	Botucatu
LZ30	100	29,94	17	-	2,76	1,92	-	Retr. Aren. I
LZ31	100	43,28	31,8	-	2,74	1,95	-	Retr. Aren. I
LZ32	100	28,53	23	-	2,66	1,91	-	S. Geral
LZ33	100	32,6	23	-	2,67	1,93	-	Botucatu
LZ34	100	32,40	24	-	2,76	1,94	-	Botucatu
LZ35	100	16,21	10,2	-	2,64	1,94	-	Botucatu
LZ36	100	35,20	26	-	2,68	1,82	-	Botucatu
LZ37	100	14,31	9,80	-	2,64	1,96	-	Botucatu
LZ38	100	36,63	19	-	2,64	1,79	-	Retr. Aren. I
LZ39	100	21,04	15	-	2,64	1,97	-	Retr. Aren. I
LZ41	100	89,27	70	-	2,94	1,37	-	Botucatu
LZ42	100	43,66	30,15	-	2,65	1,7	-	Bauru
LZ43	100	69,18	-	-	2,66	1,62	-	Retr. Aren. III
LZ44	100	59	-	-	2,65	1,59	-	Retr. Aren. III
LZ45	100	70,55	46,20	-	2,87	1,52	-	S. Geral
LZ46	100	65,88	46	-	2,83	1,63	-	S. Geral
LZ48	100	13,42	9	-	2,63	1,94	-	Botucatu
LZ49	100	35	-	-	2,76	1,96	-	Retr. Aren. I
LZ50	100	22,02	16	-	2,66	1,89	-	S. Geral
LZ54	100	17,05	11,60	-	2,64	1,52	-	Retr. Aren. I
LZ56	100	79	-	-	2,94	1,49	-	Retr. Aren. I
LZ58	100	85,73	69	-	2,94	1,57	-	S. Geral

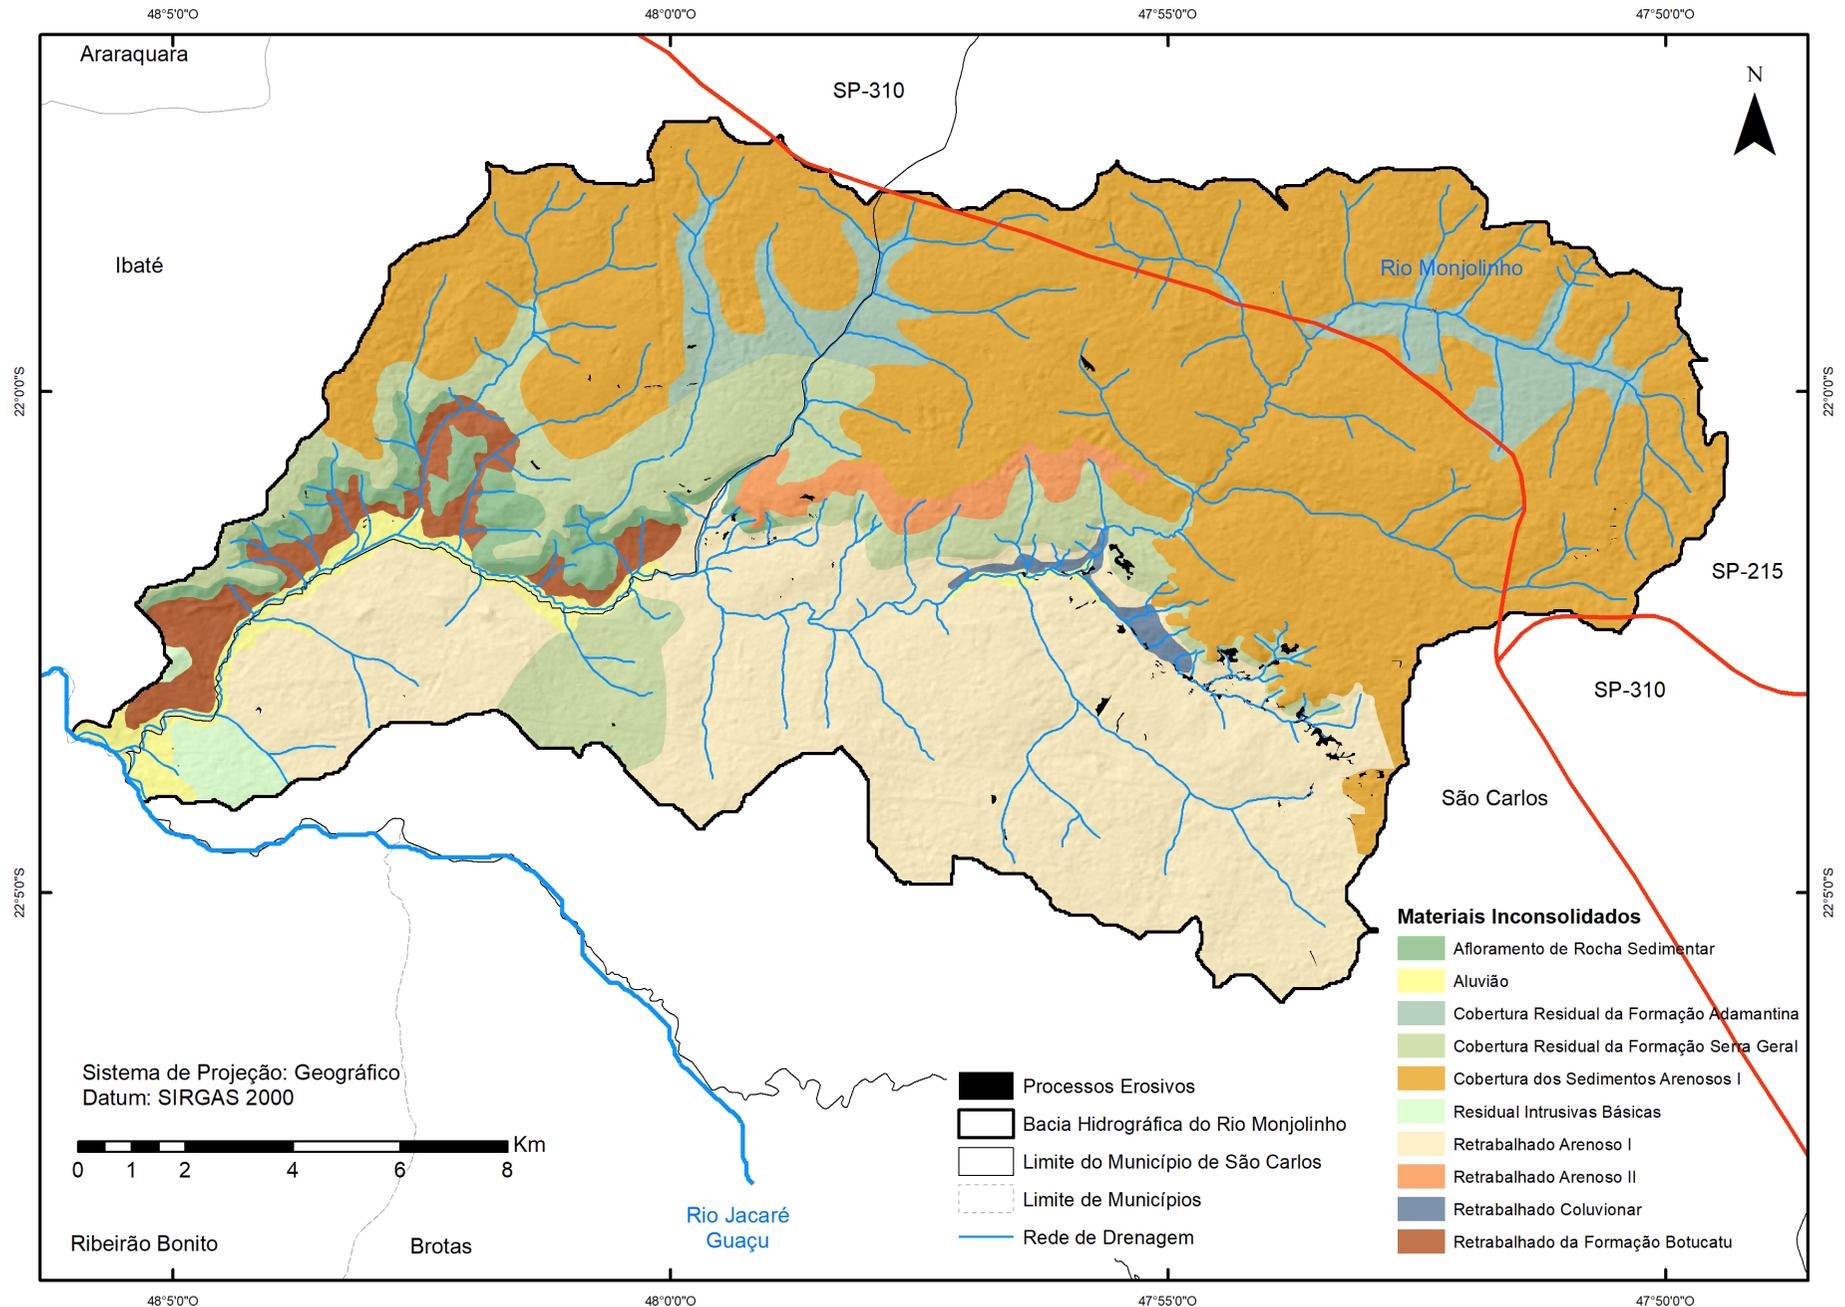


Figura 45 - Mapa de Materiais Inconsolidados BHRM

Adaptação: Campanelli (2012); Failache (2018)

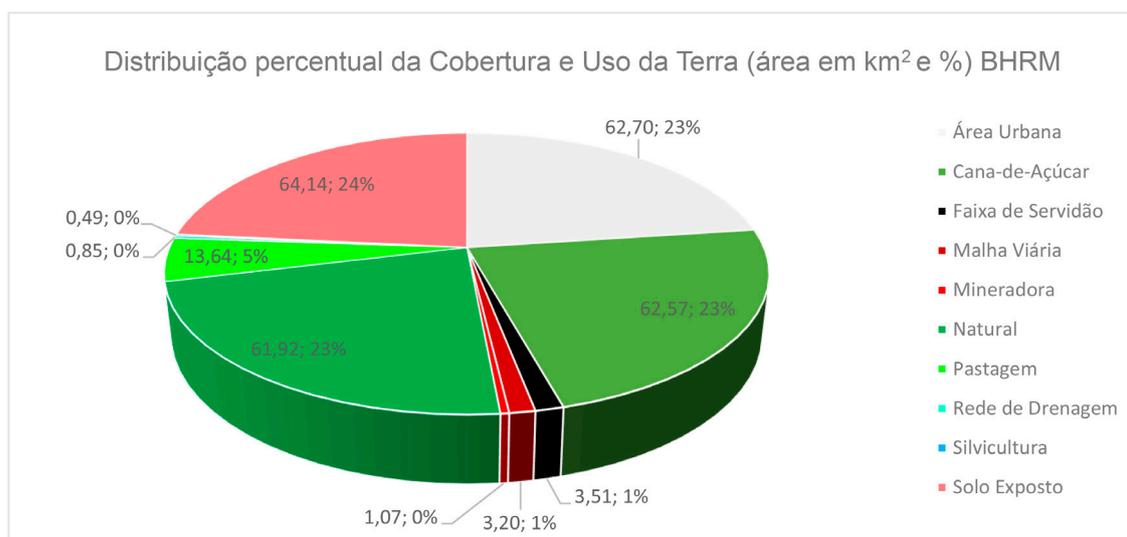
### 5.2.8 Mapa de Cobertura e Uso da Terra

Um dos grandes problemas das áreas urbanizadas é organizar o território buscando sempre seu potencial, controlar a densidade populacional e a ocupação do solo de maneira planejada, melhorar os deslocamentos e meios de mobilidade, minimizando o conflito e desse modo buscando preservar o meio ambiente. O uso da terra não só, afeta na compactação e/ou impermeabilização do solo nas camadas superficiais, mas tem relação direta com a sua capacidade de infiltração. O mapa de uso ajuda a identificar as atividades no local e no planejamento do território.

O mapa de cobertura e uso da terra da bacia hidrográfica do rio Monjolinho foi elaborado a partir da interpretação da imagem de satélite *Landsat 8* e resultou em 10 classes de atividades. As porcentagens referentes (Figura 46) a cada uma das formas de uso em relação à área total da bacia são: área urbano (23%), cana-de-açúcar (23%), pastagem (5%), vegetação natural (23%) (principalmente ao longo dos cursos d'água), solo exposto (24%) (são áreas decorrentes de manejo agrícola), faixa de servidão (1%), malha viária (1%), mineração, malha viária e a rede de drenagem representam menos de 1%.

O documento cartográfico gerado das formas de cobertura e uso da terra (Figura 47), permite ver a distribuição espacial das classes atribuídas, e identificar quais são os principais usos na área de estudo e a influência que elas exercem sobre os processos erosivos, verificou-se que aproximadamente 50% da área é voltada para o cultivo de cana-de-açúcar, onde parte do período produção o solo encontra-se exposto, acelerando esse processo de erosão. A área urbana é 23% do uso, com grande parte do solo impermeabilizado, outro fator agravante.

Figura 46 - Gráfico das porcentagens referentes a cada uma das formas de cobertura e uso da terra



Fonte: Autor (2019)

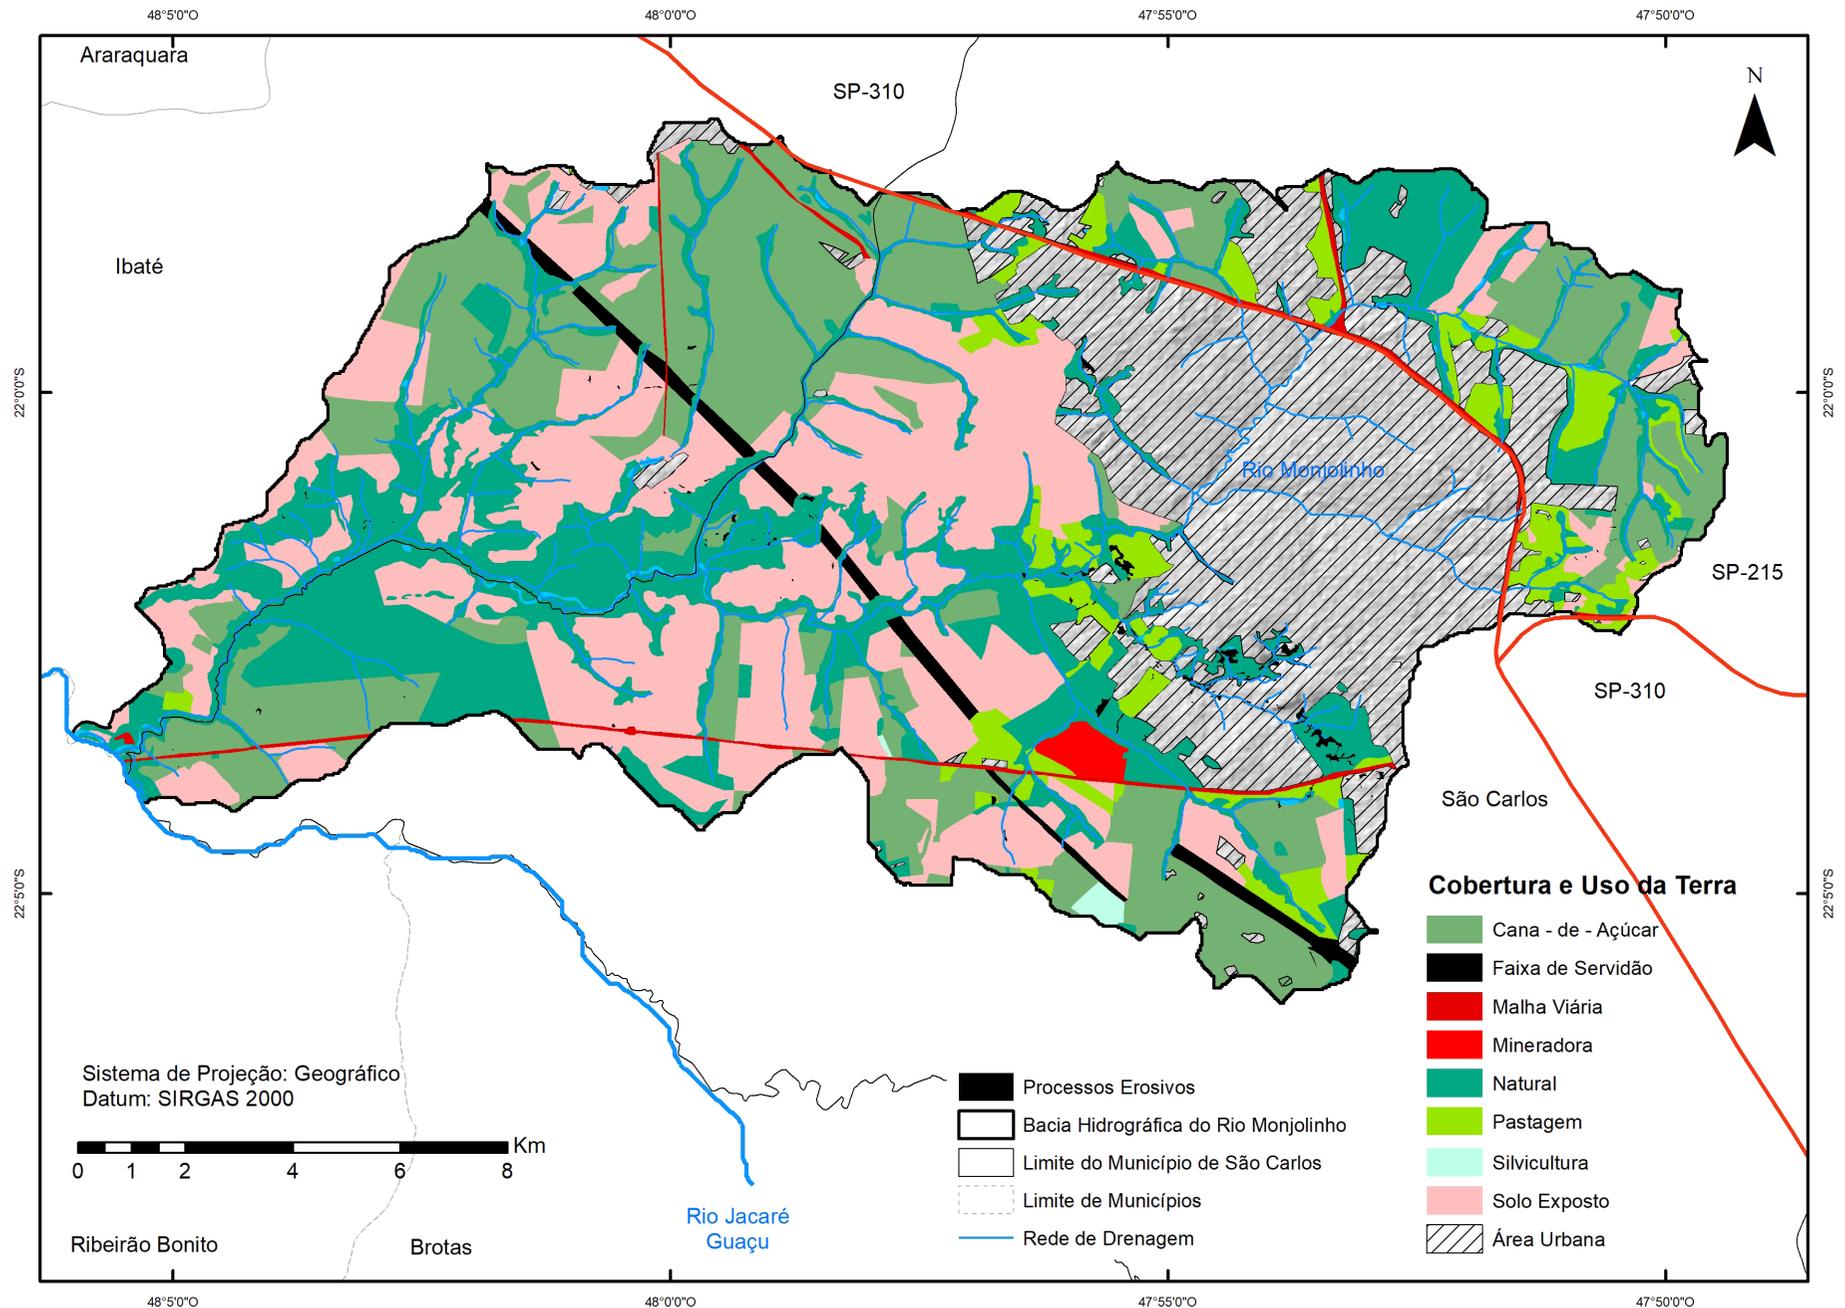


Figura 47 - Mapa de Cobertura e Uso da Terra BHRM

Fonte: Autor (2019)

### 5.2.9 Mapa de Processos Erosivos

O mapa de processos erosivos foi elaborado em três etapas, a primeira foi identificar por meio de interpretação visual de imagem do satélite *Sentinel-2* os processos erosivos que ocorrem na bacia hidrográfica em estudo. Foram identificados ao total 131 processos, em sua maioria próximos à rede de drenagem. Foram gerados os polígonos com coordenadas e a área de cada um. A etapa a seguir foi a verificação em campo para validar a ocorrência, deixando banco de dados mais consistente. A verificação foi feita em aproximadamente 30% dos casos, todos confirmando. A última etapa foi elaborar de maneira aleatória quais dados dos mapas de atributos e o de processos erosivos que seriam utilizados para o treinamento.

Em sua maioria encontram-se dentro do perímetro urbano de São Carlos, são processos provocados pela urbanização, consequência da retirada da vegetação natural, impermeabilização do solo, obras de drenagem ineficientes e ocupações irregulares, como está ilustrado na Figura 48, com a sobreposição de polígonos dos processos erosivos na cor vermelha sobre a imagem de satélite.

