UNIVERSIDADE DE SÃO PAULO

Marcos Roberto Martines

Inferências Geográficas e Redes Neurais Artificiais
aplicadas à produção da Cartografia de Síntese

São Paulo
2010

UNIVERSIDADE DE SÃO PAULO
Faculdade de Filosofia, Letras e Ciências Humanas
Departamento de Geografia

Inferências Geográficas e Redes Neurais Artificiais
aplicadas à produção da Cartografia de Síntese

Marcos Roberto Martines

Tese apresentada à Faculdade de Filosofia,
Letras e Ciências Humanas da Universidade
de São Paulo para a obtenção do título de
Doutor em Geografia.

Área de Concentração: Geografia Física

Orientador: Prof. Dr. Jorge Gustavo da Graça Raffo

São Paulo
2010

DEDICATÓRIA

À Luciana, com amor e gratidão por sua colaboração,
compreensão e importante apoio ao longo do processo de
elaboração deste trabalho.

À minha mãe, Sônia, pelos ensinamentos ao longo da minha vida.

À minha família pelo apoio.

Agradecimentos

Ao Professor Jorge Raffo, pela amizade, compreensão, orientação e incentivo ao longo de todo esse processo de trabalho.

Ao Professor José Marinaldo Gleriani da Universidade Federal de Viçosa, pelo apoio durante o desenvolvimento dos conhecimentos sobre redes neurais artificiais.

Ao colega Ricardo Ferreira, pelo incentivo e apoio neste estudo.

À colega Evelise, pela importante participação na ajuda com a Língua Portuguesa.

Ao Departamento de Geografia Física da USP, pelo apoio institucional.

A todos os colegas que participaram indiretamente desse trabalho.

Resumo

MARTINES, M. R **Inferências geográficas e Redes Neurais Artificiais aplicadas para a produção de cartografia de síntese. 2010. 163 f.** Tese (Doutorado) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, 2010.

Este trabalho está inserido com contexto da modelagem cartográfica e cartografia de síntese dentro do universo dos sistemas de informações geográficas (SIG). Serão apresentadas três metodologias distintas para obtenção de mapas sínteses através de inferências geográficas, são elas: Operações Pontuais de Soma (OPS), Processo Analítico hierarquico (AHP) e Redes Neurais Artificiais (RNA). Aqui serão desenvolvidos e apresentados todos os procedimentos técnicos e metodológicos para a obtenção desses produtos cartográficos através do uso de dois softwares: o SPRING (SIG) e o SNNS (simulador de rede neural artificial). Também será apresentada uma discussão sobre a qualidade dos modelos gerados por essas distintas metodologias e a importância do papel do pesquisador na obtenção desses produtos.

Palavras-Chave: cartografia de síntese, redes neurais artificiais, geoprocessamento, inferências geográficas

Abstract

MARTINES, M. R. **Geographic Inferences and Artificial Neural Networks applied to the production of Cartography Synthesis. 2010. 163 f.** Thesis (Doctoral) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, 2010.

This work is inserted in the context of cartographic modeling and mapping of synthesis within the universe of geographic information systems (GIS). We will present three different methodologies for obtaining maps synthesis by geographic inferences, they are: Operations Locations Sum, Analytic Hierarchy Process and Artificial Neural Network. Here will be developed and presented all the technical and methodological procedures to obtain these cartographic products through the use of two software: SPRING (GIS) and SNNS (artificial neural network simulator). It will also be a discussion of the quality of models generated by these different methodologies and the importance of the researcher in obtaining these products

Key-Words: synthesis mapping, GIS, geographic inferences, artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Modelagem segundo o paradigma dos quatro universos.....	13
Figura 2 – Três seções de um programa em LEGAL	23
Figura 3 – Sintaxe das Declarações em LEGAL.....	24
Figura 4 – Sintaxe das Instanciações em LEGAL.....	25
Figura 5 – Sintaxe geral para Operações em LEGAL	26
Figura 6 – Sintaxe de Operações sobre Imagem	27
Figura 7 – Sintaxe de Operações sobre Numérico.....	27
Figura 8 – Sintaxe de Operações sobre Temático.....	28
Figura 9 – Sintaxe das expressões condicionais	28
Figura 10 – Classe de operadores sobre geo-campos	29
Figura 12 – Operação de Ponderação em LEGAL	31
Figura 13 – Operação de Reclassificação em LEGAL	32
Figura 14 – Operação de Atribua em LEGAL	34
Figura 15 – Operações Matemáticas em LEGAL	35
Figura 16 – Linhas do LEGAL para reclassificação por atributo.....	36
Figura 17 – Rede de perceptrons proposta por Rosenblatt.....	45
Figura 18 – Redes ADALINE e MADALINE.....	46
Figura 19 – Estrutura do método <i>Backpropagation</i>	46
Figura 20 – Estrutura básica de um neurônio.....	49
Figura 21 – Estrutura de uma arquitetura de rede neural artificial.....	50