Na Tabela 6 é mostrado por meio do cálculo da taxa de frequência, como os processos erosivos estão distribuídos por classe de cada um dos atributos. A taxa de frequência foi calculada pela razão entre a ocorrência dos processos erosivos e a área total de cada classe de atributo, baseado na técnica de Lee & Pradhan (2006).

Um modelo de taxa de frequência é relação entre o evento (processo erosivo) e os fatores/atributos relacionados a este. Portanto, para se prever um evento, calcular, determinar quais as áreas mais susceptíveis, foi assumido que o processo erosivo só ocorre quando determinados fatores associados, ocorrem nas mesmas condições. Partindo desse pressuposto foi utilizado o cálculo da taxa de frequência para representar a distribuição quantitativamente.

A relação entre os atributos condicionantes e os processos erosivos, aponta que nas declividades acima de 30% a probabilidade de ocorrer é alto, a razão é 4,02, o mesmo acontece para a Formação Pirambóia que representa 0,40% da área, mas a razão é 5,75. Os materiais inconsolidados, Retrabalhado Arenoso I, Retrabalhado Arenoso II e Retrabalhado Coluvionar juntos possuem o maior número de processos, são 77 de 131.

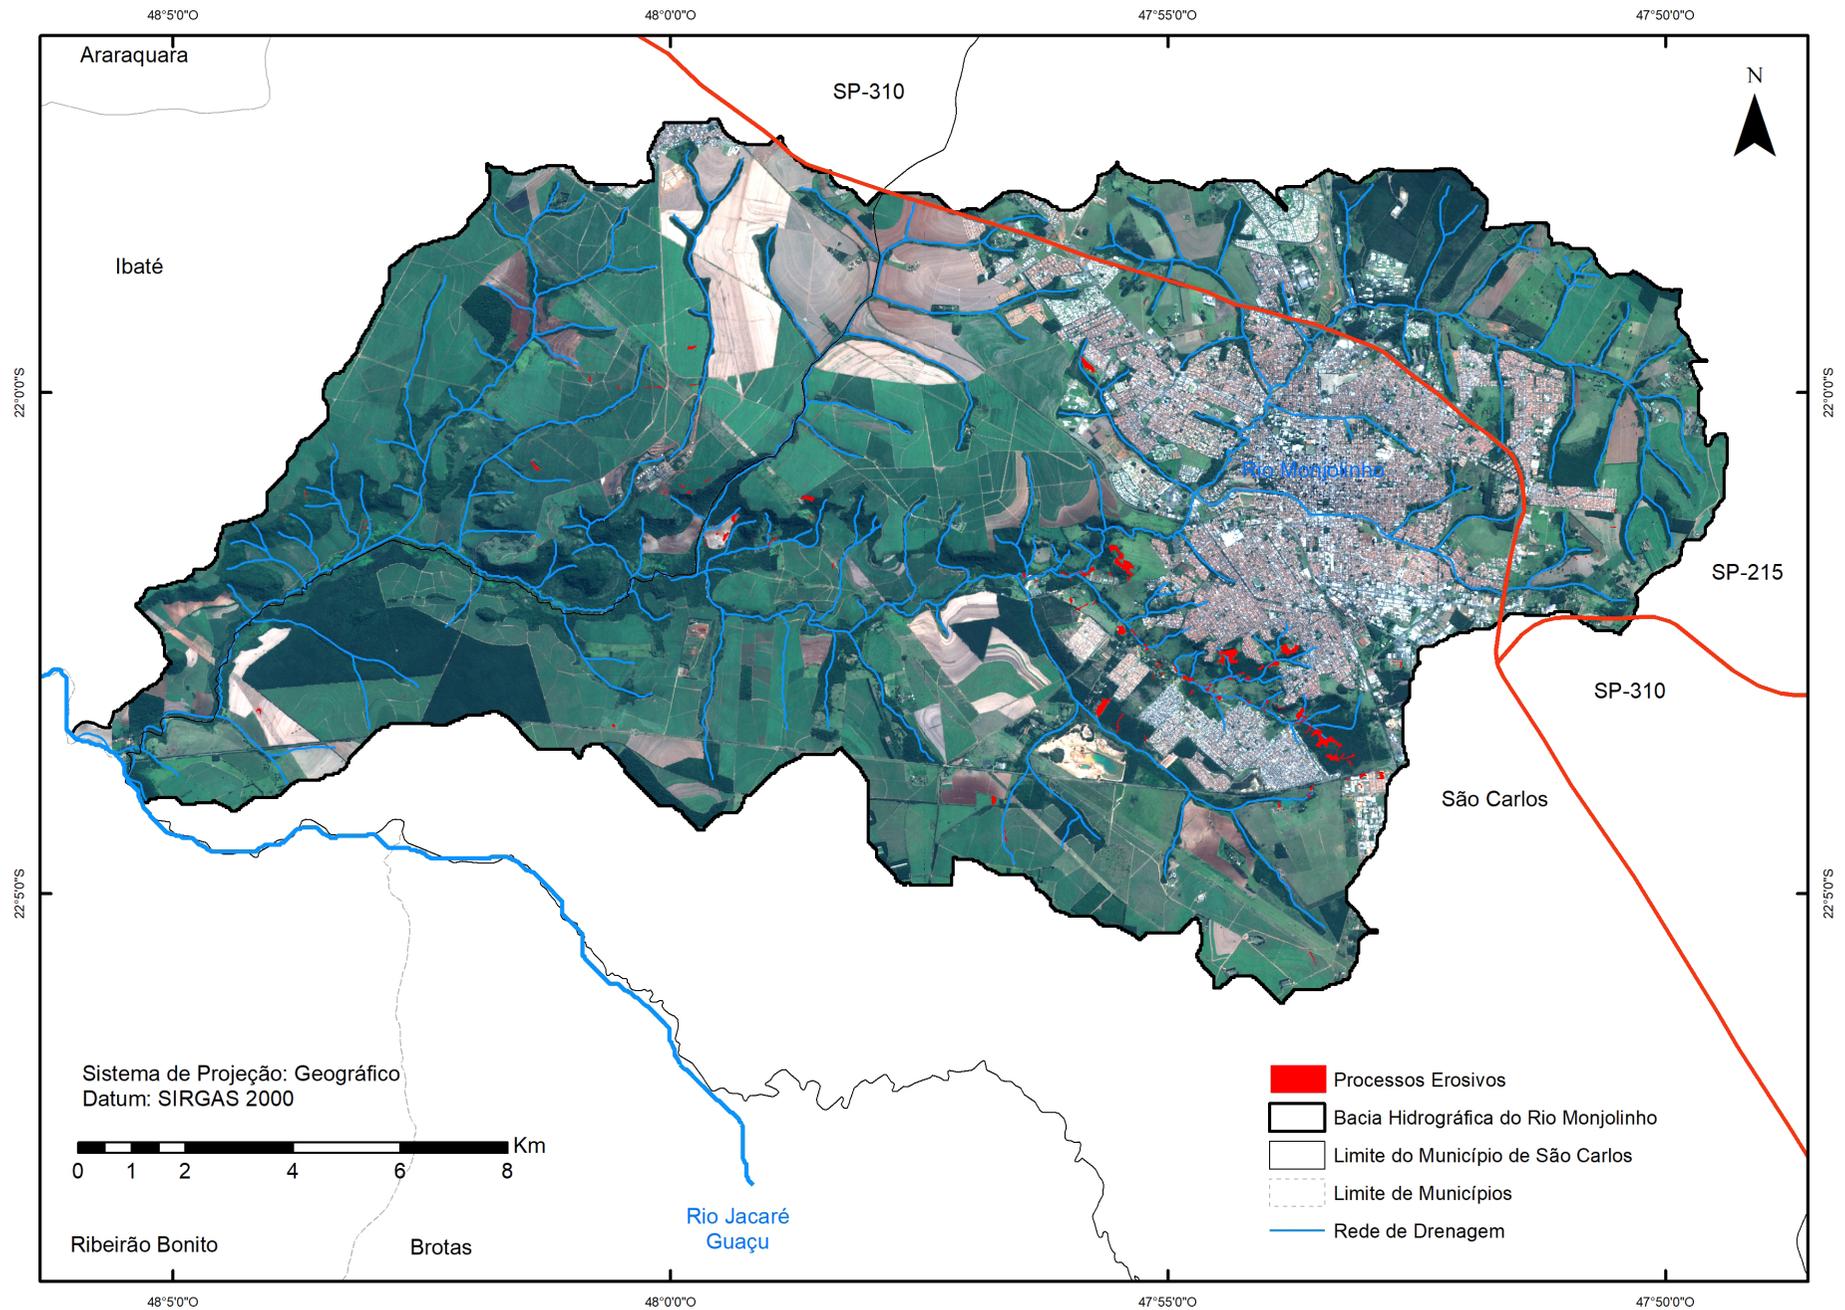


Figura 48 - Mapa de Processos Erosivos BHRM

Fonte: Autor (2019)

Tabela 6 - Distribuição dos processos erosivos por classe de atributo e cálculo da taxa de frequência dos processos erosivos

<b>Atributo</b>	<b>Classe</b>	<b>Pontos de Processos Erosivos</b>	<b>Pontos de Processos Erosivos (%) <sup>(a)</sup></b>	<b>Número de Pixel por Classe</b>	<b>Número de Pixel por Classe (%) <sup>(b)</sup></b>	<b>Taxa de Frequência <sup>(a/b)</sup></b>
<b>Elevação</b>	540 - 620	14	10,69	38160	12,46	0,86
	621 - 700	21	16,03	37457	12,23	1,31
	701 - 780	54	41,22	71245	23,25	1,77
	781 - 860	29	22,14	118953	38,83	0,57
	> 860	13	9,92	40563	13,24	0,75
<b>Declividade</b>	< 2	2	1,53	9108	2,97	0,51
	2 - 5	24	18,32	47347	15,45	1,19
	5 - 10	34	25,95	106239	34,68	0,75
	10 - 15	29	22,14	78095	25,49	0,87
	15 - 20	24	18,32	37560	12,26	1,49
	20 - 30	6	4,58	21042	6,87	0,67
	> 30	12	9,16	6987	2,28	4,02
<b>Forma da Terra</b>	Convergente-Côncava	45	34,35	41100	13,41	2,56
	Convergente-Retilínea	26	19,85	88847	29,00	0,68
	Convergente-Convexa	4	3,05	9541	3,11	0,98
	Planar-Côncava	4	3,05	5610	1,83	1,67
	Planar-Retilínea	16	12,21	40108	13,09	0,93
	Planar-Convexa	4	3,05	8545	2,79	1,09
	Divergente-Côncava	4	3,05	13545	4,42	0,69
	Divergente-Retilínea	23	17,56	53261	17,38	1,01
	Divergente-Convexa	5	3,82	45821	14,96	0,26
<b>Geologia</b>	J3K1bt	22	16,79	42904	14,00	1,20
	K1_beta_sg	73	55,73	112172	36,61	1,52
	K2Eit	18	13,74	118170	38,57	0,36
	P3T1p	3	2,29	1220	0,40	5,75
	Qce	15	11,45	31912	10,42	1,10

Continua

Continuação

<b>Materiais Incosolidados</b>	Afloramento de Rocha Sedimentar	3	2,29	8656	2,83	0,81
	Aluvião	5	3,82	7057	2,30	1,66
	Cobertura dos Sedimentos Arenosos I	26	19,85	133956	43,72	0,45
	Cobertura Residual da Formação Adamantina	4	3,05	15301	4,99	0,61
	Cobertura Residual da Formação Serra Geral	15	11,45	32370	10,57	1,08
	Residual Intrusivas Básicas	1	0,76	2870	0,94	0,81
	Retrabalhado Arenoso I	69	52,67	90573	29,56	1,78
	Retrabalhado Arenoso II	4	3,05	5022	1,64	1,86
	Retrabalhado Coluvionar	4	3,05	1586	0,52	5,90
	Retrabalhado da Formação Botucatu	0	0,00	1586	0,52	0,00
<b>Cobertura e Uso da Terra</b>	Natural	37	28,24	67008	21,87	1,29
	Represa	0	0,00	470	0,15	0,00
	Pastagem	8	6,11	14845	4,85	1,26
	Área Urbana	44	33,59	65185	21,28	1,58
	Mineradora	0	0,00	1154	0,38	0,00
	Cana-de-açúcar	15	11,45	77410	25,27	0,45
	Solo Exposto	26	19,85	69451	22,67	0,88
	Silvicultura	0	0,00	536	0,17	0,00
	Infraestrutura Urbana	1	0,76	2615	0,85	0,89
	Faixa de Servidão	0	0,00	3783	1,23	0,00
	Malha Viária	0	0,00	3487	1,14	0,00
	Rio	0	0,00	434	0,14	0,00
<b>Pluviométrico</b>	75 - 105	6	4,58	47109	15,38	0,30
	105 - 125	46	35,11	117702	38,42	0,91
	125 - 150	72	54,96	92767	30,28	1,82
	150 - 175	6	4,58	44874	14,65	0,31
	175 - 200	1	0,76	3926	1,28	0,60
<b>(a) Número de ocorrências</b>	131					
<b>(b) Total de pixel</b>	306378					

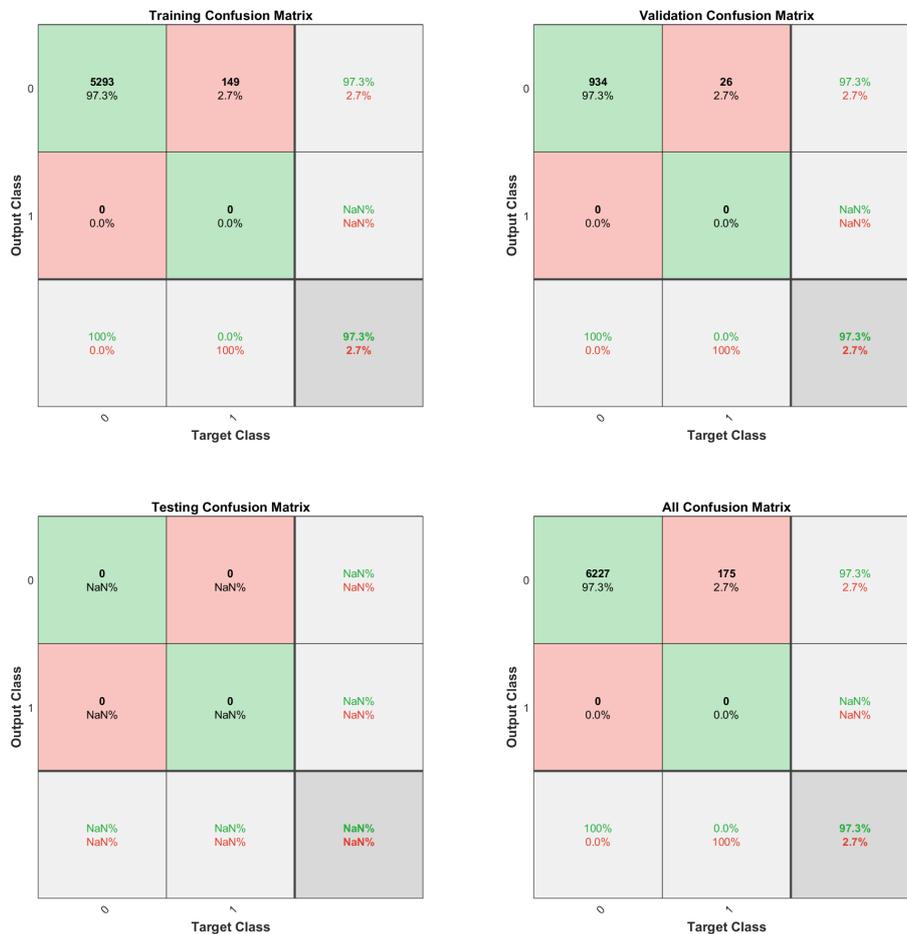
### 5.3 Resultados dos treinamento das Redes Neurais Artificiais

Os resultados a seguir são apresentados em duas etapas, a primeira são dos treinamentos das redes *Perceptron* com uma camada, da *Perceptron* Multicamada e ANFIS, com os dados crus e normalizados entre 0 e 1. Em um segundo momento o conjunto de dados passou por uma nova etapa de balanceamento e aplicado a rede neural *Perceptron* com uma camada com dois conjuntos de testes.

#### 5.3.1 Treinamento da RNA Perceptron com uma camada

O treinamento da rede neural utilizando-se uma camada apresentou resultados com 97,3% de acerto na fase de treinamento e na de validação, conforme apresentado na Figura 49, para os valores verdadeiros positivos, onde 5.293 pixels que não possuem erosão foram classificados corretamente; 2,7% foram considerados valores falsos positivos, ou seja, locais que não tem erosão foram classificados como se houvessem processos erosivos. Observa-se que não houve classificação, tanto para os casos de valores falsos positivos e falsos negativos, provavelmente devido ao desbalanceamento das classes no conjunto de dados. Esse treinamento foi realizado considerando-se toda área da bacia hidrográfica do Rio Monjolinho.

Figura 49 - Matriz de confusão RNA



Nas Figuras 50 e 51, são apresentadas as curvas de evolução dos erros de treinamento, de teste e validação, considerando ao longo das épocas de treinamento. No entanto, nem sempre o erro de validação segue este padrão de comportamento, devendo cada caso ser analisado individualmente. .

Figura 50 - Curvas dos erros de treinamento e validação com 22 épocas de treinamento

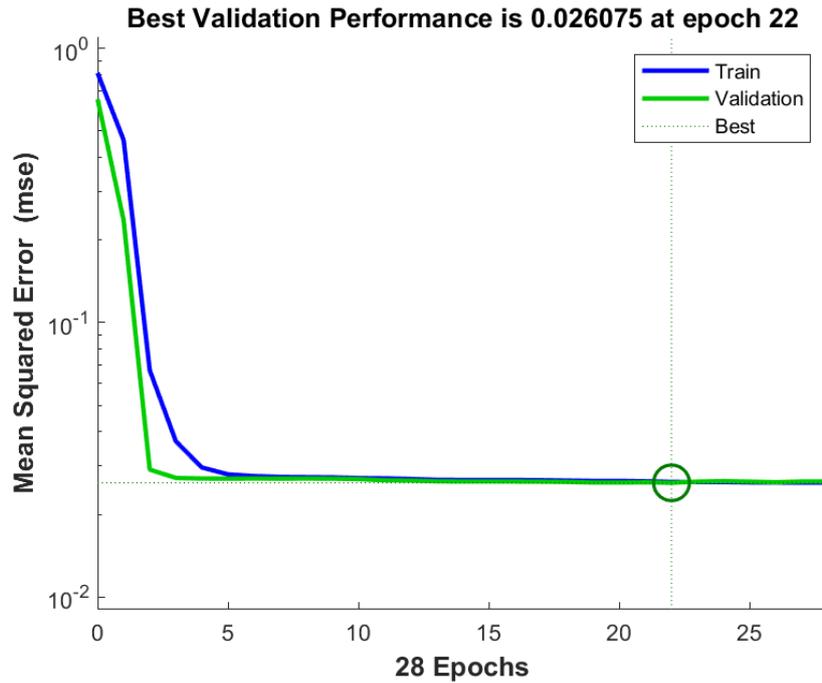
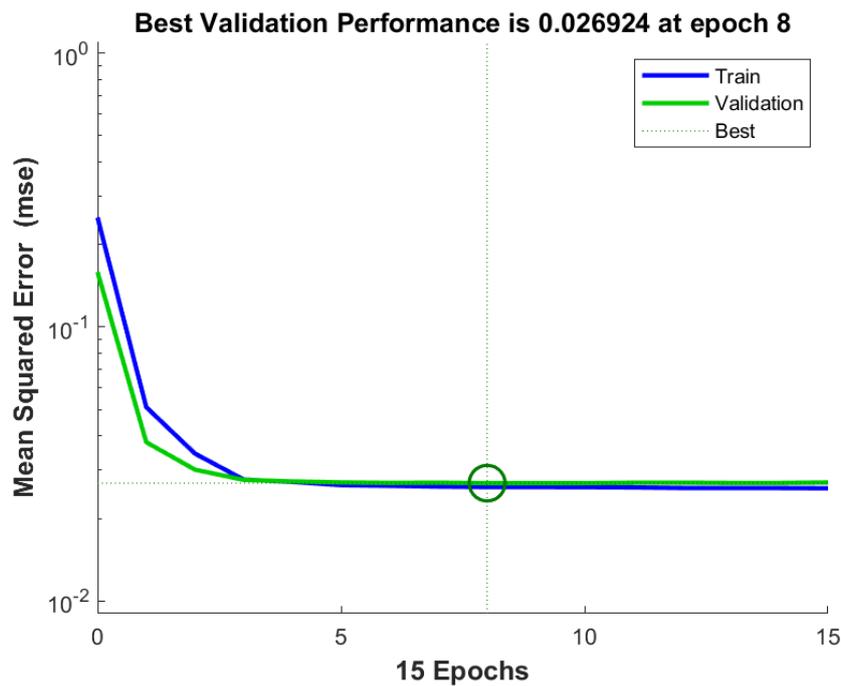
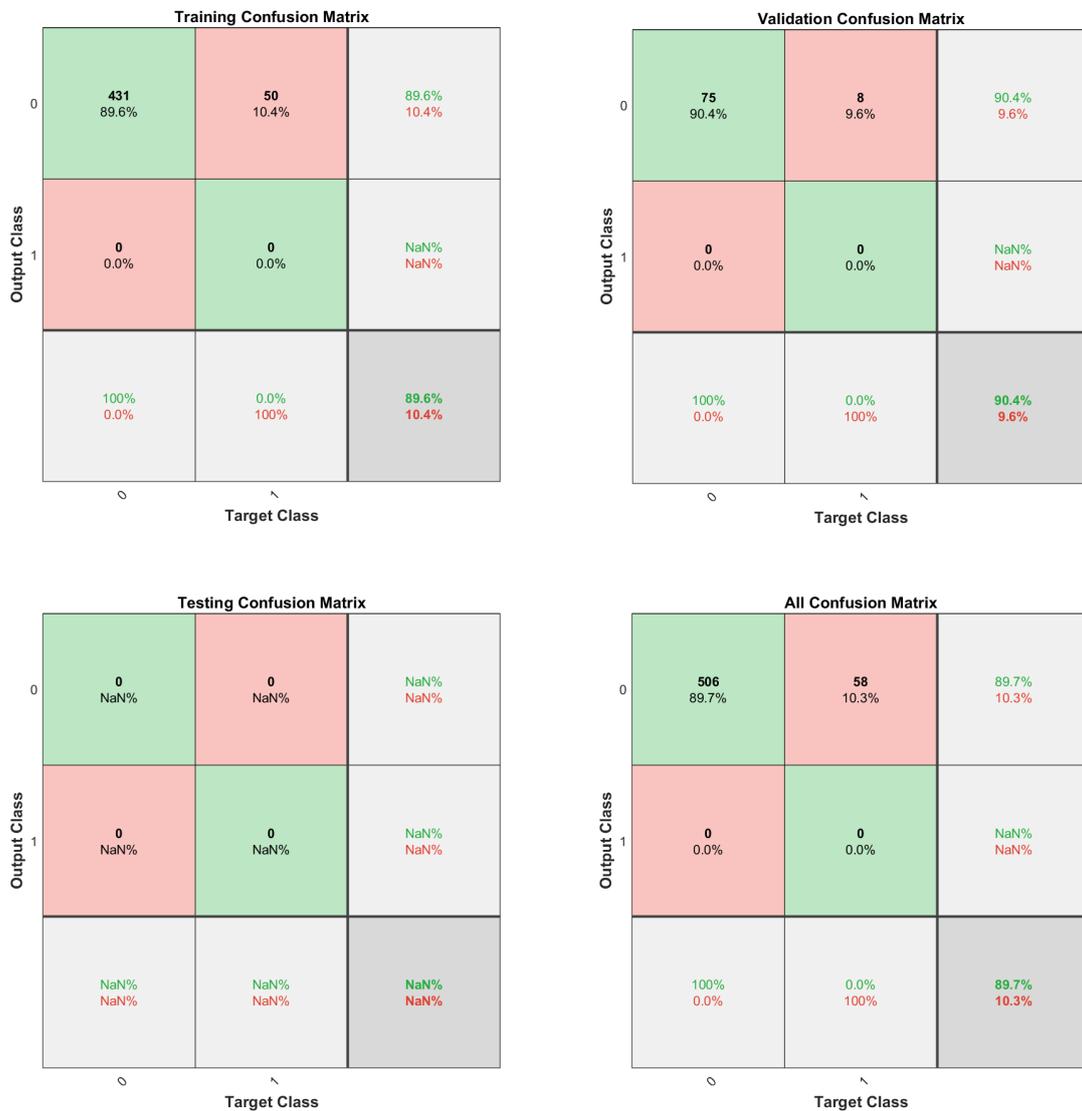


Figura 51 - Curva dos erros de treinamento e validação com 8 épocas de treinamento



O treinamento da RNA a seguir foi apenas para uma área selecionada, a microbacia hidrográfica do Córrego Água Quente (MBHCAQ) com uma área de 12,5km<sup>2</sup>. Os dados treinados e validados obtiveram uma taxa de acerto de quase 90% (Figura 52), para reconhecimento dos valores verdadeiros positivos, onde 431 *pixels* que não possuem erosão foram classificados corretamente, 89,6%. Foram considerados valores falsos positivos 10,4%. Na linha dos valores negativos não houve classificação, seguindo a mesma hipótese, o desbalanceamento dos dados.

Figura 52 - Matriz de confusão RNA, microbacia hidrográfica



Fonte: Gerado com *Matlab*® (2020)

Nas Figuras 53 e 54 são apresentadas as curvas de evolução dos erros de treinamento, validação e teste das redes neurais para a microbacia do Córrego Água Quente, o comportamento das curvas de erro é diferente das curvas apresentadas anteriormente, mas o valor do erro também é próximo de 0.

Figura 53 - Curvas dos erros de treinamento e validação da MBHCAQ para uma época

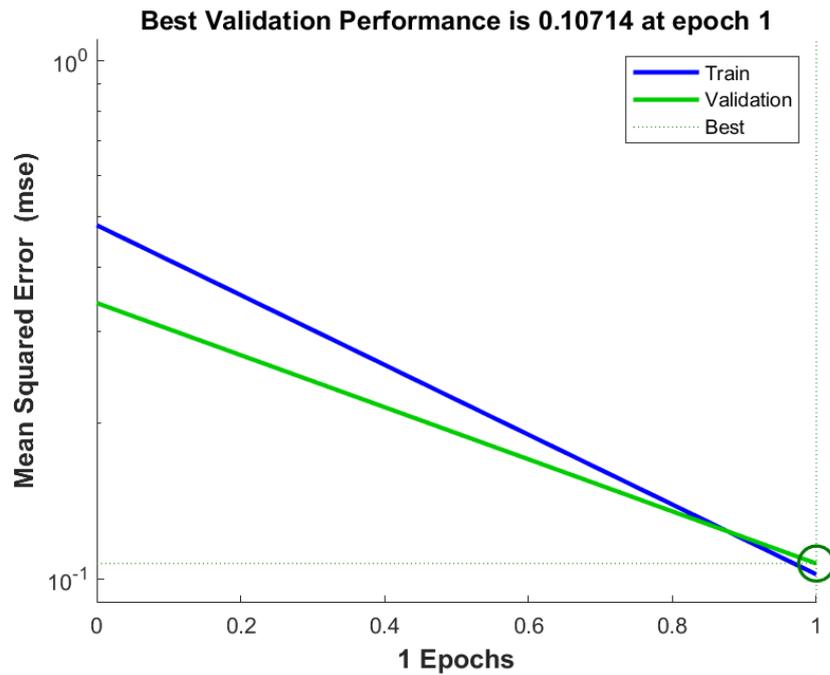
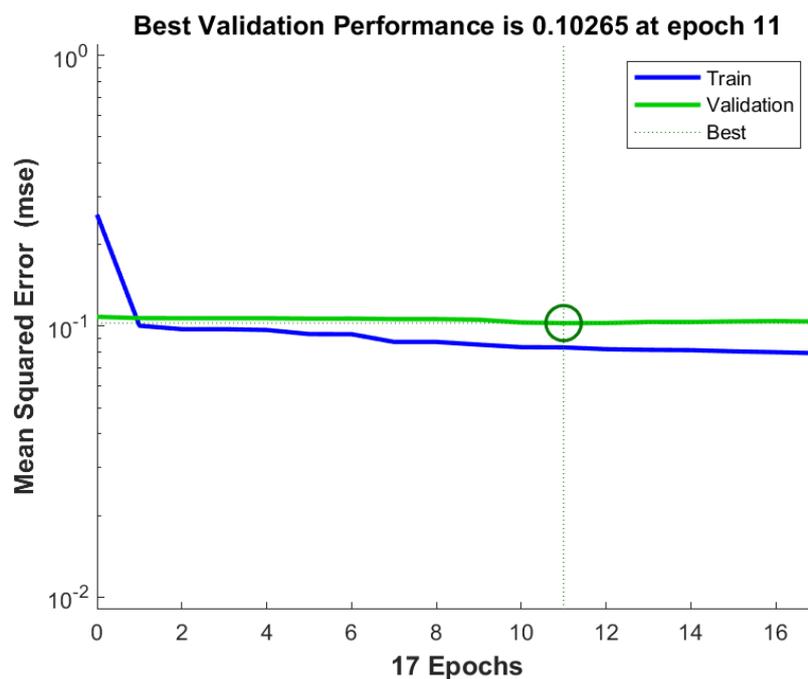


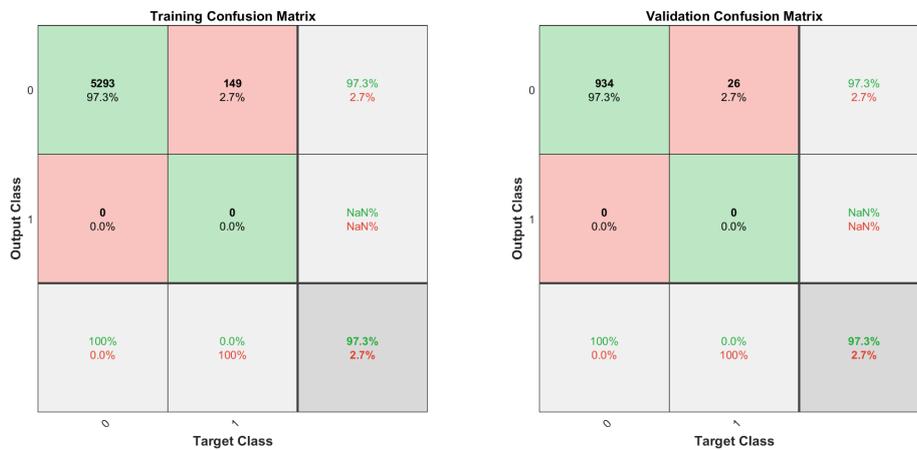
Figura 54 - Curvas dos erros de treinamento e validação da MBHCAQ para 11 época



### 5.3.2 Treinamento da RNA Perceptron Multicamada

Os dados treinados utilizando a rede multicamada supervisionada, obteve resultados de duas formas, os dados foram utilizados crus (*crisps*) num primeiro momento, com exatamente o mesmo valor na taxa de acerto da rede neural com uma camada 97,3% para as áreas verdadeiro positivo e 2,7% para as áreas falso positivo (Figura 55).

Figura 55 - Mariz de confusão multicamada com dados *crisps*



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

Como os dados apresentaram pouca variação no treinamento, uma nova tentativa foi feita com dados normalizados, ou seja, os dados que foram extraídos dos mapas estavam com as classes entre 0 e 1, foi aplicada a função *fuzzy membership* do *ArcGIS*<sup>®</sup>. A taxa de acerto reduziu, tanto no treinamento quanto na validação, diminuindo aproximadamente 6%. O valor é mais significativo no quadrante falso positivo, pois os valores aumentaram de 2 a 10% nos locais onde não tem processo erosivo e foi caracterizado como tendo (Figura 56).

Figura 56 - Mariz de confusão multicamada com dados normalizados

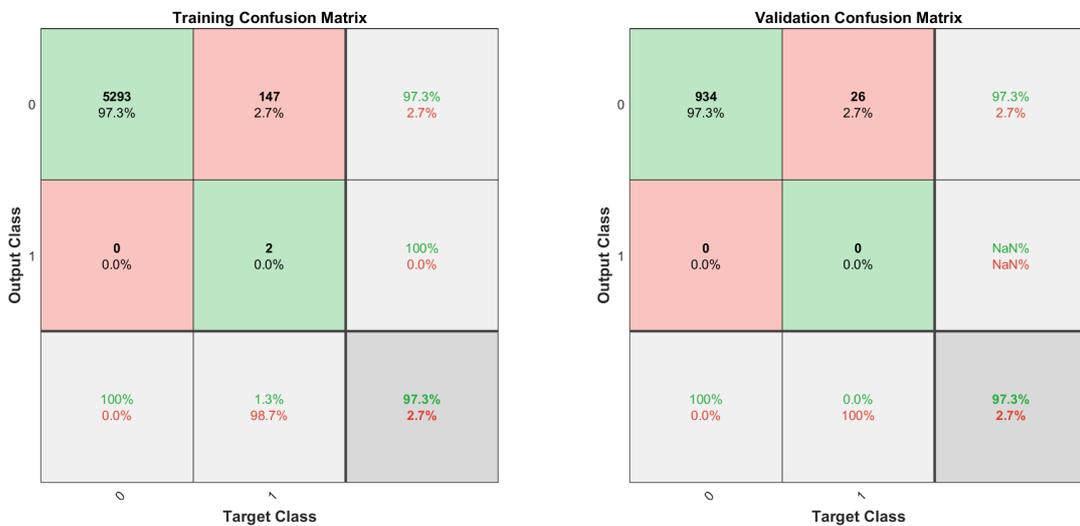


Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

### 5.3.3 Treinamento da RNA ANFIS

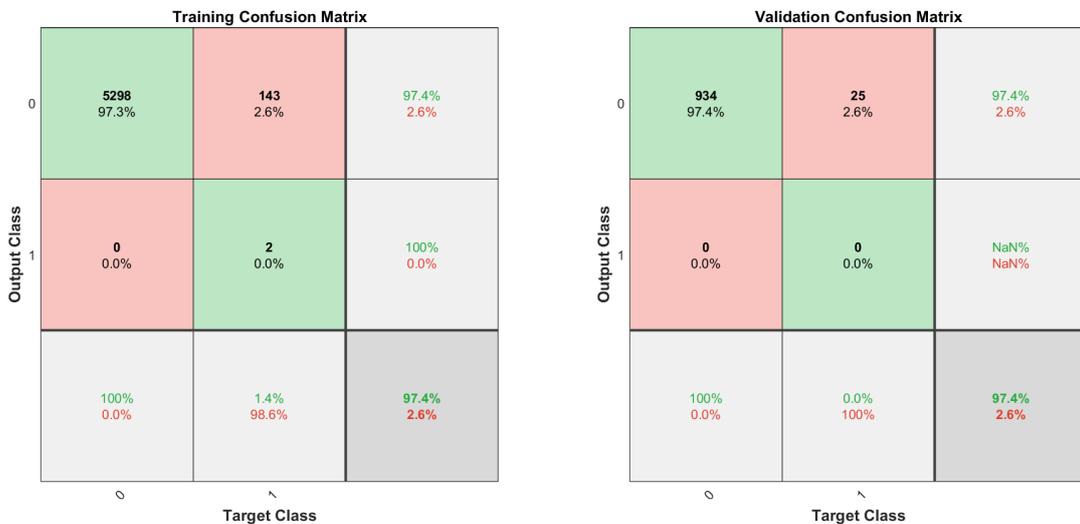
Os treinamentos realizados no método ANFIS, se deram de duas formas, a primeira os dados foram trabalhos em toda a extensão da área de estudo, a BHRM (Figuras 57 e 58), tanto com os dados críps, quanto normalizados. Num segundo treinamento os dados utilizados foram da microbacia do Córrego Água Quente (Figuras 59), também com os dados críps e normalizados. Na tentativa de melhores resultados e uma variação nas porcentagens de acertos.

Figura 57 Mariz de confusão ANFIS com dados *críps* para a BHRM



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

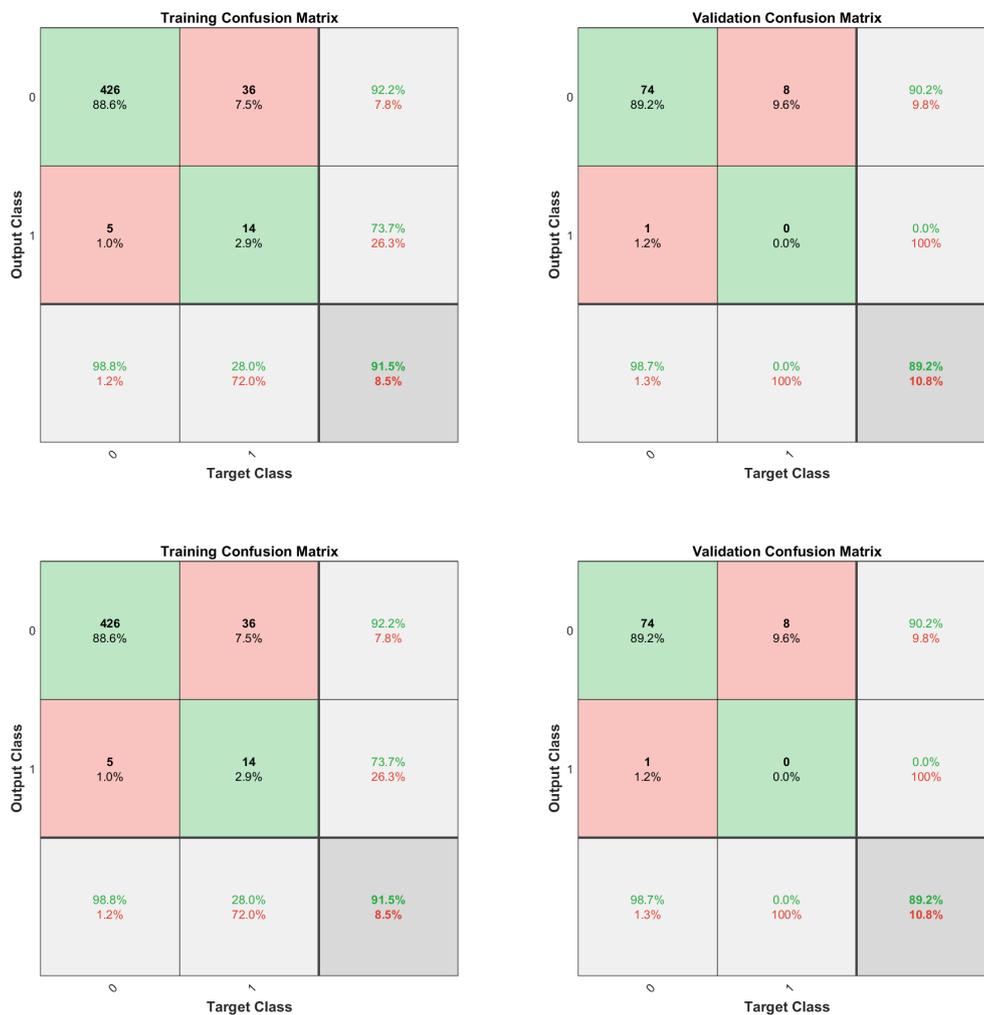
Figura 58 - Mariz de confusão ANFIS com dados normalizados para a BHRM



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

Mesmo com todas as tentativas de melhorar os resultados de treinamento, os valores dos treinamentos sofreram pouca ou quase nenhuma alteração, chegando à conclusão que a pouca informação sobre os processos erosivos foi determinante para que o treinamento não obtivesse melhores resultados. Mesmo com a pouca variabilidade nos resultados, os métodos abordados mostraram-se eficientes, com alguns ajustes na estrutura e balanceamento dos dados o método pode ser considerado muito eficiente.

Figura 59 - Mariz de confusão ANFIS com dados *crisps* e normalizados para a microbacia do Córrego Água Quente



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

#### 5.4 Treinamento da RNA Perceptron com uma camada segundo período

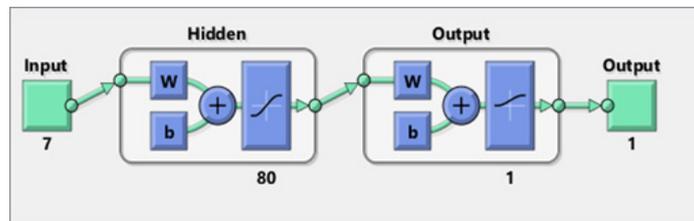
Nesse segundo período foram executados os treinamentos com os dados divididos em novos conjuntos de treinamento, validação e teste. Após o treinamento com os três modelos foi executado uma nova fase com o modelo que apresentou os melhores resultados de treinamento, foram realizados novos ajustes no intuito de se obter uma representação melhor da relação processo erosivo por área.

### 5.4.1 Rede Perceptron Design 1

O *Design 1* foi estruturado no sentido de obter melhores resultados por meio do balanceamento dos dados, para isso foram definidos sete parâmetros de entrada, que são referentes aos atributos do meio físico, condicionantes para o acionamento dos processos erosivo, e um valor de saída, referente aos locais que correspondem as erosões mapeadas. A estrutura da rede está ilustrada na Figura 60.

1. Número de entradas: 7;
2. Neurônios da camada escondida: 80;
3. Número de Saída: 1;
4. Algoritmo treinamento: *backpropagation* gradiente descendente com taxa de aprendizagem adaptativa;
5. *Learning rate*: 0.01;
6. *Learning rate increase/decrease*:  $\pm 5\%$ ;
7. Número de épocas máximo: 3000.
8. Divisão do conjunto de dados para treinamento:
  - 1) 80% Treinamento e 20% Validação;
  - 2) 70% Treinamento, 15% Validação e 15% de Teste.

Figura 60 - *Design 1* da rede *Perceptron*



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

### 5.4.2 Divisão do conjunto de dados Treinamento e Validação

O treinamento 1 apresentou os seguintes parâmetros estatísticos, apresentado na Tabela 7.