Figura 22 – Representação das funções de ativação.....	51
Figura 23 – Estrutura para o desenvolvimento de uma RNA	53
Figura 24 – Propagação do erro em RNA em MLP	57
Figura 25 – Retropropagação do erro na RNA em MLP.....	57
Figura 26 – APA's na região do Município de Itirapina	62
Figura 27 – Esboço dos principais núcleos de cobertura vegetal.....	72
Figura 28 – Mapa Topográfico do Município de Itirapina.....	77
Figura 29 – Representação de Grade Irregular Triangular (TIN).....	78
Figura 30 – Grade Irregular Triangular do Município de Itirapina.....	78
Figura 31 – Mapa de Declividades.....	80
Figura 32 – Mapa de Solos	82
Figura 33 – Mapa de Geologia.....	84
Figura 34 – Mapa de Uso da Terra e Cobertura Vegetal.....	87
Figura 35 – Exemplo de Padronização de Mapa Temático (Vetor) para um Mapa Numérico (Matriz)	89
Figura 37 – Fórmula para a aplicação dos Pesos do OPS para os Temas.....	97
Figura 38 – Área teste – Modelo numérico do <i>Operações Pontuais de Soma</i>	98
Figura 39 – Hierarquização da intensidade de importância dos temas da pesquisa	102
Figura 40 – Matriz de Comparação Pareada	103
Figura 41 – Matriz de Comparação Normalizada e Vetor de Prioridade estimado	104
Figura 42 – Aplicação dos Pesos do AHP para os Temas.....	107
Figura 43 – Modelo Numérico resultado da aplicação da técnica AHP.....	109

Figura 44 – Edição dos Cabeçalhos exportados do SPRING	115
Figura 45 – Linhas de Comando do Arquivo “tudo”.	116
Figura 46 – Junção de matrizes “sai”	117
Figura 47 – Painel do SNNS e RNA com 4 entradas e 1 saída – Estrutura	119
Figura 48 – Tela de configuração de neurônio no SNNS	121
Figura 49 – Barra de Menu do SNNS com parâmetros de importação	122
Figura 50 – Parametrização da inicialização randômica	123
Figura 51 – Neurônios com valores antes e depois da inicialização randômica	124
Figura 52 – Ajustes para os arquivos do campo Subpatterns	125
Figura 53 – Configuração do sistema de aprendizagem do SNNS	126
Figura 54 – Gráficos e Tabelas de Log do Erro SSE e MSE	127
Figura 55 – Salvamento de resultado da rede neural artificial.....	129
Figura 56 – Formatação do arquivo *.res.....	130
Figura 57 – Criação da matriz de resultados a partir dos dados do SNNS	131
Figura 58 – Configuração do cabeçalho do arquivo *.res para o Spring	132
Figura 59 – Modelo gerado pelo RNA para o arquivo <i>pattern</i> OPS.....	133
Figura 60 – Modelo gerado pelo RNA para o arquivo <i>pattern</i> AHP	134
Figura 61 – Modelos numéricos gerados para o AHP e OPS	135
Figura 62 – Modelos gerados pelas RNA's para o AHP e OPS	137
Figura 63 – Comparação espacial dos modelos AHP e RNA.....	140
Figura 64 – Comparação espacial dos modelos OPS e RNA	141

LISTA DE TABELAS

Tabela 1 – Modelagem de dados do mundo real.....	15
Tabela 2 – Regras para Aptidão Agrícola	33
Tabela 3 – Relação de Operadores sobre Geo-campos	39
Tabela 4 – Comparação cérebro humano/computador	47
Tabela 5 – Comparativo entre computadores e neurocomputadores.....	48
Tabela 6 – Litologia e Pedologia da Área do Município.....	66
Tabela 7 – Classes de solos	67
Tabela 8 – Quantificação de cobertura vegetal	71
Tabela 9 – Estrutura de Modelagem de Dados no Sistema SPRING	73
Tabela 10 – Descrição dos Modelos de Dados e Categorias do Banco de Dados	75
Tabela 11 – Classes Geológicas.....	83
Tabela 12 – Categorias classificadas no PI Uso da Terra e Cobertura Vegetal	86
Tabela 13 – Padronização dos Mapas para o Modelo Numérico	89
Tabela 14 – Valores consolidados para o tema geologia	91
Tabela 15 – Valores consolidados para tema uso da terra e cobertura vegetal	92
Tabela 16 – Valores consolidados para o tema declividade.....	92
Tabela 17 – Valores consolidados para o tema solos	93
Tabela 18 – Escala de Valores de AHP para Comparação Pareada	103
Tabela 19 – Pesos do AHP por critérios	105