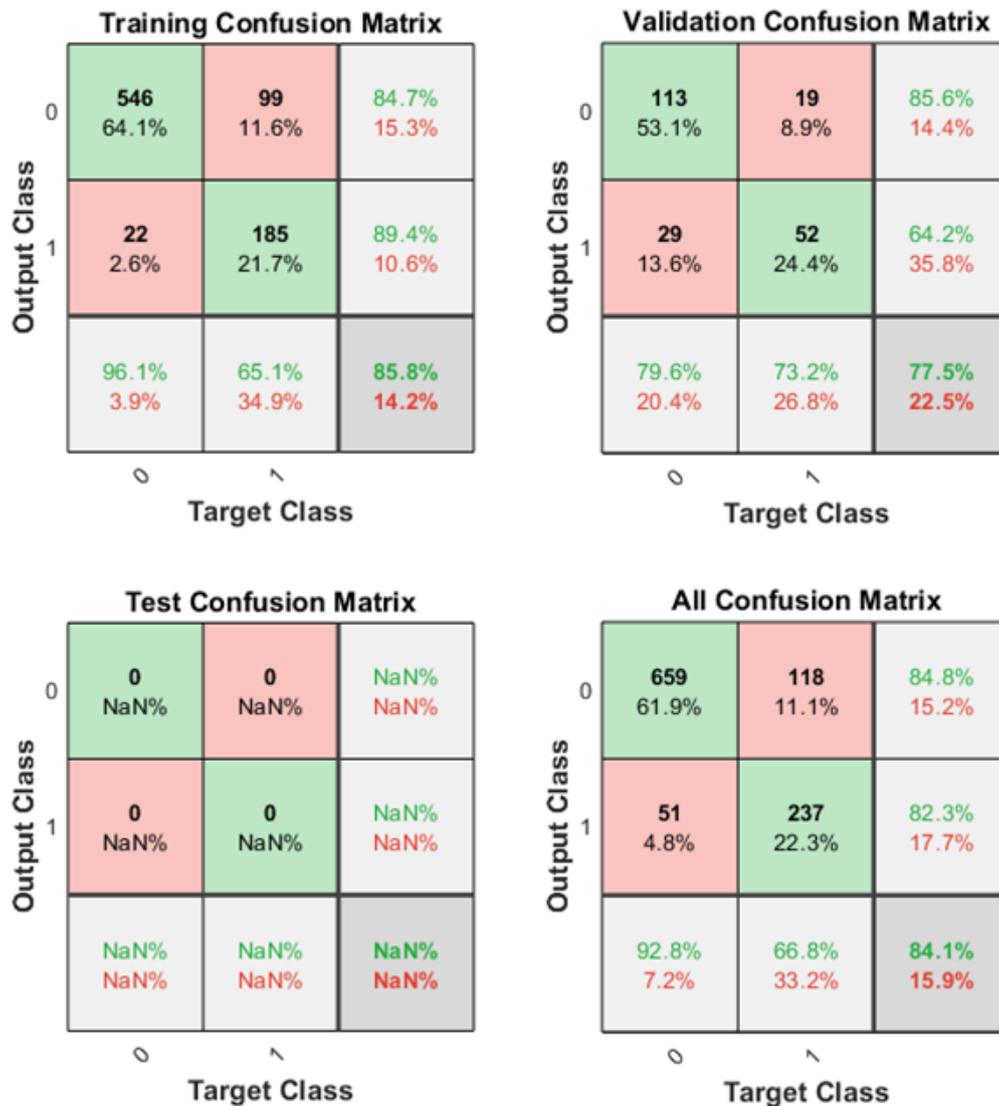
Tabela 7 - Parâmetros do treinamento 1

Número de épocas: 2728	
Mean Square Root Error (MSE):	Mean Absolute Error (MAE):
Training: 0.110380035723809	Training: 0.164367489740587
Validation: 0.172929367489260	Validation: 0.259623563434787
Test: Não avaliado	Test: Não avaliado

Fonte: Autor (2020)

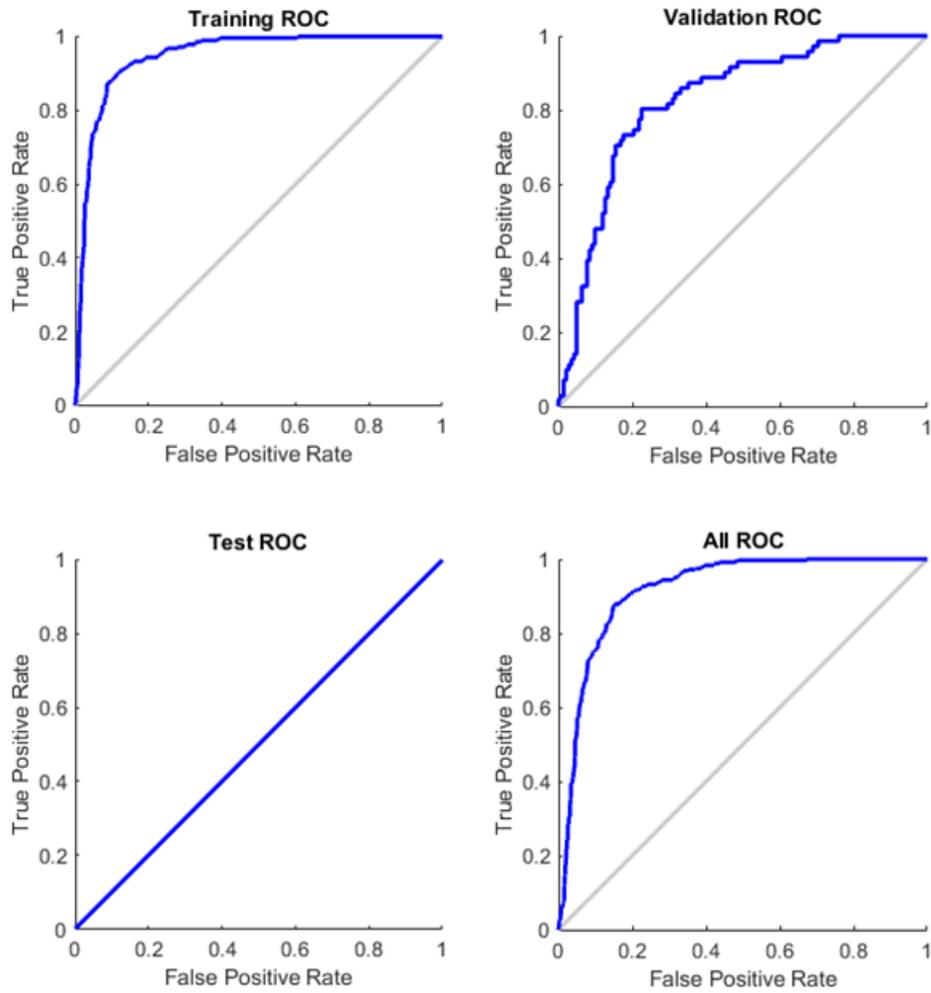
Os resultados apresentados nas matrizes de confusão para treinamento e validação possuem uma resposta mais eficiente em relação aos treinamentos anteriores, tanto para sensibilidade, quanto especificidade, ou seja, os valores de acertos verdadeiros positivos e verdadeiros negativos 85,8% para o treinamento e 77,5% para validação, os valores falsos 14,2 e 22,5%, como é mostrado na Figura 61. Na Figura 62 é mostrado na curva ROC os resultados de sensibilidade, quanto mais próximo do valor 1, no eixo de verdadeiros positivos, melhor o resultado de treinamento. Avaliação de todo conjunto com 13.152 dados, para o treinamento 1, 79,7% de acerto para os valores positivos e 20,3% para os valores falsos, como é mostrado na Figura 63.

Figura 61 - Matriz de confusão treinamento 1



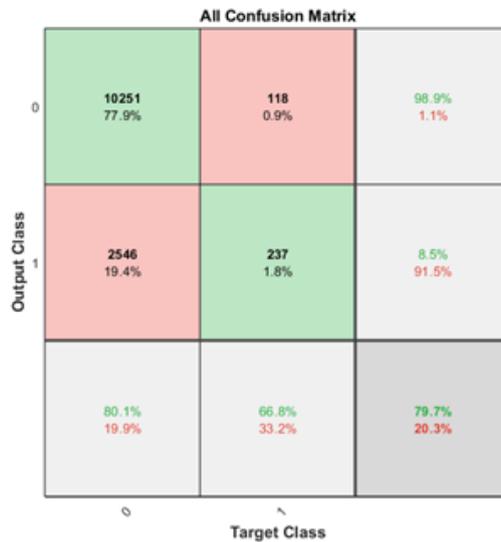
Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

Figura 62 - Curva ROC do treinamento 1



Fonte: Gerado com *Matlab*® (2020)

Figura 63 - Matriz de confusão para todo o conjunto de dados



Fonte: Gerado com *Matlab*® (2020)

### 5.4.3 Divisão do conjunto de dados Treinamento, Validação e Teste

No segundo treinamento foi obtido os resultados das matrizes de confusão para treinamento, validação e teste, os valores de acertos verdadeiros positivos e verdadeiros negativos 85,3% para o treinamento e 75,5% para validação e 77,4% para teste, os valores falsos 14,7, 24,5 e 22,6% como é mostrado na Figura 64. Na Figura 65 é mostrado na curva ROC os resultados de sensibilidade, quanto mais próximo do valor 1, no eixo de verdadeiros positivos, melhor o resultado de treinamento. Avaliação de todo conjunto com 13.152 dados, para o treinamento 2, 73,1% de acerto para os valores positivos e 26,9% para os valores falsos, como é mostrado na Figura 66.

Figura 64 - Matriz de confusão treinamento 2



Fonte: Gerado com Matlab® (2020)

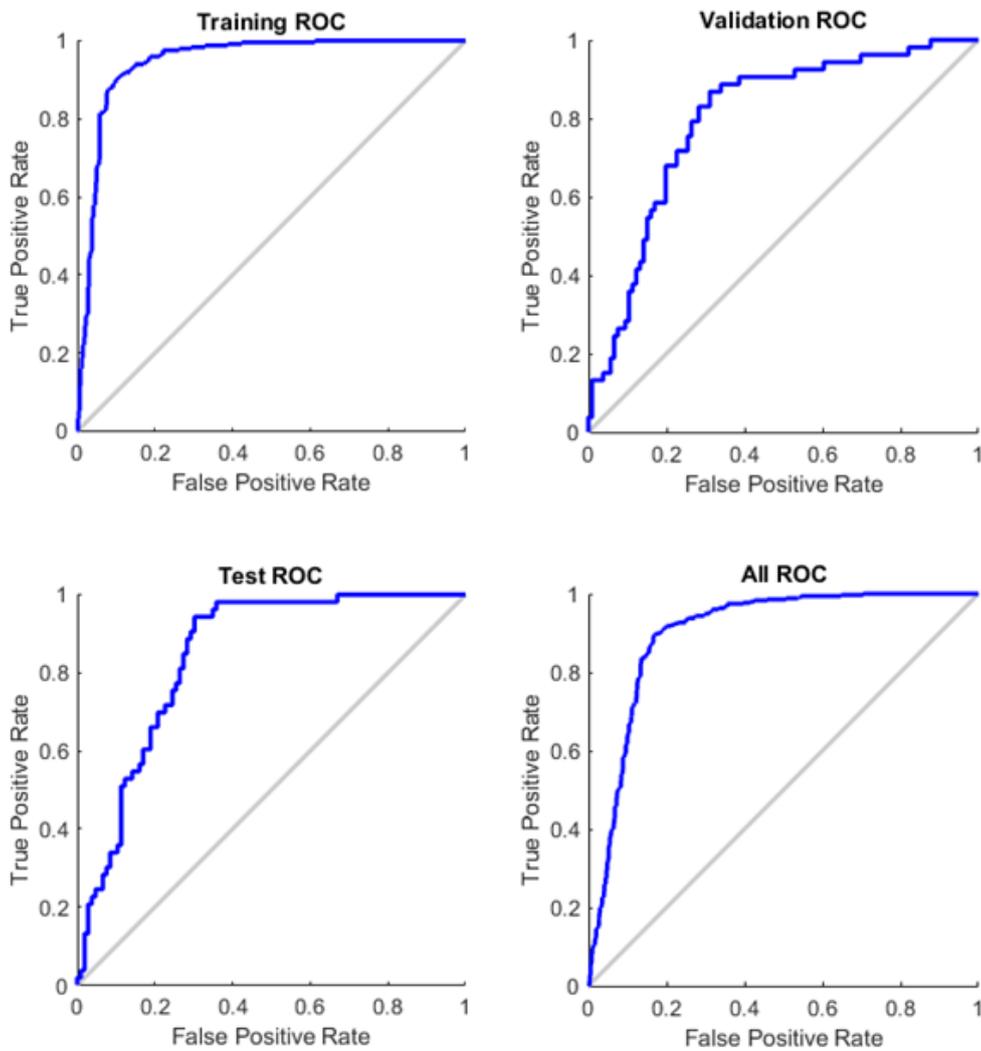
O treinamento 2 apresentou os seguintes parâmetros estatísticos, Tabela 8.

Tabela 8 - Parâmetros do treinamento 2

Número de épocas: 2156	
Mean Square Root Error (MSE):	Mean Absolute Error (MAE):
Training : 0.100728800608488	Training: 0.169973251294158
Validation: 0.189766683094269	Validation: 0.295211843957703
Test: 0.177282008577938	Test: 0.276756323987527

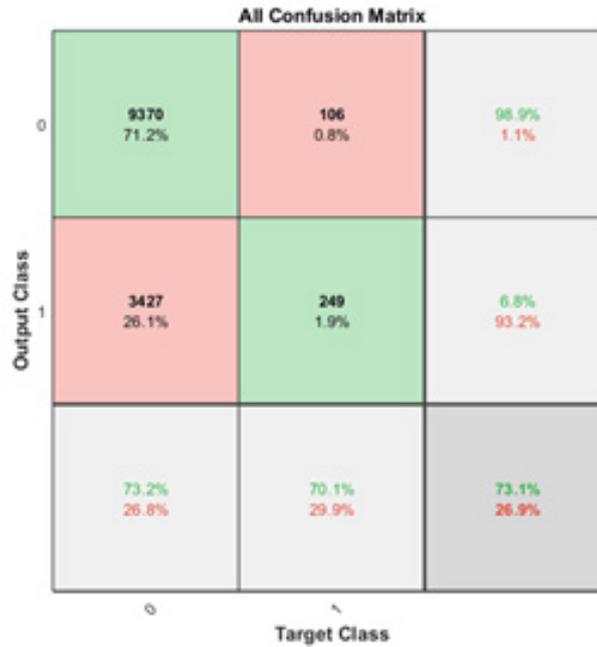
Fonte: Autor (2020)

Figura 65 - Curva ROC treinamento 2



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

Figura 66 - Matriz de confusão para todo o conjunto de dados



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

#### 5.4.4 Conclusão Design 1

O *design 1* apresentou os seguintes parâmetros, como é mostrado na Tabela 9:

Tabela 9 - Resultados para os conjuntos de treinamento *Design 1*

Treinamento do Design 1 rede neural Perceptron	
Treinamento 1 (80,20,0)	Treinamento 2 (70,15,15)
<b>Resultados para os conjuntos selecionados</b>	<b>Resultados para os conjuntos selecionados</b>
84.1% de acurácia total	82.6% de acurácia total
4.8% de falso positivo e 11.1% de falso negativo	7.4% de falso positivo e 10.0% de falso negativo
<b>Resultados para todos os dados obtidos (13152)</b>	<b>Resultados para todos os dados obtidos (13152)</b>
79.7% de acurácia total	73.1% de acurácia total
19.4% de falso positivo e 0.9% de falso negativo	26.1% de falso positivo e 0.8% de falso negativo

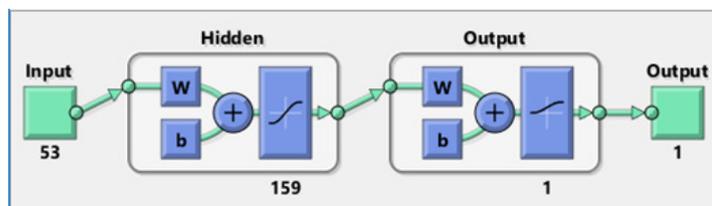
Fonte: Autor (2020)

### 5.4.5 Rede Perceptron Design 2

1. Número de entradas: 53 (Cada entrada gera uma combinação lógica, por exemplo, uma classe com 5 IDs gera 5 entradas 0 ou 1 e o ID=3 habilita 1 na terceira entrada -> [0 0 1 0 0] );
2. Neurônios da camada escondida: 159;
3. Número de Saída: 1;
4. Algoritmo treinamento: *Scaled conjugate gradient backpropagation*;
5. *MSE Stop*: 1e-3;
6. alpha: 1e-5;
7. gama: 1e-6;
8. Número de épocas máx: 10000.
9. Conjuntos:  
 Treinamento 1) 80% Treinamento e 20% Validação;  
 Treinamento 2) 70% Treinamento, 15% Validação e 15% de Teste.

O segundo *design* utilizado tem os seguintes parâmetros, como é mostrado na Figura 67.

Figura 67 - Design 2 da rede Perceptron



Fonte: Gerado com Matlab® (2020)

### 5.4.6 Divisão do conjunto de dados Treinamento e Validação

O treinamento 1 apresentou os seguintes parâmetros estatísticos, Tabela 10.

Tabela 10 - Parâmetros do treinamento 2

Número de épocas: 133	
Mean Square Root Error (MSE):	Mean Absolute Error (MAE):
Training : 0.036733736313235	Training: 0.103451733523719
Validation: 0.133117289792647	Validation: 0.241474731575511
Test: Não avaliado	Test: Não avaliado

Fonte: Autor (2020)

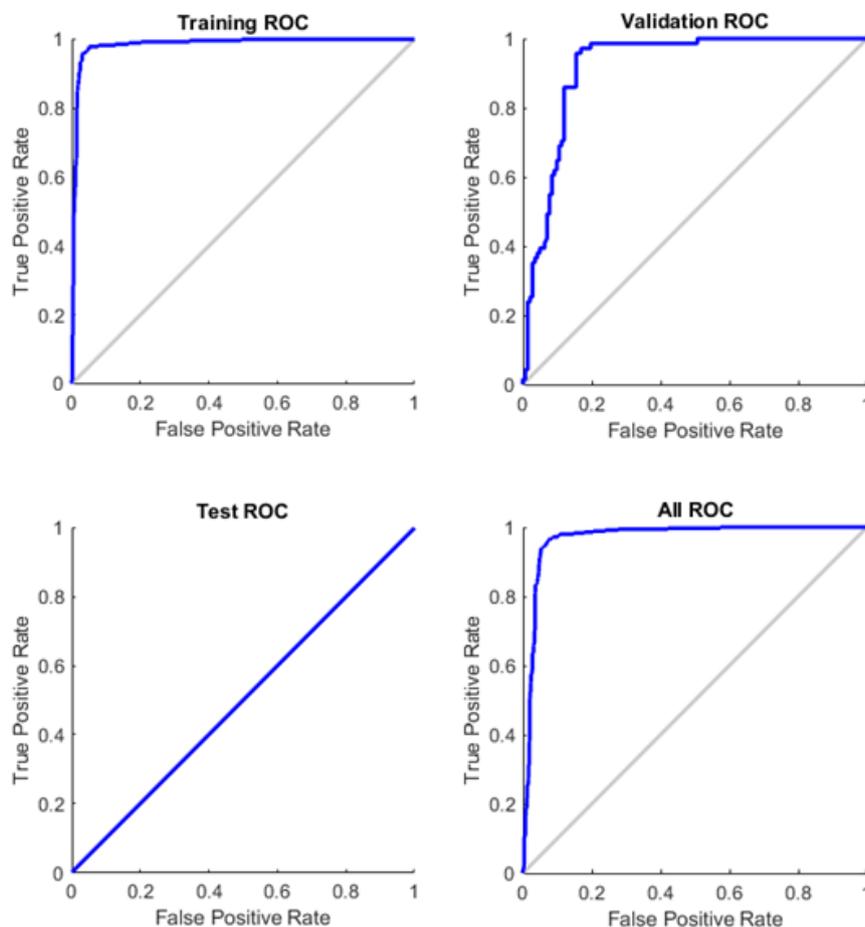
O primeiro treinamento do *design 2* da rede *Perceptron* obteve os seguintes resultados para as matrizes de confusão para treinamento e validação, os valores de acertos verdadeiros positivos e verdadeiros negativos 96,5% para o treinamento e 83,1% para validação, os valores falsos 3,5 e 16,9% como é mostrado na Figura 68. Na Figura 69 é mostrado na curva ROC os resultados de sensibilidade, quanto mais próximo do valor 1, no eixo de verdadeiros positivos, melhor o resultado de treinamento. Avaliação de todo conjunto com 13.152 dados, para o treinamento 1, 74,4% de acerto para os valores positivos e 25,6% para os valores falsos, como é mostrado na Figura 70.

Figura 68 - Matriz de confusão treinamento 1



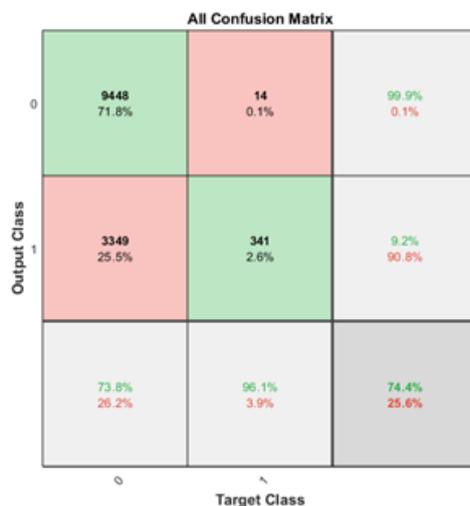
Fonte: Gerado com *Matlab*® (2020)

Figura 69 - Curva ROC treinamento 1



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

Figura 70 - Matriz de confusão para todo o conjunto de dados

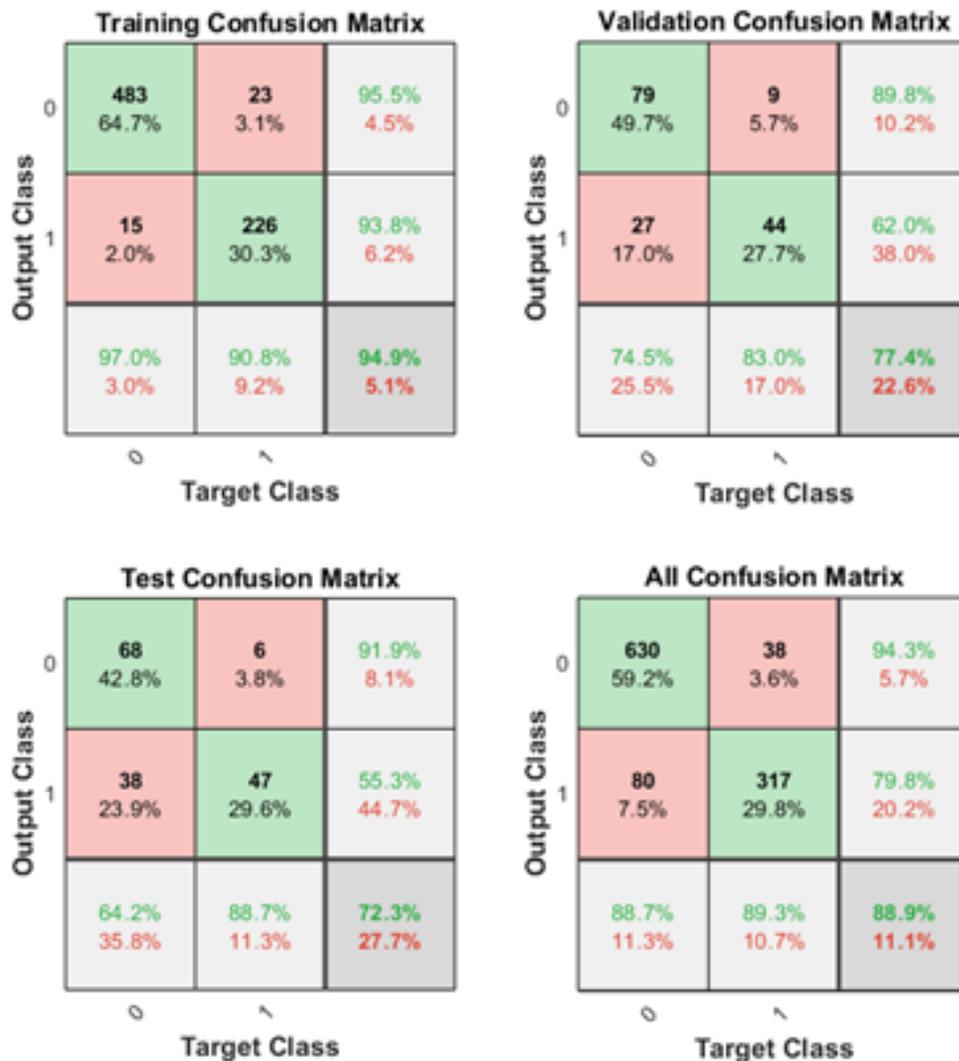


Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

### 5.4.7 Divisão do conjunto de dados Treinamento, Validação e Teste

No segundo treinamento foi obtido os resultados das matrizes de confusão para treinamento, validação e teste, os valores de acertos verdadeiros positivos e verdadeiros negativos 94,9% para o treinamento e 77,4% para validação e 72,3% para teste, os valores falsos 5,1, 22,6 e 27,7% como é mostrado na Figura 71. Na Figura 72 é mostrado na curva ROC os resultados de sensibilidade, quanto mais próximo do valor 1, no eixo de verdadeiros positivos, melhor o resultado de treinamento. Avaliação de todo conjunto com 13.152 dados, para o treinamento 2, 72,7% de acerto para os valores positivos e 27,3% para os valores falsos, como é mostrado na Figura 73.