Tabela 20 – Exemplo de arquivo <i>pattern</i> para uma rede neural artificial	113
Tabela 21 – Variação do valor e quantidade de pixel da diferença da RNA para OPS	142
Tabela 22 – Variação do valor e quantidade de pixel da diferença da RNA para AHP	143

LISTA DE GRÁFICOS

Gráfico 1 – Distribuição das Classes do Plano de Informação Declividades	79
Gráfico 2 – Distribuição das Classes do Plano de Informação Pedologia.....	81
Gráfico 3 – Distribuição das Classes do Plano de Informação Geologia	85
Gráfico 4 – Distribuição da Classificação do PI Uso da terra e Cobertura Vegetal.....	88

LISTA DE SIGLAS

ADALINE – Adaptative Linear Network

AHP – Analytic Hierarchy Process

APA – Áreas de Proteção Ambiental

BDG – Banco de Dados Geográficos

DAEE – Departamento de Águas e Energia

DARPA – Defense Advanced Research Projects Agency

IC – Índice de Consistência

IEEE – International Conference on Neural Networks

INNS – International Neural Networks Society

LEGAL – Linguagem Espacial para Geoprocessamento Algébrico

MADALINE – Many Adaptative Linear Network

MDT – Modelo Digital do Terreno

MLP – Multi Layer Perceptron

MNT – Modelo Numérico do Terreno

MSE – Erro Médio Quadrático

OPS – Operações Pontuais de Soma

PI – Plano de Informação

RNA – Redes Neurais Artificiais

SIG – Sistema de Informações Geográficas

SNNS – Stuttgart Neural Network Simulator

SSE – Somatória dos erros ao quadrado

TIN – Grade Irregular Triangular

UTM – Universal Transversa de Mercator

ÍNDICE

1. Introdução.....	1
2. Hipótese.....	5
3. Tese.....	5
4. Objetivo Geral.....	5
<i>4.1. Objetivo específico.....</i>	<i>6</i>
4. Justificativa.....	6
5. Modelos de Inferências Geográficas propostos.....	7
6. Contextualização Geral.....	8
<i>6.1. Contextualização do estudo desenvolvido.....</i>	<i>10</i>
7. Base teórica conceitual.....	12
<i>7.1. Modelagem de dados em geoprocessamento.....</i>	<i>12</i>
<i>7.2. Procedimentos para definição dos modelos.....</i>	<i>17</i>
<i>7.3. Análise e operações espaciais.....</i>	<i>20</i>
7.3.1. Classificação de LEGAL.....	21
7.3.2. Características do LEGAL.....	21
7.3.1. Classes do modelo de dados e sua representação no LEGAL.....	22
7.3.2. Seções de um programa no LEGAL.....	22
7.3.3. Formato para uma programação em LEGAL.....	24
7.3.4. Operadores entre geo-campos.....	29
<i>7.4. Redes Neurais Artificiais.....</i>	<i>40</i>
7.4.1. Redes Neurais Artificiais – Histórico.....	41

7.4.2. Modelo básico do neurônio artificial e a arquitetura da rede neural	48
7.4.3. Tipologia das Redes Neurais Artificiais	52
7.4.4. Rede Multilayer Perceptron	54
7.4.5. Algoritmo de aprendizagem MLP.....	55
8. Caracterização da área de estudo	59
8.1. <i>Breve histórico da formação Município de Itirapina</i>	59
8.2. <i>Aspectos Geomorfológico-Geológicos</i>	63
8.2.1. Grupo São Bento.....	64
8.2.2. Grupo Bauru	65
8.3. <i>Aspectos Pedológicos</i>	67
8.3.1. Latossolos Roxos	67
8.3.2. Latossolos Vermelho-escuros	68
8.3.3. Latossolos Vermelho-amarelos.....	68
8.3.4. Podzólicos Vermelho-amarelos	68
8.3.5. Terra Roxa Estruturada	68
8.3.6. Solos Litólicos	68
8.3.7. Solos Hidromórficos	69
8.3.8. Áreas Quartzosas Profundas	69
8.4. <i>Aspectos Climáticos</i>	69
8.5. <i>Vegetação</i>	71
9. Matérias, Métodos e Construção do banco de dados geográficos	73
9.1. <i>Elaboração do Banco de Dados Geográficos e Modelagem</i>	73