Figura 71 - Matriz de confusão treinamento 2



Fonte: Gerado com Matlab® (2020)

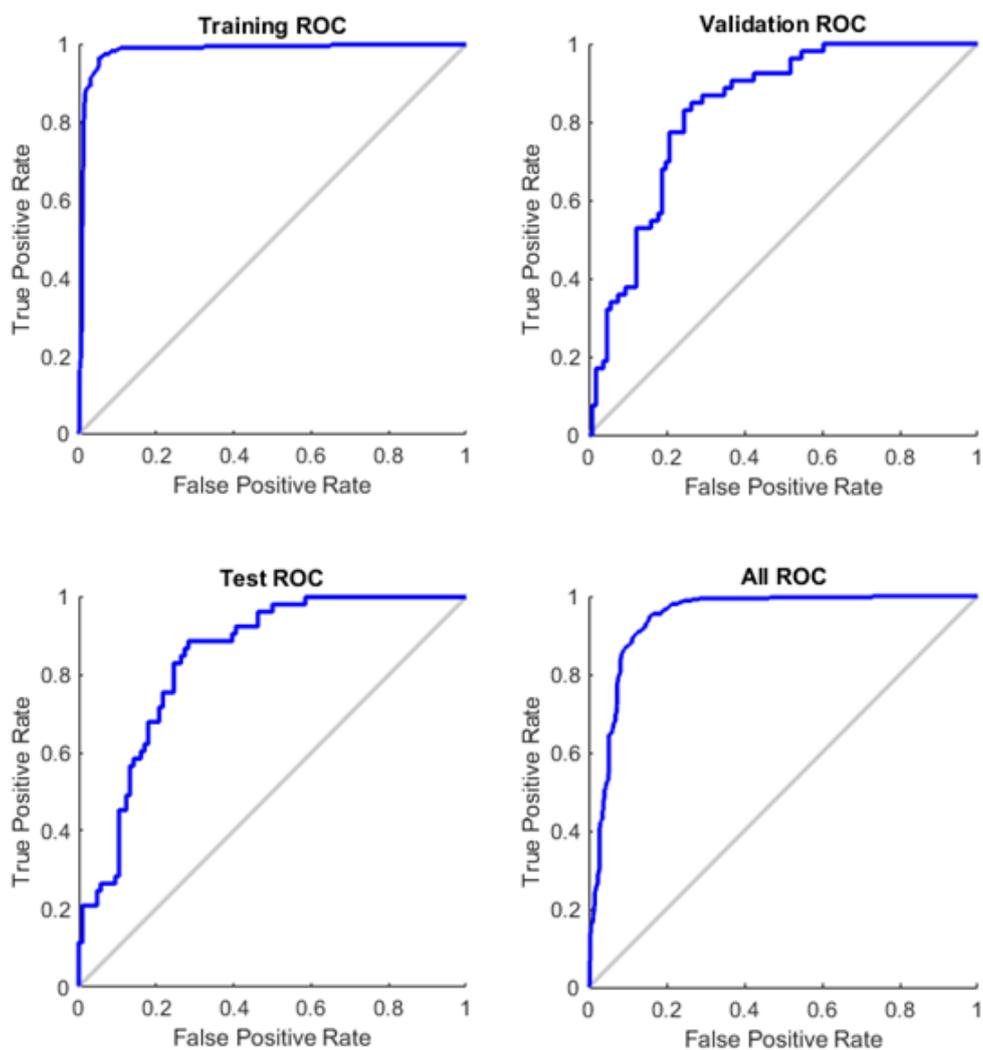
O treinamento 2 apresentou os seguintes parâmetros estatísticos, Tabela 11.

Tabela 11 - Parâmetros do treinamento 2

Número de épocas: 98	
Mean Square Root Error (MSE):	Mean Absolute Error (MAE):
Training : 0.041564348247486	Training: 0.100704557619586
Validation: 0.177334821401602	Validation: 0.299102166815436
Test: 0.195584682900087	Test: 0.298757748044616

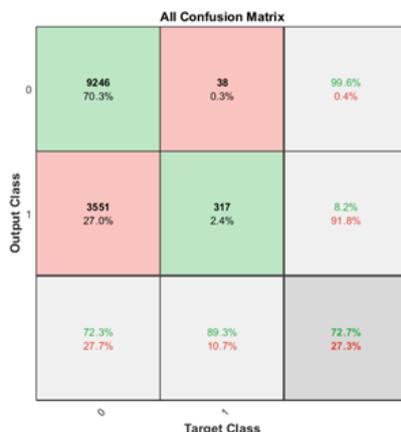
Fonte: Autor (2020)

Figura 72 - Curva ROC treinamento 2



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

Figura 73 - Matriz de confusão para todo o conjunto de dados



Fonte: Gerado com *Matlab*<sup>®</sup> (2020)

### 5.4.8 Conclusão Design 2

O *design 2* apresentou os seguintes parâmetros, como é mostrado na Tabela 12:

Tabela 12 - Resultados para os conjuntos de treinamento *Design 2*

Treinamento do Design 2 rede neural Perceptron	
Treinamento 1 (80,20,0)	Treinamento 2 (70,15,15)
<b>Resultados para os conjuntos selecionados</b>	<b>Resultados para os conjuntos selecionados</b>
93.8% de acurácia total	88.9% de acurácia total
4.9% de falso positivo e 1.3% de falso negativo	7.5% de falso positivo e 3.6% de falso negativo
<b>Resultados para todos os dados obtidos (13152)</b>	<b>Resultados para todos os dados obtidos (13152)</b>
74.4% de acurácia total	72.7% de acurácia total
25.5% de falso positivo e 0.1% de falso negativo	27.0% de falso positivo e 0.3% de falso negativo

Fonte: Autor (2020)

### 5.4.9 Conclusão geral do segundo período de treinamentos

Buscou-se com os novos treinamentos um modelo representasse com maior precisão a ocorrência de processos erosivos, por isso precisamos que os valores que representam os falsos negativos sejam baixos, pois é crítico para o sistema indicar que não existe erosão quando na verdade existe.

Nesse sentido, a rede *Perceptron* do *design 2* foi a que apresentou os melhores resultados, apresentando menor ocorrência de valores de falsos negativos do que o *design 1*. Os resultados comparatórios estão apresentados nas Tabela 13.

Tabela 13 - Resultados da comparação dos conjuntos de treinamento dos dos *Design 1* e *Design 2*

<b>Rede/Treinamento</b>	<b>Acurácia geral</b>	<b>%falso negativo</b>	<b>% falso positivo</b>
Rede 1 – T1	79.7%	0.9%	19.4%
Rede 1 – T2	73.1%	0.8%	26.1%
Rede 2 – T1	74.4%	0.1%	25.5%
Rede 2 – T2	72.7%	0.3%	27%

Fonte: Autor (2020)

## Considerações Finais

Neste capítulo são apresentadas as considerações finais. Inicia-se com uma síntese da pesquisa, seguida do relato referente às respostas sobre as questões de pesquisa e análise das hipóteses, conclusões e propostas de intervenções mitigadoras, bem como das limitações e recomendações para trabalhos futuros.

### 6.1 Síntese da pesquisa

Uma das proposições do trabalho foi apresentar um estudo das publicações sobre o tema principal da pesquisa, Sistema de Inferência Neuro-*Fuzzy* Adaptativo, considerando também as palavras e siglas, ANFIS, Sistema de Inferência *Fuzzy*, FIS, Erosão, Sistema de Informações Geográficas e SIG. As publicações analisadas correspondem ao período de 2004 a 2019, resultando num total de 99 trabalhos publicados em diferentes veículos de divulgação científica, anais de congressos e capítulos de livros. Observou-se um número crescente de publicações relacionadas ao tema, em especial a partir de 2014, destaque para os trabalhos publicados no Irã, Coréia do Sul e Austrália, com maiores números de publicações, respectivamente.

A Austrália é país que apresenta o maior número de citações e parcerias em outros trabalhos, com outros autores. Entre os autores mais ativos, Pradhan, B. destaca-se, por possuir o maior número de trabalhos relevantes publicados, também é o maior colaborador em outros trabalhos. Em relação aos periódicos que mais publicam sobre o assunto, 4 deles possuem o mesmo número de trabalhos publicados, a saber: *Catena*, *Environmental Earth Sciences*, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* e o *Journal Of The Indian Society of Remote Sensing*.

O mapeamento das principais palavras-chave, que aparecem com maior frequência nos resumos e títulos dos trabalhos foi dividido em 3 grupos: (1) Inteligência Artificial; (2) Geoinformação; (3) Geoprocessamento e Sensoriamento Remoto. De modo que esses termos podem auxiliar na busca por novos trabalhos dentro da base de dados da Scopus.

Em relação a produção de dados, na etapa seguinte foi necessário elaborar a base primária de dados, ou seja, da onde são extraídas as informações que alimentaram o banco de dados a ser treinado utilizando redes neurais artificiais. Foi necessário definir os atributos que influenciam a ocorrência dos processos erosivos, para depois executar o processo, vetorização dos dados, processamento e composição de imagens de satélite e padronização dos produtos cartográficos em termos de escala, sistema de coordenadas e número de pixel.

A elaboração desses produtos é fundamental para compreender a dinâmica da bacia hidrográfica. Apenas utilizando-se de uma análise de interpretação visual dos mapas já é possível identificar alguns fatores que contribuem para os processos erosivos, porém, com o emprego de RNA.

Em relação às metodologias utilizadas para treino das redes neurais, a variação nos resultados, mas como já descrito o desbalanceamento de classes no conjunto de dados é a principal hipótese para explicar os resultados insatisfatórios obtidos pela análise do conjunto de dados por RNA. Entretanto a documentação dos experimentos realizados, poderá ser utilizada como base para outros trabalhos, visto que, a fase de elaboração do mapa de processos erosivos foi a etapa mais dificultosa desta pesquisa.

### 6.1.1 Respostas aos objetivos da pesquisa e análise da hipótese

Este trabalho teve como motivação alguns objetivos específicos e sua hipótese. Após a aplicação do método proposto foi possível responder aos objetivos.

*Objetivo 1:* elaborar inventário de processos erosivos atualizados:

A elaboração de um inventário de processos erosivos foi importante considerando a relevância de onde se encontravam os processos erosivos. O uso das imagens *Sentinel-2* que, possuem resolução de 12 metros são adequadas para identificar os processos erosivos, considerando que o *software* SNAP é de fácil utilização, para a composição colorida das bandas utilizadas. Dentre os problemas encontrados na elaboração do inventário estão, o desbalanceamento de informações, no caso a área de estudo possui uma área muito superior ao número de processo. Outro fator importante é a validação das informações em campo, foi utilizado o método de interpretação visual de imagem de satélite, com verificações em campo para validar as informações, foram verificados 30% dos pontos.

*Objetivo 2:* gerar uma coleção de documentos cartográficos:

Os documentos cartográficos produzidos foram a fonte de dados primordial para o treinamento das redes neurais. As informações constantes destes documentos foram convertidas para matriz de pontos dos mapas, permitindo representar o terreno e cada atributo considerado determinante dos processos erosivos, de modo compatível com o aplicativo para a geração de RNA

*Objetivo 3:* avaliar pelo treinamento de diferentes modelos de redes neurais artificiais, rede neural *perceptron* com uma camada; rede neural *multilayer perceptron* e; ANFIS:

Os métodos utilizados estão em consonância com a proposta do trabalho, os métodos podem ser considerados eficientes para o treinamento de redes neurais.

Quanto à pergunta central desta tese, que se refere ao uso da inteligência artificial por meio das redes neurais artificiais e sua capacidade de auxiliar a elaboração de mapas de processos erosivos em bacias hidrográficas. Acredito que o resultado foi satisfatório, entretanto, sua transformação em um mapa visual de susceptibilidade a erosão, não foi viável. Esta abordagem de emprego de RNA com

a adição de mais alguns parâmetros demonstra-se promissora e deve ser investigada em trabalhos futuros.

### 6.1.2 Conclusões e propostas de intervenções mitigadoras

Considerando-se os resultados obtidos tem-se como conclusões principais, a contribuição acadêmica acerca do método proposto. Foi apresentado uma sequência de procedimentos metodológicos que podem ser replicados em outros estudos no objetivo de: a) fazer classificações utilizando redes neurais artificiais; b) estruturar e refinar conjunto de dados para treinamento dentro do *software Matlab*<sup>®</sup> e; c) elaboração de produtos cartográficos a partir de resultados derivados de RNA.

Ainda sobre a contribuição metodológica, foram apresentadas três técnicas diferentes de treinamento de redes neurais, aplicáveis ao mapeamento de processos erosivos. A rede neural *Perceptron* com uma camada, a rede neural *Perceptron* multicamadas e o método de inferência neuro-*fuzzy* adaptativo. Cada qual com seu comportamento e desempenho específicos no treinamento conjunto de dados.

### 6.1.3 Limitações da pesquisa

Algumas limitações foram identificadas na etapa de treinamento dos dados, e estão relacionadas a capacidade do computador em processar os dados, devido a grande quantidade, em função do refinamento espacial das informações. Outro aspecto limitador foi a escala de alguns produtos cartográficos disponíveis, causando um desbalanceamento dos dados. A relação processo erosivo por área não foi suficiente para obter melhores resultados de treinamento, mesmo também com fragmentos da bacia hidrográfica. Sugere-se que trabalhos futuros avaliem o emprego de técnicas de re-amostragem de dados (*resampling*), no sentido de tratar o desbalanceamento de classes inerente ao fenômeno.

### 6.1.4 Recomendações

As principais recomendações para um treinamento mais eficiente são:

- Utilizar recursos computacionais mais robustos e com elevada capacidade de processamento de dados;
- Avaliar a disponibilidade e informações e, em especial, sua qualidade em comparação ao objetivos pretendidos e sua relação com a dimensionalidade do conjunto de dados a ser treinado;
- Elaborar dados com uma melhor proporção, com escalas compatíveis com o problema;
- Tempo hábil para o treinamento das RNA e seus ciclos de ajuste de parâmetros e re-treinamento.

Todas essas recomendações vão garantir um treino mais efetivo, em relação ao tipo de rede neural, todas possuem limitações e vantagens, a que apresentou um melhor resultado de treinamento foi a Multicamada *Perceptron*, mas todos os métodos funcionaram.

## Referências bibliográficas

AB'SABER, A. N. As boçorocas de Franca. *Revista da Faculdade de Filosofia, Ciências e Letras de Franca*, 1(2): 5-27, Franca. 1968.

AGHDAM, I.N., VARZANDEH, M.H.M. & PRADHAN, B. Landslide susceptibility mapping using an en-semble statistical index (Wi) and adaptive neuro-fuzzy inference system (ANFIS) model at Alborz Mountains (Iran). *Environ Earth Sci* 75, 553 (2016). <https://doi.org/10.1007/s12665-015-5233-6>.

AGUIAR, R. L. *Mapeamento geotécnico preliminar da área de expansão urbana de São Carlos – SP: contribuição ao planejamento*. Dissertação (Mestrado – Geotecnia) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 1989.

ALMEIDA, F. F. M. Fundamentos Geológicos do Relevo Paulista. *Boletim do Instituto Geográfico e Geológico do Estado de São Paulo*. n 41, São Paulo, 1964.

ARIANI, F.; ROBBY, ENDRA, R. Y. Implementation of Fuzzy Inference System with Tsukamoto Method for Study Programme Selection. In: *2nd International Conference on Engineering and Technology Development (ICETD 2013)* Universitas Bandar Lampung Faculty of Engineering and Faculty of Computer Science.

ASAHI, T.; TURO, D.; SHNEIDERMAN, B. *Visual decision-making: Using tree maps for the Analytic Hierarchy Process*. University of Maryland, Department of Computer Science Technical Report CS-TR-3293. 1994. 95-104pp.

AUGUSTO FILHO, O. Análise de método de interpolação de modelo digital de terreno e aplicação em SIG de gestão de riscos geotécnicos e ambientais em oleodutos. In: *Congresso Brasileiro de Geologia de Engenharia e Ambiental*, 13., São Paulo. Anais... São Paulo, 2011.v.1.p.1-9.

BASTOS, C. A. B. *Estudo geotécnico sobre a erodibilidade de solos residuais não saturados*. Programa de Pós-Graduação em Engenharia Civil da Escola de Engenharia da Universidade Federal do Rio Grande do Sul. Tese (Doutorado). Porto Alegre, 1999.

BEN SLIMANE, A. RACLOT, D. EVRARD, O. SANAA, M. LEFEVRE, I. Y. LE. Bissonnais Relative contribution of rill/interrill and gully/channel erosion to small reservoir siltation in Mediterranean environments *Land Degradation & Development*, 27 (3) (2016), pp. 785-797.

BHUSHAN, N. & K. RAI (2004). *Strategic decision making*. Applying the Analytic Hierarchy Process. London, GBR: Springer.

Bibliometrix R Package. 2016. Massimo Aria & Corrado Cuccurullo. Disponível em: <<http://www.bibliometrix.org/>> Acesso em: 11 de setembro de 2017.

BIGARELLA, J. J.; MAZUCHOWSKI, J. Z. Visão integrada da problemática da erosão. In: *Simpósio Nacional de Controle de Erosão*, 3., 1985. Maringá, PR, Livro Guia... São Paulo: ABGE, 1985. 332p.

BIGARELLA, J. J.; SALAMUNI, R.; AB`SABER, A. N. -1961- Origem e ambiente de deposição da Bacia de Curitiba. *Boletim Paranaense de Geografia*, UFPR, Curitiba, n.4/5, p.71-81.

BRAGA, A. P.; DE CARVALHO, A. P. L. F.; LUDERMIR, T. B. (2007) *Redes Neurais Artificiais – Teoria e Aplicações*, Editora LTC, 2a. edição, ISBN: 9788521615644.

BRASIL. Casa Civil. *Lei 6.938/81*, de 31 de Agosto de 1981. Diário Oficial da União, Brasília, 1981.

BRASIL. Instituto Brasileiro de Geografia e Estatística (IBGE). *Cidades*. Disponível em: <<http://cidades.ibge.gov.br/xtras/home.php?lang=>>> Acesso em: 17, dez. 2017.

BRIOZO, R. A.; MUSETTI, M. A. Método multicritério de tomada de decisão: aplicação ao caso da localização espacial de uma Unidade de Pronto Atendimento – UPA 24 h. *Gest. Prod. [online]*. 2015, vol.22, n.4, pp.805-819. Epub Sep 29, 2015. ISSN 1806-9649. <https://doi.org/10.1590/0104-530X975-13>.

CÂMARA, G.; ORTIZ, M.J. “*Sistemas de Informação Geográfica para Aplicações Ambientais e Cadastrais: Uma Visão Geral*” . In: Souza E SILVA, M., “*Cartografia, Sensoriamento e Geoprocessamento*”, cap. 2, pp.59-88. Lavras, UFLA/SBEA, 1998.

CAMPAGNA, A.F., FRACÁRIO, R., RODRIGUES, B.K., ELER, M.N., VERANI, N.F. & ESPÍNDOLA, E.L.G., 2008. Analysis of the sediment toxicity of Monjolinho River, São Carlos, São Paulo State, Brazil, using survey, growth and gill morphology of two fish species (*Danio rerio* and *Poecilia reticulata*). *Brazilian Archives of Biology and Technology*, vol. 51, no. 1, pp. 193-201.

CAMPANELLI, L.C. *Zoneamento (Geo) Ambiental analítico da Bacia hidrográfica do rio Monjolinho – São Carlos (SP)*. Dissertação de Mestrado. 2012. PPGEU / UFS-CAR. 184 p.