9.2. Procedimentos – Planos de Informação	75
9.3. Plano de Informação Declividades.....	75
9.3.1. Plano de Informação Solos	81
9.3.2. Plano de Informação Geologia.....	83
9.3.3. Plano de Informação Uso da Terra e Cobertura Vegetal.....	85
9.4.3. Padronização dos Mapas Temáticos	88
10. Experimento: Área de teste para a aplicação das metodologias.....	94
10.1. Operações Pontuais de Soma – OPS (Modelo de Soma Álgebraica)	95
10.2. Analytical Hierarchical Process – AHP	99
10.3. Redes Neurais Artificiais	110
10.3.1. Normalização dos dados.....	110
10.3.2. Formação do arquivo de “resultados esperados”	112
10.3.3. Construção da RNA no SNNS	118
10.3.4. Configuração individual dos neurônios.....	120
10.3.5. Importação dos dados pelos SNNS	122
10.3.6. Processamento dos dados no SNNS	122
10.3.6.1. Inicialização da RNA.....	123
10.3.6.2. Configuração do arquivo Subpatterns.....	125
10.3.6.3. Aprendizagem da RNA.....	126
10.3.6.4. Acompanhamento do treinamento da RNA	127
10.3.7. Exportação dos dados para o SIG	129
10.3.8. Importação dos dados pelo SPRING	132
10.3.9. Aplicação da RNA na área teste.....	133

11. Aplicação das metodologias para toda a área estudada e comparação dos modelos	135
12. Considerações Finais	144
13. Bibliografia.....	147

1. Introdução

A modelagem cartográfica apresenta-se como uma importante técnica de análise espacial disponível para ser utilizada nas mais diferentes naturezas de estudos geográficos. Ela aparece como definição, no contexto da utilização de tecnologias de geoprocessamento, no início da década de 1990, com Tomlin (1990), em sua publicação *“Geographic Information Systems and Cartographic Modeling”*, em que o autor introduz um conceito novo, a “álgebra de mapas”.

Esse conceito traz para o universo do geocomputação a possibilidade de produção de uma cartografia de síntese, e também a da produção de novos cenários dentro dos sistemas de informação geográfica (SIG). Essa produção ocorre a partir da sobreposição e combinação de mapas de diferentes naturezas dentro dos SIG (Bédard, 2001).

Portanto, a modelagem cartográfica está inserida no contexto do desenvolvimento de tecnologias de geoprocessamento e da valorização de técnicas de análise espacial. A contribuição que a aplicação da “álgebra de mapas” oferece é a possibilidade de gerar novas informações geográficas, ou seja, a partir das diferentes técnicas de combinação de mapas é possível projetar, criar e prognosticar novos cenários.

Essa possibilidade de integrar dados geográficos se faz muito importante quando se projetam as possíveis áreas de aplicação. Por exemplo, em estudos governamentais, privados, acadêmicos, etc. Eles podem, de uma forma determinante, ampliar e potencializar o universo de análises desses estudos.

Assim, é possível definir que as tecnologias de geoprocessamento são consideradas instrumentos imprescindíveis para a pesquisa e entendimento do espaço geográfico.

Essas tecnologias resgataram questões essenciais para os geógrafos que atuam nesta área de conhecimento: o tratamento do dado espacial, a valorização da informação geográfica, e, ainda, uma questão central – como fazer análise espacial, via tecnologia, dominando as técnicas disponíveis nos softwares de SIG, gerando informação nova e útil para o entendimento da complexidade do espaço contemporâneo.

Para tanto, os geógrafos devem conhecer em detalhes quais são as possibilidades metodológicas e técnicas da criação de novas informações espaciais, e assim, poder avaliar com entendimento crítico os resultados obtidos.

Existem diversas possibilidades de criação desses cenários, e ter o conhecimento dos procedimentos, métodos, manipulação e técnica é indispensável para que o geógrafo tenha subsídios para a tomada de decisão e interpretação correta do produto cartográfico obtido. E assim, ter a capacidade de decidir qual, dentre as possibilidades metodológicas disponíveis, o atenderá melhor e de modo mais eficiente em uma determinada situação.

Esta é a motivação deste estudo, a instrumentalização dos geógrafos para a aplicação da cartografia de síntese em processamento computacional, ou seja, a possibilidade que a tecnologia traz para uma nova construção de cenários e para a leitura do território, subsidiado por procedimentos de análise espacial através de inferências geográficas.

Alguns desses recursos tecnológicos serão demonstrados e outros citados ao longo deste estudo. Cabe destacar que essas tecnologias não podem gerar ilusões e inibição do senso crítico do pesquisador. A utilização desses instrumentos deve ser ancorada em conhecimentos teóricos e conceituais dos processos e resultados obtidos.

Tendo esse foco, este estudo apresentará três das técnicas que possibilitam geração de novos dados geográficos e discutirá os processos conceituais e

metodológicos envolvidos. Para isso, será utilizada uma aplicação prática: no município de Itirapina, no estado de São Paulo, onde serão desenvolvidas técnicas e aplicadas três metodologias: *Operações Pontuais de Soma (OPS)*, *Analytic Hierarchy Process (AHP)* e *Artificial Neural Network (RNA)*.

A estratégia do estudo será inicialmente separar uma pequena área teste para a aplicação e desenvolvimento técnicos dos métodos propostos, e posteriormente, a replicação destes para toda a área do município.