CARVALHO, A. C. P. *Integração de atributos morfológicos e geotécnicos para definição de zona sujeitas à inundação na Bacia do Ribeirão Bocaina (MG)*. 2017. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017a.

CARVALHO, A. P. P. *Mapeamento geoambiental do município de Delfinópolis (MG)*.

2017. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017b.

CASTILLO, C. J. A. GÓMEZ. A century of gully erosion research: Urgency, complexity and study approaches. *Earth-Science Reviews*, 160 (2016), pp. 300-319.

CASTRO-FRANCO, M., M. B. DOMENECH, M. R. BORDA, AND J. L. COSTA. 2018. A spatial dataset of topsoil texture for the southern Argentine Pampas. *Geoderma Regional* 12:18–27. doi:10.1016/j.geodrs.2017.11.003.

CEREDA JUNIOR, A. *Análise da fragilidade ambiental com métodos multicritérios – críticas e propostas metodológicas*. 2011. Tese (Doutorado) Programa de Pós-Graduação em Engenharia, Urbana Universidade Federal de São Carlos, São Carlos. 2011.

CEREDA JUNIOR, A. *Mapeamento da fragilidade ambiental na bacia do Ribeirão do Monjolinho – São Carlos – SP – utilizando ferramentas de geoprocessamento*. 2006. Dissertação (Mestrado) Programa de Pós-Graduação em Engenharia, Urbana Universidade Federal de São Carlos, São Carlos. 2006.

CHRISTOFOLETTI, A. *Geomorfologia*. São Paulo: Edgard Blücher. 1980.

CHUNG, C. F.; FABBRI, A. G. Validation of spatial prediction models for landslide hazard mapping. *Natural Hazards*, 30 (3) 2003, pp. 451-472.

COLE, S., E. MIKHAILOVA, C. POST, C. PRIVETTE, M. A. SCHLAUTMAN, AND M. COPE. 2017. Comparing SSURGO data with geospatial field measurements to estimate soil texture and infiltration rate classes in glaciated soils. *Communications in Soil Science and Plant Analysis* 48 (11):1309–18. doi:10.1080/00103624.2017.1341916.

COLLINS, W. D., 2001: *Effects of enhanced shortwave absorption on coupled simulations of the tropical climate system*. *J. Climate*, 14, 1147–1165.

COSTA, C. W. Mapeamentos geoambientais, em escala 1:50.000, aplicados em análises de planejamento territorial de manancial periurbano: bacia do Ribeirão Feijão, São Carlos, SP. Tese (Doutorado) Universidade Federal de São Carlos. São Carlos, 2017, 166f.

COSTA, C. W.; LORANDI, R.; SERIKAWA, V. S.; FERREIRA, T. S.; STANGANINI, F. N.; GONÇALVES NETO, P. S.; LOLLO, J. A. Análise multicritério aplicada à seleção de áreas para implantação de aterros sanitários na Bacia do Ribeirão do Meio (Leme, SP), em escala 1:50.000. *Sociedade & Natureza (UFU. ONLINE)*, v. 30, p. 205-227, 2018.

COSTA, C. W.; PIGA, F. G.; MORAES, M. C. P.; DORICI, M.; SANGUINETTO, E. C.; LOLLO, J. A.; MOSCHINI, L. E.; LORANDI, R.; OLIVEIRA, L. J. Fragilidade ambiental e escassez hídrica em bacias hidrográficas: Manancial do Rio das Araras - Araras, SP. Vol. 20 n° 4. *Revista Brasileira de Recursos Hídricos*, 2015. DOI: 10.21168/rbrh. v20n4. p946-958.

COSTA, C.W.; LORANDI, R.; DE LOLLO, J.A. Surface runoff and accelerated erosion in a periurban wellhead area in southeastern Brazil. *Environment Earth Science* (2018) 77: 160.

COTTAS, L. R. *Estudos geológico-geotécnicos aplicados ao planejamento urbano de Rio Claro-SP*. Tese (Doutorado em Geologia Geral e de Aplicação). Volume 1. 1983. Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 1983.

CURCIO, D., G. CIRAULO, F. D'ASARO, AND M. MINACAPILLI. 2013. Prediction of soil texture distributions using VNIR-SWIR reflectance spectroscopy. *Procedia Environmental Sciences* 19:494–503. doi:10.1016/j.proenv.2013.06.056.

D'AGOSTINI, L. R. *Erosão: o problema mais que o processo*. Florianópolis: Ed. UFSC, 1999. 131p.

DAEE – Departamento de Águas e Energia Elétrica do Estado de São Paulo. *Banco de dados Pluviométricos e Pluviográficos do Estado de São Paulo*. Disponível em: <http://www.dae.sp.gov.br>. Acesso em: 13 de Junho de 2018.

DANTAS-FERREIRA, M. *Análise da evolução dos processos erosivos acelerados em áreas urbanas e das técnicas de controle e recuperação: córrego do Tucum (São Pedro/SP)*. 2004. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004. doi:10.11606/D.18.2004.tde-08072008-110310.

DEWITTE, M. DAOUDI, C. BOSCO, M. VAN DEN EECKHAUT. Predicting the susceptibility to gully initiation in data-poor regions. *Geomorphology*, 228 (2015), pp. 101-115.

DIXON, B. Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis. *Journal of Hydrology*, 309. 2005, pp. 17-38.

DOBARCO, M. R., D. ARROUAYS, P. LAGACHERIE, R. CIAMPALINI, AND N. P. A. Saby. 2017. Prediction of topsoil texture for Region Centre (France) applying model ensemble methods. *Geoderma* 298:67–77. doi:10.1016/j.geoderma.2017.03.015.

DOGRU, A.O., KAHRAMAN, A., SEKER, D.Z., SIVRI, N. Hide details. GIS based evaluation of social determinants of children's health in Turkey: Case study of Istanbul. *Environmental Research*, Volume 179, December 2019.

DOMAZETOVIĆ, F. A. ŠILJEG, F. LONČAR, N. MARIĆ, I. Development of automated multicriteria GIS analysis of gully erosion susceptibility. *Applied Geography*, 112 (2019) pp. 1-12.

DUBOIS, D.; PRADE, H.; YAGER, R. R. *Fuzzy information engineering: a guided tour of applications*. [S.l.]: John Wiley and Sons, Inc., 1996.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification 2/E*. New York, NY:

Wiley Interscience, 2000.

EBRU AKCAPINAR SEZER, BISWAJEET PRADHAN, CANDAN GOKCEOGLU. Manifestation of an adaptive neuro-fuzzy model on landslide susceptibility mapping: Klang valley, Malaysia. *Expert Systems with Applications*, 40, (2013), Pages 2360.

EGLER, C. A. G.; CRUZ, C. B. M.; MADSEN, P. F. H.; COSTA, S. M.; SILVA, E. A. *Proposta de zoneamento ambiental da Baía de Guanabara*. Disponível em: <http://www.laget.igeo.ufrj.br/egler/pdf/zeegb.pdf>. Acessado em: 01/06/2017.

EIRAS, C. G. S. *Mapeamento de susceptibilidade a eventos perigosos de natureza geológica e hidrogeológica em São Carlos - SP*. 2017. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

ELLISON, W.D. 1947. *Soil erosion studies* - Part I: Agric. Eng. 28:145-146.

ELLISON, W.D.; O.T. Ellison. 1947, *Soil erosion studies* - Part VI: Soil detachment by surfasse flow. Agric. Eng. 28:402-408.

ELSEVIER. 2019. *Scopus*. Editora Elsevier. Disponível em: <<https://www.elsevier.com/americalatina/pt-br/scopus>>. Acesso em: 20 de janeiro de 2019.

ERCANOGLU, M.; GOKCEOGLU, C. Assessment of landslide susceptibility for a landslide-prone area (north of Yenice, NW Turkey) by fuzzy approach. *Environmental Geology*, 41 (2002), pp. 720-730.

ERKTAN, A. CÉCILLON, L. F. GRAF, ROUMET, C. C. LEGOUT, F. REY. Increase in soil aggregate stability along a mediterranean successional gradient in severely eroded gully bed ecosystems: Combined effects of soil, root traits and plant community characteristics *Plant and Soil*, 398 (1-2) (2016), pp. 121-137.

ESRI. Environmental Systems Research Institute. *ArcGIS for the desktop 10.5*, 2016.

FAILACHE, M. F. *Estudo comparativo de duas metodologias na definição de unidades geoambientais: Ribeirão do Feijão (São Carlos-SP) / Moisés Furtado Failache*. - São Carlos: UFSCar, 2015. 200 f.

FAILACHE, M. F. *Proposta de procedimentos para a estimativa da infiltração potencial e do escoamento superficial Hortoniano potencial baseada em dados geológicos, geotécnicos, de uso e ocupação e eventos de chuva*. 2018. Tese (Doutorado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018. doi:10.11606/T.18.2018.tde-19062018-094526. Acesso em: 2018-11-03.

FARIA, D.G.M.; AUGUSTO FILHO, O. Aplicação do Processo de Análise Hierárquica (AHP) no mapeamento de perigo de escorregamentos em áreas urbanas. *Revista do Instituto Geológico*, v. 34, p. 23-44, 2013.

FINNIE, G.R.; WITTIG, G.E. *An Intelligent Web Tool for Collection of Comparative Survey Data*. School of Information Technology Bond University, Austrália. 1999, p. 310-321.

FITZ, Paulo Roberto, *Geoprocessamento sem Complicação*, São Paulo, Ed. Oficina de Textos, 2008.

GANDOLFI, N.; ZUQUETTE, L.V. Discussão e adaptação de metodologia para mapeamento geotécnico. In *Congresso Latino-Americano de Geologia*, 5, Argentina, 1982. Atas. Argentina, v.III, p.245-258.

GIMENES, F. B. Q.; AUGUSTO FILHO, O. Mapas de Fragilidade Ambiental utilizando o Processo de Análise Hierárquica (AHP) e Sistema de Informação Geográfica (SIG). In: *Simpósio Brasileiro de Sensoriamento Remoto*, 16. (SBSR), 2013, Foz do Iguaçu. Anais... São José dos Campos: INPE, 2013. p. 6564-6571.

GOMES, D. M. *Mapeamento geológico-geotécnico para análise de feições erosivas concentradas na bacia do córrego Ribeirão do Meio, região de São Pedro – SP, na escala de 1: 20.000*. São Carlos, 2002. Dissertação (Mestrado). Escola de Engenharia de São Carlos da Universidade de São Paulo, 2002.

GOMES, F. S. *Estudo da erodibilidade e parâmetros geotécnicos de um solo em processo erosivo*. Recife, 2001. Dissertação (Mestrado). Universidade Federal de Pernambuco. Centro de Tecnologia e Geociências. Mestrado em Engenharia Civil, 2001.

GOMES, M. V. *Escoamento superficial, geometria e perfil de alteração na análise de estabilidade de taludes de corte nas Formações Botucatu, Tabulares*. 2018. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

GOMES, W. S.; DANTAS-FERREIRA, M. Áreas Degradadas na microbacia do Córrego da Água Quente, São Carlos-SP. In: *Simpósio Nacional de Geomorfologia*, 2012, Rio de Janeiro. 9º SINAGEO - Simpósio Nacional de Geomorfologia, 2012. v. 1. p. 1-4.

GÓMEZ-GUTIÉRREZ, Á. C. CONOSCENTI, S.E. ANGILERI, E. ROTIGLIANO, S. SCHNABEL. Using topographical attributes to evaluate gully erosion proneness (susceptibility) in two mediterranean basins: Advantages and limitations. *Natural Hazards*, 79 (1) (2015), pp. 291-314.

GONÇALVES, A. P. *Aplicação de Lógica Fuzzy em Guerra Eletrônica*. Instituto Tecnológico da Aeronáutica, 2007.

GRECCHI, R. C. *Zoneamento geoambiental da região de Piracicaba-SP, com auxílio de geoprocessamento*. 1998. 132 f. Dissertação de Mestrado. Escola de Engenharia de São Carlos/USP, São Carlos. 1998.

GREHS, S. A. A importância do geólogo no estudo preventivo de escorregamentos, deslizamentos e outros aspectos correlatos. In: *Congresso Brasileiro de Geologia*,

21. *Anais*. Curitiba, SBG, 1967. p.119-123.

GRIMALT, J.O. BÖSE-O'REILLY, S. VAN DEN HAZEL, P. Steps forward reduction of environmental impact on children's health. *Environ. Res.*, 164 (July 2018), pp. 184-185. 2017.

GUSTAFSON, E. J.; PARKER, G. R. Relationships between landcover proportion and indices of landscape spatial pattern. *Landscape Ecology*, v. 7, n. 2, p. 101-110, 1992.

HABERLEHNER. Princípios de mapeamento geotécnico. In: *Congresso Brasileiro de Geologia*, 22. Resumos. SBG. Rio de Janeiro. 1960. p37-39.

HAIR, J. F.; TATHAM, R. L.; ANDERSON, R. E.; BLACK, W. *Análise Multivariada De Dados*. Porto Alegre: Bookman, 2009, 5. ed., 593 p.

HARRIS-LOVETT, J. LIENERT, D. SEDLAK. A mixed-methods approach to strategic planning for multi-benefit regional water infrastructure. *J. Environ. Manag.*, 233 (2019), pp. 218-237

HAYKIN, S. *Neural networks: a comprehensive foundation*, 2/E. New York, NY: Prentice Hall, Inc., 1999.

HECHT, A. D. The triad of sustainable development: promoting sustainable development in developing countries. *Journal of Environment and Development*. Vol. 8, n. 2, junho, 111-132. Sage Publications, 1999.

HEINE, D. Levantamento geotécnico do estado da Guanabara. In: *Congresso Brasileiro de Geologia*, 20. *Anais*. SBG. Rio de Janeiro. 1966. p41.

HOU, Z., SHEN, Q., AND LI, H. Nonlinear system identification based on ANFIS. *Proceedings of 2003 IEEE International Conference on Neural Networks & Signal Processing*, 1, 2003. 510-512.

HUTCHINSON, M. F. A new procedure for gridding elevation na stream line data with automatic removal of spurious pits. *Journal of Hidrology* 106: 211-232. 1989.

HUTCHINSON, M. F. Calculation of hidrologically sound digital elevation models. Paper presented at Third *International Symposium on Spatial Data Handling at Sydney*, Australia. 1988.

IBGE-INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Cartas topográficas, folhas: Araraquara (SF-22-X-D-VI-4); São Carlos (SF-23-Y-A-I-1); Ibaté (SF-23-V-C-IV-3); Ribeirão Bonito (SF-22-Z-B-III-2); na escala 1:50.000.

ISLAM, R. MD; JAAFAR, W. Z. W; HIN, S. L.; OSMAN, N.; HOSSAIN, A; MOHD, N. S. Development of an intelligent system based on ANFIS model for predicting soil erosion. *Environmental Earth Sciences* (2018) 77-186.

JANG, J. S.; SUN, C.T. Neuro-fuzzy modeling and control. *Proceedings of the IEEE*,

*IEEE*, v. 83, n. 3, p. 378-406, 1995.

JANG, J., SUN, C., AND MIZUTANI, E. (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, Prentice Hall, New Jersey, U.S.A.

JANG, S. R. *Neuro-fuzzy modeling: architecture, analyses and applications*, Dissertation, Department of Electrical Engineering and Computer Science, University of California, Berkeley, CA 94720. 1992.

JANG, S. R., "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 23, no. 3, pp. 665-685, 1993.

JIANG, H.; EASTMAN, J.R. Application of Fuzzy Measures in Multi-Criteria Evaluation in GIS. *International Journal of Geographical Information Science*, 14, 2000. 173-184. <http://dx.doi.org/10.1080/136588100240903>

KANUNGO, D.P.; ARORA, M.K.; GUPTA, R.P.; SARKAR, S. Landslide risk assessment using concepts of danger pixels and fuzzy set theory in *Darjeeling Himalayas. Landslides*, 5 (2008), pp. 407-416.

KANUNGO, D.P.; ARORA, M.K.; SARKAR, S.; GUPTA, R.P. A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas. *Engineering Geology*, 85 (2006), pp. 347-366.

KASABOV, N. K.; SONG, Q. Den\_s: Dynamic evolving neural-fuzzy inference system and its application for time-series prediction. *IEEE Transactions on Fuzzy Systems*, v. 10, n. 2, p. 144-154, 2002.

KIM, S. C. *Statistical Issues in Combining Expert Opinions for Analytic Hierarchy Process*. Soongsil University. 1999. 1-2pp.

KIMERLING, J. *Sistemas de Informações Geográficas e Cartografia*. Associação Cartográfica Universal, 1994.

KÖPPEN, W. *Climatologia*. México: Fondo de Cultura Económica, 1948, 478p.

KOSKO, B. *Neural Networks and Fuzzy Systems*. Englewood Cliffs, NJ: Prentice-Hall, 1992.

LAL, R. *Soil erosion in the tropics: principles and management*. New York: McGraw-Hill, 1990. 580 p.

LEE, C. C. Fuzzy logic in control system: Fuzzy logic controller - part 1. In: *IEEE Transactions on Systems, Man, and Cybernetics* [S.l.:s.n.], 1990a. v. 20, n. 2, p. 404-418.

LEE, C. C. Fuzzy logic in control system: Fuzzy logic controller - part 2. In: *IEEE Transactions on Systems, Man, and Cybernetics* [S.l.:s.n.], 1990b. v. 20, n. 2, p.

419-435.

LEE, S. Application and verification of fuzzy algebraic operators to landslide susceptibility mapping. *Environmental Geology*, 52 (2007), pp. 615-623.

LEE, S; B. PRADHAN, B. Probabilistic landslide risk mapping at Penang Island, Malaysia. *Journal of Earth System Sciences*, 115 (6) 2006, pp. 661-672.

LIMA, F. I. de. *Estudo geoambiental de bacias hidrográficas utilizando o modelo PER no município de São Carlos (SP)*. 2016. Dissertação (Mestrado em Geotecnia) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016. doi:10.11606/D.18.2017.tde-08062017-161832. Acesso em: 2018-11-03.

LIPORACI, S. *Mapeamento geológico-geotécnico visando estudos sobre a erosão/assoreamento e potencial escoamento superficial da bacia do monjolinho em São Carlos – SP*. 2003. Tese (Pós-Doutorado) Departamento de Engenharia Civil, Universidade Federal de São Carlos, São Carlos, 2003.

LLOPIS TRILLO, G. “Control de la erosión y obras de desagüe” - Manual de Estabilización y Revegetación de Taludes. Entorno Grafico S. L., Madri. 1999.

MACIEL, G. de C. *Geologia e geomorfologia*. In: ESPÍNDOLA, E. L. G.; SILVA, J. S. V.; MARINELLI, C. E.; ABDON, M. M. A bacia hidrográfica do rio do Monjolinho. São Carlos: Ed. Rima, 2000.

MAGRI, R. A. F. *Análise da suscetibilidade à erosão da região do Médio Rio Grande (MG)*. 2013. Dissertação (Mestrado) – Programa de Pós-Graduação e Área de Concentração em Geotecnia – Escola de Engenharia de São Carlos. Universidade de São Paulo, 2013.

MALCZEWSKI, J. *Based Land-Use Suitability Analysis: A Critical Overview*. Progress in Planning, 2004. 62, 3-65.

MARARAKANYE, N. SUMNER, P.D. Gully erosion: A comparison of contributing factors in two catchments in South Africa. *Geomorphology*, 288 (2017), pp. 99-110.

MENDONÇA, F; DANNI-OLIVEIRA, I. M. *Climatologia: noções básicas e climas do Brasil*. Oficina de textos. São Paulo. 2007. 206p.

MIDOUHAS, E. KOKOSI, T. FLOURI, E. Outdoor and indoor air quality and cognitive ability in young children. *Environ. Res.*, 161 (2017), pp. 321-328.

MIKHAILOVA, E. A., C. J. POST, M. A. SCHLAUTMAN, J. M. GALBRAITH, AND H. A. ZURQANI. 2018. Usability of soil survey soil texture data for soil health indicator scoring. *Communications in Soil Science and Plant Analysis* 49 (15):1826–34. doi:10.1080/00103624.2018.1474918.

MMA (Ministério do Meio Ambiente) *Zoneamento ecológico-econômico*. Acessado em: Disponível em: <www.mma.gov.br> Acessado em: 2 de julho de 2018.

MONTAÑO, M. (2005). *A aplicação conjunta de método de projeção das alterações no uso e ocupação do solo e de instrumentos de política ambiental: o caso do município de São Carlos (SP)*. Tese de doutorado em Engenharia Civil – Hidráulica e Saneamento. Escola de Engenharia de São Carlos – EESC. Universidade de São Paulo – USP. São Carlos, 2005.

MONTAÑO, M.; OLIVEIRA, I. S. D.; RANIERI, V. E. L.; FONTES, A. T.; SOUZA, M. P. O Zoneamento Ambiental e a sua importância para a localização das atividades. *Revista Pesquisa e Desenvolvimento Engenharia de Produção*, n.6, p.49-64, jun/2007.

MURO, M. D. *Carta de zoneamento para seleção de áreas frente à instalação de aterros sanitários no município de São Carlos - SP - escala 1:50.000*. Dissertação (Mestrado) 2v. São Carlos, 2000. Escola de Engenharia de São Carlos, Universidade de São Paulo. 2000.

MUTHU, K.; PETROU, M.; TARANTINO, C.; BLONDA, P. Landslide possibility mapping using fuzzy approaches. *IEEE Transactions on Geoscience and Remote Sensing*, 46 (2008), pp. 1253-1265.

NAKASHIMA, P. *Estudo das formações superficiais na área de Campinas, Viracopos (SP); suas relações com a evolução geomorfológica e os solos*. Universidade de São Paulo, USP. Geografia Física. São Paulo, 1973.

NAKASHIMA, P. *Sistemas pedológicos da região Noroeste do Estado do Paraná: distribuição e subsídios para o controle da erosão*. Universidade de São Paulo, USP. Geografia Física. São Paulo, 2000.