O estudo irá apresentar essas três metodologias, sendo elas diferenciadas pelas suas concepções e execuções. Iniciando com um processo algébrico de combinação linear ponderada, OPS; posteriormente o AHP, no qual há uma metodologia de categorização hierárquica das variáveis, obtendo pesos diferenciados na aplicação da álgebra de mapa; e, por último, RNA, um procedimento de aproximação de função matemática que simula uma “aprendizagem” a partir de uma experiência apresentada para a RNA.

Serão apresentados procedimentos metodológicos para essas três possibilidades de gerar novos dados geográficos na forma de mapas sínteses. Se isso for possível, então fica claro que, apesar de obter mapas sínteses de diferentes processos, a participação do pesquisador é conveniente e decisiva no resultado produzido, independente da complexidade do processo de obtenção do produto cartográfico.

Essa será a linha de pesquisa desta tese: apresentar formas mais clássicas e novas tendências de obtenção de mapas sínteses através de procedimentos computacionais. E ainda destacar o papel fundamental do pesquisador (geógrafo) na elaboração desses produtos cartográficos.

Como este trabalho traz para a discussão procedimentos ainda pouco explorados, as potencialidades das RNA's na Geografia, faz-se necessário destacar

as convicções de Openshaw (1997), quando discorreu em seu trabalho sobre o tema *Artificial Intelligence in Geography*.

O autor não tem dúvidas quando afirma que a Geografia está agora no meio de sua terceira revolução quantitativa, a revolução da neurocomputação. As outras duas foram: a revolução estatística no início dos anos 60 e a modelagem matemática no início dos anos 70. Faz-se essa citação, pois uma das possibilidades que será apresentada como instrumento técnico-metodológico de geração de mapas sínteses é através das redes neurais artificiais, uma nova fronteira dentro da geografia quantitativa.

Na Geografia, como em muitos outros ramos da Ciência, está havendo um rápido e crescente interesse na aplicação de métodos neurocomputacionais, que por sua vez são novas ferramentas que podem vir a complementar os métodos existentes.

Como na Geografia, muitos métodos de análise quantitativa e modelagem inserem-se na classe dos problemas complexos, e a justificativa corrente para o uso de RNA é uma promessa de melhora no desempenho e na eficiência, na diminuição das suposições críticas, na grande facilidade de tratamento de problemas complexos, na expansão da aplicabilidade dos métodos computacionais quantitativos e na automação. Justifica-se assim a possibilidade de aplicação de RNA's na Geografia. Enfatadamente, Openshaw (1994) afirma que:

A Geografia está hoje no início de sua maior e mais recente revolução que é a Geografia Computacional. A esperança é que no curso dos próximos 50 anos a Geografia interligará todas as suas sub-disciplinas em um processo de modelagem baseado numa estrutura cibernética, capaz de prover um entendimento racional e científico dos sistemas geográficos.

2. Hipótese

Existem diversos procedimentos matemáticos e algoritmos computacionais que podemos utilizar para produzir mapas sínteses através das técnicas disponíveis nos sistemas de informação geográficos. Dentro dessas possibilidades, este trabalho apresenta e analisa o Processo hierárquico Analítico (AHP), as Operações Pontuais de Soma (OLP) e as Redes Neurais Artificiais (RNA).

3. Tese

A confiabilidade dos resultados da RNA na elaboração de dados para mapas síntese em SIG pode ser avaliada utilizando para treinamento parte de um mapa produzido por outra metodologia como AHP, OLP e comparando o mapa final produzido a partir da RNA com o mapa gerado pela outra metodologia. O nível de coincidência entre os mapas indica a qualidade de aprendizagem da RNA.

Assim as RNA podem também se apresentar como mais uma alternativa para a produção de uma cartografia de síntese, e caberá ao pesquisador não só escolher qual dos métodos é o mais adequado ao problema a ser resolvido em função das complicações e qualidades que cada um apresenta. Mas, também as interações com os modelos e algoritmos dariam uma maior qualidade ao produto produzido, o mapa síntese.

4. Objetivo Geral

Estudo de três métodos de inferência geográfica: *Operações Pontuais de Soma* (OPS), *Processo Analítico Hierárquico* (AHP) e *Redes Neurais Artificiais* (RNA), aplicados à construção de mapas sínteses para avaliação da hipótese de semelhança entre eles.

4.1. Objetivo específico

Desenvolver procedimentos técnico-metodológicos que viabilizem a utilização de software de redes neurais artificiais existentes, em combinação com sistemas de informações geográficas, para obtenção de mapas sínteses.

A ideia é utilizar software livre, e por tal motivo foi escolhido o SIG, SPRING do INPE – Instituto Nacional de Pesquisas Espaciais, e o simulador de redes neurais, o SNNS – Stuttgart Neural Network Simulator, disponibilizado pela Universidade de Stuttgart. Os dois softwares estão disponíveis para download nos sites dos respectivos institutos.