NASCIMENTO, G. GÖETHEL, B. GAUER, E. SAUER, J. NARDI, L. CESTONARO, D. CORREIA, C. PERUZZI, L. MOTA, R.V. MACHRY, T.W. FURLANETTO, T. SAINT'PIERRE, A. GIODA, M.D. ARBO, S.C. GARCIA. Exposure to environment chemicals and its possible role in endocrine disruption of children from a rural area. *Environ. Res.*, 167 (November 2018), pp. 488-498. 2018.

NISHIYAMA, L. *Mapeamento geotécnico preliminar da quadricula de São Carlos – SP*. 1991. 228 f. Dissertação (Mestrado em Geotecnia). Programa de Pós-Graduação em Geotecnia. Escola de Engenharia de São Carlos. Universidade de São Paulo, 1991.

OH, H; PRADHAN, B. Application of a neuro-fuzzy model to landslide-susceptibility mapping for shallow landslides in a tropical hilly area. *Computers & Geosciences* 37 (2011) 1264–1276.

OLIVEIRA, V. G.; MENEZES, D. B. Depósitos Antropogênicos: Evolução das Abordagens por Meio de Análise Bibliométrica / Anthropogenic Deposits: Evolution of Approaches by Bibliometric Analysis. *Anuário do Instituto de Geociências (UFRJ. Impreso)*, v. 41, p. 369-376, 2018.

PARAGUASSU, A. B. Experimental silicification of sandstone. *Geological Society of America Bulletin*, v. 83, n. 9, p. 2853-2858, 1972.

PEJON, O. J. (1992) *Mapeamento geotécnico da folha de Piracicaba-SP (escala 1:100.000): estudo de aspectos metodológicos, de caracterização e de apresentação dos atributos*. 224 f. Ph.D. thesis. Programa de Pós-Graduação em Geotecnia. Escola de Engenharia de São Carlos. Departamento de Engenharia Civil. Universidade de São Paulo, São Carlos.

PEREIRA, L. C., FORMAGGIO, A. R., STRAUCH, J. C. M. Taxa de adequação de uso das terras de uma bacia hidrográfica utilizando informações geográficas e técnicas de sensoriamento remoto. In: *Congresso brasileiro de ciência do solo. Anais*. Viçosa: MG/SBCS/UFV, 1995. v.4 p.2117-2118.

PONÇANO, W. L.; CARNEIRO, C. D. R.; BISTRICHI, C. A.; ALMEIDA, F.F. M. de; PRANDINI, F.L. *Mapa Geomorfológico do Estado de São Paulo*, Mapa 1:1.000.000 e nota explicativa; Série Monografias, Instituto de Pesquisas Tecnológicas do Estado de São Paulo-IPT, São Paulo, no . 5, 94 p. il. (IPT – Publicação 1183), 1981.

PONS, N.A.D. *Levantamento e diagnóstico geológico-geotécnico de áreas degradadas na cidade de São Carlos – SP, com auxílio de geoprocessamento*. Tese de Doutorado (210p.). Escola de Engenharia de São Carlos. Universidade de São Paulo. São Carlos. 2006.

PRADHAN, B.; LEE, S.; BUCHROITHNER, M. F. A GIS-based back-propagation neural network model and its cross-application and validation for landslide susceptibility analyses. *Computers, Environment and Urban Systems* 34 (2010) 216–235.

PRADHAN, B.; OH, H. Application of a neuro-fuzzy model to landslide-susceptibility mapping for shal-low landslides in a tropical hilly área. *Computers & Geosciences*, 37 (9) 2011, pp. 1264-1276.

PRADHAN, B; LEE, M.F. Buchroithner Use of geospatial data for the development of fuzzy algebraic operators to landslide hazard mapping: a case study in Malaysia. *Applied Geomatics*, 1 (2009), pp. 3-15.

PRADHAN, B; PIRASTEH, P. Comparison between prediction capabilities of neural network and fuzzy logic techniques for landslide susceptibility mapping. *Disaster Advances*, 3 (2) (2010a), pp. 26-34.

PRADHAN, B; YOUSSEF, A.M. Manifestation of remote sensing data and GIS on landslide hazard analysis using spatial-based statistical models. *Arabian Journal of Geosciences*, 3 (3) (2010b), pp. 319-326.

PRANDINI F.L., GUIDICINI G., GREHS S.A. 1974. Geologia ambiental ou de planejamento. In: *Congresso Brasileiro de Geologia*, 28, Porto Alegre, 1974. *Anais.*, Porto Alegre, SBG. V.7, p. 273-290.

RODRIGUES, D. R. *Um Modelo de Rede Neuro-Fuzzy Baseada em Funções de Base Radial Capaz de Inferir Regras do Tipo Mamdani*. Dissertação (Mestrado) Universidade Federal de Santa Catarina. Florianópolis, 2015. 71f.

- RODRÍGUEZ-MERINO, A., GARCÍA-MURILLO, P., FERNÁNDEZ-ZAMUDIO, R. Combining multicriteria decision analysis and GIS to assess vulnerability within a protected area: An objective methodology for managing complex and fragile systems. *Ecological Indicators*, Volume 108, January 2020.
- ROMANELLI, J. P.; FUJIMOTO, J. T.; DANTAS-FERREIRA, M; MILANEZ, D. H. Assessing ecological restoration as a research topic using bibliometric indicators. *Ecological Engineering*, v. 120, p. 311-320, 2018.
- ROY, B. *Multicriteria Methodology for Decision Aiding*. Dordrecht: Kluwer Academic Publishers. 1996.
- SAATY, T. L. A. Scaling method for priorities in hierarchical structures. *Journal of mathematical psychology*, 15, p. 234-281, 1977.
- SAATY, T. L. *Método de análise hierárquica*. Tradução e revisão técnica Wainer da Silveira e Silva. São Paulo: Makron Books, 1991. 326p.
- SAATY, T. L. *The Analytic Hierarchy Process*. N. York, USA: McGraw-Hill.1980.
- SAATY, T. L. *Theory and applications of the Analytic Network Process*. Decision making with benefits, opportunities, costs, and risks. Pittsburgh, USA: RWS. 2005.
- SAATY, T.L. *The analytic hierarchy process*. New York, McGraw Hill, 1980.
- SABOYA, R. Análises espaciais em planejamento urbano: novas tendências. *Revista Brasileira de Estudos Urbanos e Regionais*, v. 3, p. 61 -79, 2000.
- SANCHEZ, M.C. A propósito das cartas de declividade. In: *Simpósio de Geografia Física Aplicada*. 5, São Paulo, 311-314, 1993.
- SANDMANN, H. *Predição não-linear de séries temporais usando sistemas de arquitetura neuro-fuzzy*. 2006. 72 p. Dissertação (Mestrado) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2006.
- SANDRI, S.; CORREA, C. *Lógica Nebulosa*. Instituto Tecnológico da Aeronáutica, 1999.
- SÃO PAULO (Estado) Divisão de Minas e Geologia Aplicada. Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT). *Mapa Geológico do Estado de São Paulo – escala 1:500.000*. Instituto de Pesquisas Tecnológicas do Estado de São Paulo. São Paulo: IPT, volume I, 1981.
- SÃO PAULO (Estado). Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT) - *Carta geotécnica dos morros de Santos e São Vicente*. Monografias N° 3. Publicação IPT N° 1153. São Paulo, 1980.
- SÃO PAULO (Estado). Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT). *Determinação de áreas críticas à erosão ao longo das faixas marginais dos reservatórios dos rios Tietê e Paranapanema*. Relatório 26.769, 1989.

SÃO PAULO (Estado). Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT). *Determinação de áreas críticas à erosão ao longo das faixas marginais dos reservatórios dos rios Tietê e Paranapanema*. Relatório 26.769, 1989.

SEYEDMOHAMMADI, J., NAVIDI, M. N., ESMAEELNEJAD, L. Geospatial modeling of surface soil texture of agricultural land using fuzzy logic, geostatistics and GIS techniques. 2019. *Communications in Soil Science and Plant Analysis* 50: 1452-1464. doi.org/10.1080/00103624.2019.1626870.

SEZER, E. A.; PRADHAN, B.; GOKCEOGLU, C. Manifestation of an adaptive neuro-fuzzy model on landslide susceptibility mapping: Klang valley, Malaysia. *Expert Systems with Applications* 38 (2011) 8208–8219.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais para engenharia e ciências aplicadas*, Artliber, 2010.

SILVA, J. dos S. V. da; ABDON, M. de M.; PARANAGUÁ, P. A. Remanescentes de vegetação. In: ESPÍNDOLA, E. L. G.; SILVA, J. S. V.; MARINELLI, C. E.; ABDON, M. M. *A bacia hidrográfica do rio do Monjolinho*. São Carlos: Ed. Rima, 2000.

SINGH, A. Environmental problems of salinization and poor drainage in irrigated areas: management through the mathematical models. *J. Clean. Prod.*, 206 (2019), pp. 572-579.

SINGH, A. Poor-drainage-induced salinization of agricultural lands: management through structural measures. *Land Use Pol.*, 82 (2019), pp. 457-463.

SINGH, A. Remote sensing and GIS applications for municipal waste management. *Journal of Environmental Management*. 243 (2019c) Pp 22-29.

SOUZA, L. A. *Cartografia Geoambiental e Geotécnica Progressiva em Diferentes Escalas: Aplicação na Bacia Hidrográfica do Ribeirão do Carmo, Municípios de Ouro Preto e Mariana, Minas Gerais.*, Ano de obtenção: 2015.

SOUZA, M. L. *Proposta de um Sistema de Classificação de Feições Erosivas Voltados à Estudos de Procedimentos de Análises de Decisões Quanto a Medidas Corretivas, Mitigadoras e Preventivas: aplicação no município de Umuarama (PR)*, Unesp: 2001.

SOUZA, N. C. *Dinâmica do Uso e Ocupação da Terra Associada ao Crescimento de Processos Erosivos Lineares e aos Aspectos Sóciodemográficos e Físico-estruturais*. Tese (Doutorado) Programa de Pós-Graduação em Engenharia, Urbana Universidade Federal de São Carlos, São Carlos. 198f. 2020.

SOUZA, N. C. *Geotecnologias na Análise da Suscetibilidade e Risco de Processos Erosivos em Áreas de Entorno de Linhas Férreas Estudo De Caso: Malha Paulista – SP (Bacia Do Tietê –Sorocaba)*. Dissertação (Mestrado) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2015.

SOUZA, N. C.; OLIVEIRA, V. G.; LOLLO, J. A. Perception of Risk and Sustainability: Concept Analysis of Environmental Justice and Sustainable Development in

Geological-Geotechnical Risk Assessment Approaches. *Geotechnical and Geological Engineering*, v. 37, p. 1-12, 2019.

STANGANINI, F. N. *Modelagem da dinâmica espacial do uso da terra para o município de São Carlos: condições pretéritas e futuras* / Fábio Noel Stanganini. São Carlos: UFSCar, 2016. 206 p. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Urbana, Universidade Federal de São Carlos, São Carlos, 2016.

STRAHLER, A. N. Hypsometric (area-altitude) analysis of erosional topography. *Geological Society of America Bulletin*, v. 63, n. 11, p. 1117-1142, 1952.

SUGENO, M.; TAKAGI, T. A new approach to design of fuzzy controller. In: *Advances in Fuzzy Sets, Possibility Theory, and Applications*. [S.l.]: Springer, 1983. p. 325-334.

SWINGLER, K. *Applying Neural Networks: A Practical Guide*, Academic Press, New York, 1996.

TAKAGI, T. ; SUGENO, M. Fuzzy identification of systems and its application to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, 15, (1): 116-132, 1985.

TAKAGI, T., SUGENO, M. Derivation of fuzzy control rules from human operator's control actions. In: *Proceedings of the IFAC Symposium on Fuzzy Information, Knowledge Representation and Decision Analysis*, July 1983, pp. 55-60.

Tarik Dogru, T.; Sirakaya-Turk, E.; Crouch, G. Remodeling international tourism demand: Old theory and new evidence, *Tourism Management* (60) 2017, pp 47-55, ISSN 0261-5177 (<https://doi.org/10.1016/j.tourman.2016.11.010>).

TEIXEIRA, W.; FAIRCHILD, T. R.; TOLEDO, M. C. M.; TAIOLI, F. *Decifrando a Terra*. [S.l: s.n.], 2009.

TEODORO, V; TEIXEIRA, D; COSTA, D.J.L; FULLER, B.B. O conceito de bacia hidrográfica e a importância da caracterização morfométrica para o entendimento da dinâmica ambiental local. *Revista Uniara*, n.20. p 22-29. 2007.

TOMA, T.; ASHARIF, M.R. *AHP coefficients optimization technique based on GA*. Department of Information. Engineering of University of Ryukyus, Japão. 2003.

TRENTIM, M. *Tomada de decisão em projetos: método AHP*. Disponível em: <<http://blog.mundopm.com.br/2012/05/02/tomada-de-decisao-em-projetos-%e2%80%93-93-metodo-ahp/>>. 2018

TUNUSLUOGLU, M. C.; GOKCEOGLU, C.; NEFESLIOGLU, H. A.; SONMEZ, H. Extraction of potential debris source areas by logistic regression technique: a case study from Barla, Besparmak and Kapi mountains (NW Taurids, Turkey). *Environmental Geology*, 54 (1) 2008, pp. 9-22

UNITED NATIONS 4. *The cost of a polluted environment, the official website of World*

*Health Organization*. <http://www.who.int/mediacentre/news/releases/2017/pollution-child-death/en/>, Acessado 25. Jan.2019.

UNITED NATIONS. *World Population Prospects: 2017 Revision Population Database*. online at (2017). 2nd December 2017.

UNITED STATES – United States Geological Survey (USGS). *LANDSAT8*. Cena: LC82200752014078LGN00. Disponível em: <<http://earthexplorer.usgs.gov/>> Acesso em: 13/06/2018.

VALERIANO, M.M. *TOPODATA*: guia para utilização de dados geomorfológicos locais. Instituto Nacional de Pesquisas Espaciais, Relatório INPE-15318-RPQ/818, 75 p. 2008.

VALERIANO, M.M.; ALBUQUERQUE, P.C.G. *TOPODATA*: processamento dos dados SRTM. Instituto Nacional de Pesquisas Espaciais, Relatório INPE-16702-RPQ/854, 81 p. 2010.

VALLEJO, L. I. G.; FERRER, M; ORTUÑO, L.; OTEO, C. *Ingeniería geológica*. Madrid: Pearson Educación, 2002.

VANMAERCKE, M. POESEN, J. VAN MELE, B. DEMUZERE, M. BRUYNSEELS, A. V. Golosov. How fast do gully headcuts retreat?. *Earth-Science Reviews*, 154 (2016), pp. 336-355i dr.

VOSVIEWER: *Visualizing Scientific Landscapes*. 2018. Versão 1.6.6. Netherlands: Centre For Science And Technology Studies, Leiden University. Disponível em: <<http://www.vosviewer.com/>>

WANG, H., PAN, Y., LUO, X. Hide details. Integration of BIM and GIS in sustainable built environment: A review and bibliometric analysis. *Automation in Construction*, Volume 103, July 2019.

ZACHAR, O. *Soil erosion*. Elsevier, 547 pp. 1982, Amsterdam.

ZADEH, L. A. *Fuzzy Sets*. Berkeley, California, October 1965.

ZADEH, L. A. Outline of a new approach to the analysis of complex systems and decision processes. In: *IEEE Transactions on Systems, Man, and Cybernetics*. [S.l.: s.n.], 1973. v. 3, n. 1, p. 28-44.

Zadeh, Lotfi A. 1996. *Fuzzy Sets, Fuzzy Logic, and Fuzzy Systems*: Selected Papers by Lotfi A. Zadeh. In Klir, G.J. and Yuan, B. (eds.) Singapore and River Edge, New Jersey: World Scientific.

ZANATA, M.; PISSARRA, T. C. T.; ARRAES, C. L.; RODRIGUES, F. M.; CAMPOS, S. Influência da escala na análise morfométrica de microbacias hidrográficas. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.15, n.10, p.1062-67, 2012.

ZUQUETE, L. V.; PEJON, O. J.; GANDOLFI, N.; RODRIGUES, J. E. Mapeamento

Geotécnico: Parte 1 - Atributos e Procedimentos Básicos para a Elaboração de Mapas e Cartas. São Paulo: *Geociências*, 16:491-524. 1997.

ZUQUETTE, L. V. *Análise Crítica da Cartografia Geotécnica e Proposta metodológica para as Condições Brasileiras*. Tese (Doutorado) 673f. Escola de Engenharia de São Carlos. Universidade de São Paulo. São Carlos, 1987.

ZUQUETTE, L. V. *Importância do mapeamento geotécnico no uso e ocupação do meio físico; fundamentos e guia para elaboração*. São Carlos. Tese (Livre-Docência) 330. Escola de Engenharia de São Carlos, Universidade de São Paulo. 2, 1993.

ZUQUETTE, L. V. *Mapeamento geotécnico preliminar na região de São Carlos*. Dissertação de Mestrado. Escola de Engenharia de São Carlos. USP. São Carlos. 1981.

ZUQUETTE, L.V.; PALMA, J. B.; PEJON, O. J. Methodology to assess groundwater pollution conditions (current and pre-disposition) in the São Carlos and Ribeirão Preto regions, Brazil. *Bull. Eng. Geol Environment*. V. 68. 2009. p 177-136.

---

# Apêndice

## 1 Rotina computacional para treinamento de redes neurais artificiais para o mapeamento de susceptibilidade a erosão

**%Main Script**

**% Passo 1 - Carregamento dos dados do Shapefile (ArcGis)**

dataset\_load;

**% Passo 2 - Ajuste dos dados removendo as inconsistências**

dataset\_adjustment;

**% Passo 3 - Preparar os conjuntos de Treinamento, Validação e Teste**

% Training Set: this data set is used to adjust the weights on the neural network.

% Validation Set: this data set is used to minimize overfitting.

You're not adjusting the weights of the network with this data set, you're just verifying that any increase in accuracy over the training data set actually yields an increase in accuracy over a data set that has not been shown to the network before, or at least the network hasn't trained on it (i.e. validation data set). If the accuracy over the training data set increases, but the accuracy over the validation data set stays the same or decreases, then you're overfitting your neural network and you should stop training.

% Testing Set: this data set is used only for testing the final solution in order to confirm the actual predictive power of the network.

```
Ptr = 0.85;
Pval=0.15;
Ptes=0.0;
[TrainingData1, ValidationData1, TestingData1, inputData1, output-
Data1] = dataset_preparation(Data1,Ptr,Pval,Ptes,false);
[TrainingData1n, ValidationData1n, TestingData1n, inputData1n, ou-
tputData1n] = dataset_preparation(Data1_n,Ptr,Pval,Ptes,false);
[TrainingData2, ValidationData2, TestingData2, inputData2, output-
Data2] = dataset_preparation(Data2,Ptr,Pval,Ptes,false);
[TrainingData2n, ValidationData2n, TestingData2n, inputData2n, ou-
tputData2n] = dataset_preparation(Data2_n,Ptr,Pval,Ptes,false);

%% Passo 3 - Treinar a rede perceptron de uma única camada (hidden
layer)
hiddenLayerSize = 15;
perceptron_training

% Passo 4 - Treinar a rede perceptron multicadas
hiddenLayersSize = [7, 14, 14, 1];
mlp_training;

%% Passo 5 - Treinar o sistema de inferência fuzzy ANFIS
anfis_training;

%% Passo 6 - Salvar os resultados
%Save all perceptron data
save_perceptron;
save_mlp;
save_anfis;



---


addpath(fullfile(pwd,'data2_shapefiles\shapefile set 1'));
addpath(fullfile(pwd,'data2_shapefiles\shapefile set 2 - bacia'));
%% Preprocessamento dos dados de entrada
%%DATASET1
%Shapefile contendo os pontos crus pelo ArcGis
S1_1 = shaperead('Pontos_Crut.shp');
```

```
Decliv = [S1_1.Decli_Recl]';
Elev = [S1_1.Eleva_Recl]';
Geol = [S1_1.Geol_Res]';
Pluv = [S1_1.Pluvio_Rec]';
UsoSolo = [S1_1.Coher_Res]';
MI = [S1_1.MatIncon_R]';
FT = [S1_1.FT_Res]';
Erosao = [S1_1.Processos3]';
%Construir o dataset
Data1 = [Decliv, Elev, Geol, Pluv, UsoSolo, MI, FT, Erosao];
%Shapefile contendo os pontos normalizados pelo ArcGis
S1_2 = shaperead('Pontos_Fuzzy.shp');
%mapshow(S1);
Decliv = [S1_2.Declividad]';
Elev = [S1_2.Elevacao]';
Geol = [S1_2.Geologia]';
Pluv = [S1_2.Pluviometr]';
UsoSolo = [S1_2.Uso_do_Sol]';
MI = [S1_2.MI]';
FT = [S1_2.FT]';
Erosao = [S1_2.Processos3]';
%Construir o dataset normalizado
Data1_n = [Decliv, Elev, Geol, Pluv, UsoSolo, MI, FT, Erosao];

%%DATASET2
%Shapefile contendo os pontos normalizados pelo ArcGis
S2_1 = shaperead('Pt_cru_area_menor.shp');
Decliv = [S2_1.Decli_Recl]';
Elev = [S2_1.Eleva_Recl]';
Geol = [S2_1.Geol_Res]';
Pluv = [S2_1.Pluvio_Rec]';
UsoSolo = [S2_1.Coher_Res]';
MI = [S2_1.MatIncon_R]';
FT = [S2_1.FT_Res]';
Erosao = [S2_1.Processos3]';
%Construir o dataset
Data2 = [Decliv, Elev, Geol, Pluv, UsoSolo, MI, FT, Erosao];
```

```

%Shapefile contendo os pontos crus pelo ArcGis
S2_2 = shaperead('Pt_fuzzy_area_menor.shp');
Decliv = [S2_2.Declividad]';
Elev = [S2_2.Elevacao]';
Geol = [S2_2.Geologia]';
Pluv = [S2_2.Pluviometr]';
UsoSolo = [S2_2.Uso_do_Sol]';
MI = [S2_2.MI]';
FT = [S2_2.FT]';
Erosao = [S2_2.Processos3]';
%Construir o dataset normalizado
Data2_n = [Decliv, Elev, Geol, Pluv, UsoSolo, MI, FT, Erosao];

%Limpar variáveis não mais utilizadas
clear Decliv; clear Elev; clear Geol; clear Pluv; clear UsoSolo;
clear MI; clear FT; clear Erosao;