E ainda, desenvolver e descrever todo o processo técnico-metodológico de migração, utilização e processos para trabalhar com redes neurais artificiais permitindo a integração e utilização dentro do sistema de informação geográfica SPRING.

4. Justificativa

A relevância desta pesquisa se dá pela grande demanda de estudos de impacto e licenças ambientais, estudos de áreas de risco, fragilidade, suscetibilidade, caracterização socioeconômica, tanto no âmbito da geografia física quanto no da humana.

No Brasil esses estudos vêm sendo produzidos tanto no meio acadêmico quanto no mundo corporativo, e o destaque que os mapas integradores (cartografia de síntese) deveriam ter dentro desses estudos é muito grande, pois eles podem propiciar uma leitura integradora e unificada dos fenômenos estudados.

Assim, espera-se que esta tese amplie o entendimento da importância do domínio técnico/metodológico na produção de inferências geográficas e a inserção das redes neurais artificiais como mais uma alternativa dentre elas; isso, para a

melhoria na obtenção dos resultados e a aproximação de uma validade territorial mais significativa.

5. Modelos de Inferências Geográficas propostos

Esta tese pretende discutir e apresentar três possibilidades de modelagem para a produção de cartografia de sínteses. São elas:

Operações Pontuais de Soma (OPS) – Processo de obtenção de novos dados geográficos através do estudo dos elementos que se pretende combinar gerando, de forma linear, operação matemática ponderada em intervalos numéricos.

Analytic Hierarchy Process (AHP) – É a utilização de uma metodologia que nasceu na Economia e que pode ser utilizada no âmbito da Geografia. Consiste basicamente no processo de hierarquia dos temas/variáveis do banco de dados geográficos que serão combinados através de modelo matemático, regido pela geração de pesos diferenciados e importância relativa.

Redes Neurais Artificiais (RNA) – Processo de análise fundado em operações matemáticas não lineares que realizam previsões a partir de exemplos. A ideia é desenvolver uma rede neural artificial do tipo MLP – *Multi Layer Perceptron* – que seja capaz de gerar um processo de inferência geográfica.

6. Contextualização Geral

O processamento digital de dados nos SIG's pode auxiliar na compreensão de muitos conceitos socioeconômicos e ambientais. Esses sistemas computacionais são capazes de expressar, através de medidas diretas ou estimativas, conceitos de expressão territorial como "potencialidade de uso da terra", "zonas de influência", "setores críticos", "áreas de concentração", entre outras possibilidades. Em consequência de toda essa versatilidade de produção cartográfica, esses sistemas computacionais podem prestar grandioso auxílio no planejamento territorial, econômico e ambiental (Goodchild, 1993).

Considerando a aplicação em estudos voltados para os universos dos dados ambientais. Os sistemas computacionais como os SIG's, baseados em modelos digitais do ambiente, permitem avaliações das situações ambientais com uma boa precisão e com uma economia muito interessante para o esforço da coleta e armazenamento dos dados geográficos. A possibilidade de contato entre os pesquisadores, dados levantados e a possibilidade de manipulação dentro de um banco de dados geográficos potencializam o poder de análise dos diferentes estudos realizados (Lovett, 2007).

Assim, esses sistemas concretizam uma possibilidade de um caminho para as investigações ambientais, baseada em documentação concreta e confiável. Segundo Xavier (2001), os SIG's funcionam baseados em microcomputadores e isso é um facilitador da viabilização de estudos, pois torna-se de baixo custo para administradores, pesquisadores, empresas, organizações governamentais, militares, e ainda podem ser aplicados em diversos níveis: local, municipal, estadual, regional, etc. Apesar disso, as principais utilizações ainda estão na identificação e classificação dos fenômenos ambientais.

O mesmo autor esclarece que os SIG's, compreendendo os modelos ambientais, são instrumentos conceituais, metodológicos e tecnológicos que

respeitam e integram dados e conservam algumas características ambientais fundamentais como:

A) Dados ambientais são geralmente muito numerosos, milhões deles são gerados diariamente, impondo assim, a necessidade de um processamento e tratamento eficaz;

B) Os dados ambientais têm diferentes formas e fontes;

C) Os dados ambientais podem sofrer variação quanto à classificação e apresentam diferentes graus de complexidade e aplicabilidade, necessitando de trabalhos múltiplos e interdisciplinares;

D) Os dados ambientais têm por definição uma localização geográfica e podem ser geocodificados. A partir deste atributo é possível construir estruturas geocodificadas para o armazenamento, recuperação, atualização e recuperação de dados ambientais.

Os avanços tecnológicos na geração de dados ambientais trouxeram um crescimento exponencial da disponibilidade desses produtos, mas também criaram um cenário antagônico. Por um lado, esses avanços tecnológicos na área da informática, por exemplo a nanotecnologia, possibilitaram preços atraentes tanto para softwares como para hardwares, e associada a essas tecnologias e produtos a facilidade de armazenamento, integração e divulgação digitais (Antenucci, 1991).

Mas por outro lado, a geração, identificação e classificação de dados ambientais são muito dispendiosas em tempo, verbas e recursos humanos, e necessariamente, os dados levantados devem passar por um processo analítico peculiar. Esse processo deve “decompor” o ambiente em partes básicas e ainda requer a preservação da possibilidade de alcançar um retrato único e integrado da situação ambiental analisada (Zaidan, 2004).

Assim, a instrumentação que os Sistemas de Informação Geográficas disponibilizam associada à característica principal do dado ambiental, que é a localização geográfica, são amplamente respeitadas dentro de um SIG, estabelecem a esses a possibilidade de ser o instrumento para obtenção da informação ambiental.

6.1. Contextualização do estudo desenvolvido

Como citado acima, para a produção de Mapas de Síntese utilizando-se o Sistema de Informações Geográficas efetua-se uma rotina de operações chamada “Algebra de Mapas”, conhecida mais comumente como cruzamento dos mapas. Nesta metodologia são “cruzados” mapas que apresentam as diversas variáveis que devem participar do mapa final.

Geralmente todas as variáveis que intervêm no problema tratado não tem a mesma significância no resultado final do problema e conseqüentemente no Mapa de Síntese. Para ponderar a significância relativa dos diversos mapas fornecedores de dados, existem várias metodologias que atribuem uma valoração quantitativa a cada mapa. Entre elas o AHP e as OPS. A proposta dessa tese é apresentar as RNA's como uma dessas alternativas, no método Supervisionado.

Quando se trabalha com RNA's no método supervisionado a Rede “aprende” a partir de uma região de “treinamento” estabelecida pelo usuário. Sucede normalmente que a “aprendizagem” adotada pela rede é aceita pelo usuário, mas se for adotado um posicionamento mais crítico cabe a pergunta: será que a RNA “aprendeu” corretamente a partir do “treinamento” efetuado pelo ser humano que foi seu “Treinador”?

Fazendo um paralelismo com aprendizagem de pessoas: quando um professor ensina a um aluno com um exemplo na solução de um problema, é de praxis avaliar o nível da aprendizagem do aluno apresentando um problema similar ao anterior, mas que não seja necessariamente o mesmo, e avaliar o resultado da solução dada pelo aluno.

Na aprendizagem de pessoas duvida-se da aprendizagem do aluno, mas na aprendizagem das RNA muitas pessoas tem dúvidas sobre a qualidade da aprendizagem. Este trabalho pretende avaliar o nível de aprendizagem das RNA e estabelecer um método para obtenção de mapas síntes pelas RNA's. O método basicamente consiste em criar um mapa de síntese usando à metodologia do AHP e outro a metodologia OPS.e compara-los.

Posteriormente “treinar” a RNA numa “amostra” o mapa gerado por ambas metodologias e solicitar à RNA que gere dados através de previsão para construir o mapa de síntese em toda a região problema. O nível de coincidência entre o mapa gerado pela RNA e pelo AHP, assim como a RNA e OPS indica, o “grau de aprendizagem” da rede e consequentemente a confiabilidade de seus resultados em comparação de uma metodologia totalmente transparente como a AHP ou a OPS.

7. Base teórica conceitual

Esta tese é baseada em métodos e técnicas de modelagem cartográfica e neste item serão apresentados alguns conceitos importantes para o entendimento desses procedimentos. Também serão expostos os conceitos para a manipulação da linguagem LEGAL e os conceitos e técnicas fundamentais para o uso das RNA's.

7.1. Modelagem de dados em geoprocessamento

No estudo de um determinado fenômeno utilizando as técnicas de geoprocessamento aplicadas em um banco de dados geográficos, a modelagem é um procedimento necessário que pode-se sintetizar como o processo de descrição de forma matemática, simbólica ou funcional de um fenômeno estudado. O resultado obtido deverá ser um modelo que procure representar o conhecimento que se tem sobre esse fenômeno (Berry,1993).

Para realizar uma modelagem de dados geográficos para ser utilizada em um SIG é necessário um conjunto de ferramentas conceituais que descreva como uma realidade pode ser representada. Assim, no desenvolvimento de um banco de dados geográficos, o modelo prevê como a realidade geográfica será representada no computador.

Para Câmara (1996), ao modelar uma área de estudo, podemos obter diferentes modelos de representação em virtude dos diversos objetivos de cada um. Por exemplo, criando um modelo conceitual a partir de uma imagem de satélite para uma mesma área, diferentes profissionais obteriam modelagens diferentes: um geomorfólogo teria um mapa de unidades territoriais, um biólogo, um mapa de diferentes unidades de cobertura vegetal, etc.