```

---

```

function [TrainingData, ValidationData, TestingData, inputData, ou-
tputData] = dataset_preparation(myData, Ptr, Pval, Ptes, adjust_class_
size)
%Obter os índices separadamente dos dados em que Erosão é 0 e 1
idx0 = find(myData(:,8)==0);
idx1 = find(myData(:,8)==1);
if(adjust_class_size)
    %Igualar os datasets para o menor conjunto (descomentar para
    %igualar os datasets)
    shuffle = @(v)v(randperm(numel(v)));
    if(length(idx1)<length(idx0))
        idx0 = shuffle(idx0);
        idx0 = idx0(1:(length(idx1)));
    else
        idx1 = shuffle(idx1);
        idx1 = idx1(1:length(idx0));
    end
end
Data0 = myData(idx0,:);
Data1 = myData(idx1,:);

%Preparação dos dados de Treinamento e Teste

[m,~] = size(Data0);
[trainInd,valInd,testInd] = divideblock(m,Ptr,Pval,Ptes);

```

```
TrainingData = Data0(trainInd,:) ;
ValidationData = Data0(valInd,:) ;
TestingData = Data0(testInd,);

[m,~] = size(Data1);
[trainInd,valInd,testInd] = divideblock(m,Ptr,Pval,Ptes);
TrainingData = [TrainingData; Data1(trainInd,:)] ;
ValidationData = [ValidationData; Data1(valInd,:)];
TestingData = [TestingData; Data1(testInd,:)];

%Preparação dos dados de entrada e saída da rede neural
inputData = [TrainingData(:,1:7); ValidationData(:,1:7); TestingDa-
ta(:,1:7)];
outputData = [TrainingData(:,8); ValidationData(:,8); TestingDa-
ta(:,8)];
end
```

---

#### **% Dataset Adjustment: filtra dados inconsistentes**

**%Remover os valores inválidos dos datasets**

```
idx = Data1<0;
[delRows,~] = find(idx);
delRows = unique(delRows);
Data1(delRows,:) = [];
Data1_n(delRows,:) = [];
```

**%Remover valores repetidos dos datasets**

```
[~, unique_idx,~] = unique(Data1,'rows');
Data1 = Data1(unique_idx,:);
Data1_n = Data1_n(unique_idx,:);
```

**%Remover os valores inválidos dos datasets**

```
idx = Data2<0;
[delRows,~] = find(idx);
delRows = unique(delRows);
Data2(delRows,:) = [];
Data2_n(delRows,:) = [];
```

**%Remover valores repetidos dos datasets**

```
[~, unique_idx,~] = unique(Data2,'rows');
Data2 = Data2(unique_idx,:);
Data2_n = Data2_n(unique_idx,:);
```

**%Limpar variáveis não mais utilizadas**

```
clear idx; clear delRows; clear unique_idx;
```

**%% Rede Neural Perceptron 1 Canada**

```
function [net, Errors, tr] = perceptron(hiddenLayerSize,inputDa-
ta,outputData,Ptr,Pval,Ptes)
%Parameters
x = inputData';
t = outputData';

trainFcn = 'trainscg'; % Scaled conjugate gradient backpropagation.
%Create a Pattern Recognition Network
net = patternnet(hiddenLayerSize);
net.divideFcn = 'divideblock';
net.divideParam.trainRatio = Ptr;
net.divideParam.valRatio = Pval;
net.divideParam.testRatio = Ptes;
net.performFcn = 'mse'; % Cross-Entropy
net = configure(net,x,t);
% Train the Network
[net,tr] = train(net,x,t);
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y);
tind = vec2ind(t);
yind = vec2ind(y);
percentErrors = sum(tind ~= yind)/numel(tind);
%Recalculate Training, Validation and Test Performance
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};
testTargets = t .* tr.testMask{1};

Errors.trainPerformanceMSE = perform(net,trainTargets,y);
Errors.valPerformanceMSE = perform(net,valTargets,y);
Errors.testPerformanceMSE = perform(net,testTargets,y);

net.performFcn = 'mae'; % erro absoluto
Errors.trainPerformanceMAE = perform(net,trainTargets,y);
Errors.valPerformanceMAE = perform(net,valTargets,y);
Errors.testPerformanceMAE = perform(net,testTargets,y);

% figure; plottrainstate(tr);
% figure; ploterrhist(e);
% figure; plotfit(net,x,t);
% figure; plotregression(t,y);

% View the Network
%view(net);
```

---

**%% Treinamento em lote da rede perceptron**

```
[net1, Errors1, tr1] = perceptron(hiddenLayerSize, inputData1, outputData1, Ptr, Pval, Ptes);
[net1n, Errors1n, tr1n] = perceptron(hiddenLayerSize, inputData1n, outputData1n, Ptr, Pval, Ptes);
[net2, Errors2, tr2] = perceptron(hiddenLayerSize, inputData2, outputData2, Ptr, Pval, Ptes);
[net2n, Errors2n, tr2n] = perceptron(hiddenLayerSize, inputData2n, outputData2n, Ptr, Pval, Ptes);
```

---

```
y = net1(inputData1');
h = figure; plotconfusion(outputData1', y, 'All');
saveas(h, 'net1_ROC_all.png');
y = net1(TrainingData1(:, 1:7)');
h = figure; plotconfusion(TrainingData1(:, 8)', y, 'Training');
saveas(h, 'net1_ROC_training.png');
y = net1(ValidationData1(:, 1:7)');
h = figure; plotconfusion(ValidationData1(:, 8)', y, 'Validation');
saveas(h, 'net1_ROC_validation.png');
y = net1(TestingData1(:, 1:7)');
h = figure; plotconfusion(TestingData1(:, 8)', y, 'Testing');
saveas(h, 'net1_ROC_testing.png');
h = figure; plotperform(tr1);
saveas(h, 'net1_performance.png');
close all;
y = net1n(inputData1n');
h = figure; plotconfusion(outputData1n', y, 'All');
saveas(h, 'net1n_ROC_all.png');
y = net1n(TrainingData1n(:, 1:7)');
h = figure; plotconfusion(TrainingData1n(:, 8)', y, 'Training');
saveas(h, 'net1n_ROC_training.png');
y = net1n(ValidationData1n(:, 1:7)');
h = figure; plotconfusion(ValidationData1n(:, 8)', y, 'Validation');
saveas(h, 'net1n_ROC_validation.png');
y = net1n(TestingData1n(:, 1:7)');
h = figure; plotconfusion(TestingData1n(:, 8)', y, 'Testing');
saveas(h, 'net1n_ROC_testing.png');
h = figure; plotperform(tr1n);
saveas(h, 'net1n_performance.png');
close all;
y = net2(inputData2');
h = figure; plotconfusion(outputData2', y, 'All');
saveas(h, 'net2_ROC_all.png');
y = net2(TrainingData2(:, 1:7)');
h = figure; plotconfusion(TrainingData2(:, 8)', y, 'Training');
saveas(h, 'net2_ROC_training.png');
y = net2(ValidationData2(:, 1:7)');
h = figure; plotconfusion(ValidationData2(:, 8)', y, 'Validation');
```

```

saveas(h, 'net2_ROC_validation.png');
y = net2(TestingData2(:,1:7)');
h = figure; plotconfusion(TestingData2(:,8)',y,'Testing');
saveas(h, 'net2_ROC_testing.png');
h = figure; plotperform(tr2);
saveas(h, 'net2_performance.png');
close all;
y = net2n(inputData2n');
h = figure; plotconfusion(outputData2n',y,'All');
saveas(h, 'net2n_ROC_all.png');
y = net2n(TrainingData2n(:,1:7)');
h = figure; plotconfusion(TrainingData2n(:,8)',y,'Training');
saveas(h, 'net2n_ROC_training.png');
y = net2n(ValidationData2n(:,1:7)');
h = figure; plotconfusion(ValidationData2n(:,8)',y,'Validation');
saveas(h, 'net2n_ROC_validation.png');
y = net2n(TestingData2n(:,1:7)');
h = figure; plotconfusion(TestingData2n(:,8)',y,'Testing');
saveas(h, 'net2n_ROC_testing.png');
h = figure; plotperform(tr2n);
saveas(h, 'net2n_performance.png');
close all;

```

---

### %% Treinamento e Teste Rede Neural Perceptron MultiCamada

% Multi-layer perceptron

```
addpath(fullfile(pwd, 'additional_toolbox\MultiLayerPerceptron'));
```

```
epoches = 50;
```

```
min_err = 1e-2;
```

```
momentum = 0.7;
```

### %% Dataset1

```
MLP1 = MultiLayerPerceptron('LengthsOfLayers', hiddenLayersSize, ...
                             'HiddenActFcn', 'logistic', ...
                             'OutputActFcn', 'logistic');
```

```
[m,n] = size(inputData1);
```

% Options

```
Options = ...
```

```
    struct('TrainingAlgorithm', 'GD', ...
          'NumberOfEpochs', epoches, ...
          'MinimumMSE', min_err, ...
          'SizeOfBatches', floor(m/10), ...
          'SplitRatio', Ptr, ...
          'Momentum', momentum);
```

% Training

```
MLP1.train(inputData1',outputData1',Options);
```

```
%MLP.propagate(Coordinates2);
```

```

%% Dataset1n
MLP1n = MultiLayerPerceptron('LengthsOfLayers', hiddenLayersSize, ...
                              'HiddenActFcn', 'logistic', ...
                              'OutputActFcn', 'logistic');

[m,n] = size(inputData1n);
% Options
Options = ...
    struct('TrainingAlgorithm', 'GD', ...
          'NumberOfEpochs',   epoches, ...
          'MinimumMSE',        min_err, ...
          'SizeOfBatches',     floor(m/10), ...
          'SplitRatio',        Ptr, ...
          'Momentum',          momentum);

% Training
MLP1n.train(inputData1n',outputData1n',Options);

%% Dataset2
MLP2 = MultiLayerPerceptron('LengthsOfLayers', hiddenLayersSize, ...
                              'HiddenActFcn', 'logistic', ...
                              'OutputActFcn', 'logistic');

[m,n] = size(inputData2);
% Options
Options = ...
    struct('TrainingAlgorithm', 'GD', ...
          'NumberOfEpochs',   epoches, ...
          'MinimumMSE',        min_err, ...
          'SizeOfBatches',     floor(m/10), ...
          'SplitRatio',        Ptr, ...
          'Momentum',          momentum);

% Training
MLP2.train(inputData2',outputData2',Options);

%% Dataset2n
MLP2n = MultiLayerPerceptron('LengthsOfLayers', hiddenLayersSize, ...
                              'HiddenActFcn', 'logistic', ...
                              'OutputActFcn', 'logistic');

[m,n] = size(inputData2n);
% Options
Options = ...
    struct('TrainingAlgorithm', 'GD', ...
          'NumberOfEpochs',   epoches, ...
          'MinimumMSE',        min_err, ...
          'SizeOfBatches',     floor(m/10), ...
          'SplitRatio',        Ptr, ...
          'Momentum',          momentum);

% Training
MLP2n.train(inputData2n',outputData2n',Options);

```

```
MLP1.propagate(inputData1');
h = figure; plotconfusion(outputData1',MLP1.Outputs,'All');
saveas(h,'mlp1_ROC_all.png');
MLP1.propagate(TrainingData1(:,1:7)');
h = figure; plotconfusion(TrainingData1(:,8)',MLP1.Outputs,'Training');
saveas(h,'mlp1_ROC_training.png');
MLP1.propagate(ValidationData1(:,1:7)');
h = figure; plotconfusion(ValidationData1(:,8)',MLP1.Outputs,'Validation');
saveas(h,'mlp1_ROC_validation.png');
if (~isempty(TestingData1))
MLP1.propagate(TestingData1(:,1:7));
h = figure; plotconfusion(TestingData1(:,8)',MLP1.Outputs,'Testing');
saveas(h,'mlp1_ROC_testing.png');
end
```

```
MLP1n.propagate(inputData1n');
h = figure; plotconfusion(outputData1n',MLP1n.Outputs,'All');
saveas(h,'mlp1n_ROC_all.png');
MLP1n.propagate(TrainingData1n(:,1:7)');
h = figure; plotconfusion(TrainingData1n(:,8)',MLP1n.Outputs,'Training');
saveas(h,'mlp1n_ROC_training.png');
MLP1n.propagate(ValidationData1n(:,1:7)');
h = figure; plotconfusion(ValidationData1n(:,8)',MLP1n.Outputs,'Validation');
saveas(h,'mlp1n_ROC_validation.png');
if (~isempty(TestingData1n))
MLP1n.propagate(TestingData1n(:,1:7));
h = figure; plotconfusion(TestingData1n(:,8)',MLP1n.Outputs,'Testing');
saveas(h,'mlp1n_ROC_testing.png');
end
```

```
MLP2.propagate(inputData2');
h = figure; plotconfusion(outputData2',MLP1.Outputs,'All');
saveas(h,'mlp2_ROC_all.png');
MLP2.propagate(TrainingData2(:,1:7)');
h = figure; plotconfusion(TrainingData2(:,8)',MLP2.Outputs,'Training');
saveas(h,'mlp2_ROC_training.png');
MLP2.propagate(ValidationData2(:,1:7)');
h = figure; plotconfusion(ValidationData2(:,8)',MLP2.Outputs,'Validation');
saveas(h,'mlp2_ROC_validation.png');
if (~isempty(TestingData2))
MLP2.propagate(TestingData2(:,1:7));
h = figure; plotconfusion(TestingData2(:,8)',MLP2.Outputs,'Testing');
saveas(h,'mlp2_ROC_testing.png');
end
```

```

MLP2n.propagate(inputData2n');
h = figure; plotconfusion(outputData2n',MLP2n.Outputs,'All');
saveas(h,'mlp2n_ROC_all.png');
MLP2n.propagate(TrainingData2n(:,1:7)');
h = figure; plotconfusion(TrainingData2n(:,8)',MLP2n.Outputs,'Training');
saveas(h,'mlp2n_ROC_training.png');
MLP2n.propagate(ValidationData2n(:,1:7)');
h = figure; plotconfusion(ValidationData2n(:,8)',MLP2n.Outputs,'Validation');
saveas(h,'mlp2n_ROC_validation.png');
if (~isempty(TestingData2n))
MLP2n.propagate(TestingData2n(:,1:7));
h = figure; plotconfusion(TestingData2n(:,8)',MLP2n.Outputs,'Testing');
saveas(h,'mlp2n_ROC_testing.png');
end

```

---

### %% Treinamento e Teste ANFIS

```

%Lista de funções membro
% "gbellmf"      Generalized bell-shaped membership function gbellmf
% "gaussmf"     Gaussian membership function      gaussmf
% "gauss2mf"    Gaussian combination membership function  gauss2mf
% "trimf"      Triangular membership function    trimf
% "trapmf"     Trapezoidal membership function   trapmf
% "sigmf"      Sigmoidal membership function    sigmf
% "dsigmoidf"  Difference between two sigmoidal membership functions
dsigmoidf
% "psigmoidf"  Product of two sigmoidal membership functions    psigmoidf
% "zmf"        Z-shaped membership function      zmf
% "pimf"       Pi-shaped membership function    pimf
% "smf"        S-shaped membership function     smf
% "constant"   Constant membership function for Sugeno output membership functions
              Sugeno Fuzzy Inference Systems
% "linear"     Linear membership function for Sugeno output membership functions

```

```

opt = anfisOptions;
opt.EpochNumber = 500;
opt.ErrorGoal = 10^-4;
opt.InitialStepSize = 0.01;
opt.StepSizeDecreaseRate = 0.95;
opt.StepSizeIncreaseRate = 1.05;
opt2 = genfisOptions('GridPartition');
%opt2.NumMembershipFunctions = [3 2 2 2 4 3 2];
%opt2.NumMembershipFunctions = [3 2 2 2 3 3 2];

```

```

opt2.NumMembershipFunctions = [2 2 2 2 2 2 2];
%opt2.InputMembershipFunctionType = ["gbellmf", "gbellmf", "gbell-
mf", "gbellmf", "gbellmf", "gbellmf", "gbellmf"];
opt2.InputMembershipFunctionType = ["gaussmf", "gaussmf", "gauss-
mf", "gaussmf", "gaussmf", "gaussmf", "gaussmf"];
% opt2.InputMembershipFunctionType = ["trimf", "trimf", "trimf",
"trimf", "trimf", "trimf", "trimf"];
opt2.OutputMembershipFunctionType = 'constant';

%% Dataset 1
opt.ValidationData = ValidationData1;
init_fis = genfis(inputData1,outputData1,opt2);
opt.InitialFIS = init_fis;
if(~isempty(opt.ValidationData))
    [fis,trainError,stepSize,chkFIS,chkError] = anfis(TrainingDa-
tal,opt);
else
    [fis,trainError,stepSize] = anfis(TrainingData1,opt);
end
writefis(fis,'anfis1');
writefis(chkFIS,'anfischk1');

%% Dataset 1n
opt.ValidationData = ValidationData1n;
init_fis = genfis(inputData1n,outputData1n,opt2);
opt.InitialFIS = init_fis;
if(~isempty(opt.ValidationData))
    [fis,trainError,stepSize,chkFIS,chkError] = anfis(TrainingDa-
taln,opt);
else
    [fis,trainError,stepSize] = anfis(TrainingData1n,opt);
end
writefis(fis,'anfis1n');
writefis(chkFIS,'anfischk1n');

%% Dataset 2
opt.ValidationData = ValidationData2;
init_fis = genfis(inputData2,outputData2,opt2);
opt.InitialFIS = init_fis;
if(~isempty(opt.ValidationData))
    [fis,trainError,stepSize,chkFIS,chkError] = anfis(TrainingDa-
ta2,opt);
else
    [fis,trainError,stepSize] = anfis(TrainingData2,opt);
end
writefis(fis,'anfis2');
writefis(chkFIS,'anfischk2');

%% Dataset 2n
opt.ValidationData = ValidationData2n;
init_fis = genfis(inputData2n,outputData2n,opt2);

```

```

opt.InitialFIS = init_fis;
if (~isempty(opt.ValidationData))
    [fis,trainError,stepSize,chkFIS,chkError] = anfis(TrainingData2n,opt);
else
    [fis,trainError,stepSize] = anfis(TrainingData2n,opt);
end
writefis(fis,'anfis2n');
writefis(chkFIS,'anfischk2n');

```

---

```

fis1 = readfis('anfis1.fis');
fis1n = readfis('anfis1n.fis');
fis2 = readfis('anfis2.fis');
fis2n = readfis('anfis2n.fis');

output = evalfis(inputData1,fis1);
h = figure; plotconfusion(outputData1',output','All');
saveas(h,'anfis1_ROC_all.png');
output = evalfis(TrainingData1(:,1:7),fis1);
h = figure; plotconfusion(TrainingData1(:,8)',output','Training');
saveas(h,'anfis1_ROC_training.png');
output = evalfis(ValidationData1(:,1:7)',fis1);
h = figure; plotconfusion(ValidationData1(:,8)',output','Validation');
saveas(h,'anfis1_ROC_validation.png');
if (~isempty(TestingData1))
output = evalfis(TestintData1(:,1:7),fis1);
h = figure; plotconfusion(TestintData1(:,8)',output','Testing');
saveas(h,'anfis1_ROC_testing.png');
end
close all;
output = evalfis(inputData1n,fis1n);
h = figure; plotconfusion(outputData1n',output','All');
saveas(h,'anfis1n_ROC_all.png');
output = evalfis(TrainingData1n(:,1:7),fis1n);
h = figure; plotconfusion(TrainingData1n(:,8)',output','Training');
saveas(h,'anfis1n_ROC_training.png');
output = evalfis(ValidationData1n(:,1:7)',fis1n);
h = figure; plotconfusion(ValidationData1n(:,8)',output','Validation');
saveas(h,'anfis1n_ROC_validation.png');
if (~isempty(TestingData1n))
output = evalfis(TestintData1n(:,1:7),fis1n);
h = figure; plotconfusion(TestintData1n(:,8)',output','Testing');
saveas(h,'anfis1n_ROC_testing.png');
end
close all;
output = evalfis(inputData2,fis2);

```

```
h = figure; plotconfusion(outputData2',output','All');
saveas(h,'anfis2_ROC_all.png');
output = evalfis(TrainingData2(:,1:7),fis2);
h = figure; plotconfusion(TrainingData2(:,8)',output','Training');
saveas(h,'anfis2_ROC_training.png');
output = evalfis(ValidationData2(:,1:7)',fis2);
h = figure; plotconfusion(ValidationData2(:,8)',output','Valida-
tion');
saveas(h,'anfis2_ROC_validation.png');
if (~isempty(TestingData2))
output = evalfis(TestintData2(:,1:7),fis2);
h = figure; plotconfusion(TestintData2(:,8)',output','Testing');
saveas(h,'anfis2_ROC_testing.png');
end
close all;
output = evalfis(inputData2n,fis2n);
h = figure; plotconfusion(outputData2n',output','All');
saveas(h,'anfis2n_ROC_all.png');
output = evalfis(TrainingData2n(:,1:7),fis2n);
h = figure; plotconfusion(TrainingData2n(:,8)',output','Training');
saveas(h,'anfis2n_ROC_training.png');
output = evalfis(ValidationData2n(:,1:7)',fis2n);
h = figure; plotconfusion(ValidationData2n(:,8)',output','Valida-
tion');
saveas(h,'anfis2n_ROC_validation.png');
if (~isempty(TestingData2n))
output = evalfis(TestintData2n(:,1:7),fis2n);
h = figure; plotconfusion(TestintData2n(:,8)',output','Testing');
saveas(h,'anfis2n_ROC_testing.png');
end
close all;
```