Mas, é possível deparar-se com a seguinte questão: Qual é o melhor modelo? Para isso, deve-se levar em consideração o grau de similaridade do modelo gerado com o resultado do fenômeno natural. E pode-se realizar uma estimativa a partir do

conhecimento e previsão que o modelo resultou sobre o fenômeno. Assim, são fatores relevantes: a acurácia dos dados e os métodos de aquisição (Longley, 2005).

Câmara (1996) define a modelagem de dados como um conjunto de ferramentas conceituais que caracterizam a realidade de uma forma que poderá ser representada. Nos SIG's a modelagem define como a realidade geográfica será representada no computador.

O processo de modelagem é a forma de que se dispõe para traduzir o mundo real em outros domínios. A Figura 1 apresenta uma abordagem das mais úteis para realizar essa modelagem, o chamado “paradigma dos quatro universos” (Gomes, 1995).

Figura 1 – Modelagem segundo o paradigma dos quatro universos

Fonte: Adaptado de Gomes (1995)

Ainda sobre o fluxograma apresentado na figura 1, é possível apresentar as definições de cada um dos paradigmas:

No universo do mundo real: estão situados os elementos ou fenômenos de uma realidade a ser representada, que no caso do espaço geográfico, podem ser: dados climatológicos, tipos de solo, cadastros urbano e rural, dados geofísicos, topográficos e socioeconômicos.

O universo conceitual ou matemático: pode ser distinguido entre as grandes classes formais de dados geográficos, os dados contínuos e objetos

individualizáveis, e especializar estas classes nos tipos de dados geográficos mais comuns, os dados temáticos e cadastrais, modelos numéricos de terreno, dados de sensoriamento remoto.

Universo de representação: as entidades formais definidas no universo conceitual são associadas a diferentes representações geométricas, que podem variar conforme a escala, a projeção cartográfica e a época de aquisição do dado. Aqui se distingue entre as representações matriciais e vetoriais.

Universo de implementação: é onde ocorre a realização da modelagem dos dados através de linguagens de programação. Neste universo, escolhem-se as estruturas de dados para implantar as geometrias do universo de representação.

Portanto, na construção dos modelos de dados geográficos, dados espaciais são selecionados do “mundo real”. Exemplos são: topográficos, meteorológicos, pedológicos, geológicos. Cada um desses tipos de dados tem características próprias e que devem ser definidas quando for realizada a “modelagem computacional”.

Com relação à modelagem em SIG e principalmente sobre a modelagem matemática de dados espaciais, Becker (1996) define como uma das características dos SIG's a representação da informação espacial na forma numérica. Essa modelagem é realizada pela utilização de ferramentas que descrevam e manipulem essa informação numérica. Isso tem estimulado o desenvolvimento de outras áreas de estudo em SIG, como estatística espacial, álgebra de mapas, RNA, etc.

No entendimento do mundo das representações, devem-se discutir dois conceitos: o mundo real e conceitual, e suas principais características:

No mundo real, onde a intenção é construir um modelo não limitado de uma área sendo utilizado um SIG para sua gestão, e, através deste, desenvolver estudos em diversas áreas como: urbanos, agricultura, geologia e redes de transporte,

gestão agrícola. É preciso estabelecer quais modelagens serão realizadas dentro do SIG.

Assim, o mundo real e suas características específicas podem ter a seguinte modelagem proposta por Câmara (1997):

Tabela 1 – Modelagem de dados do mundo real

Escalas típicas	Escalas típicas	Representações Gráficas	Operações
1:10.000 a 1:1.000.000	dados temáticos, Sensoriamento Remoto	matricial, vetorial	classif. imagens, consulta espacial
1:5.000 a 1:250.000	dados temáticos, Sensoriamento Remoto, MNT, cadastro rural	matricial, vetorial, grades, TIN	análise espacial, declividade, consulta espacial
1:50.000 a 1:5.000.000	MNT, imagens, dados temáticos	grades, matricial vetorial	transf. IHS, visualiz. 3D
1:1.000 a 1:10.000	redes lineares (topologia)	Vetorial	consulta espacial, cálculos dedicados
1:1.000 a 1:25.000	redes, cadastro urbano e rural	Vetorial	consulta espacial
Várias	dados alfanuméricos, cadastros	N/A	consulta espacial, cálculos dedicados

Fonte: Adaptado de Câmara (1997)

No campo da modelagem conceitual, dividem-se os dados em duas possibilidades: modelos de campos e modelos de objetos. Os modelos de campos fazem referência aos fenômenos de natureza contínua no espaço geográfico (dados contínuos) e os modelos de objetos representam uma coleção de entidades distintas e identificáveis (dados discretos) (Worboys, 1995).

Após a caracterização da modelagem dos dados geográficos serão apresentadas as duas principais formas de modelagem geométrica e conceituais em

um SIG: os grupos de campos-objetos e matricial-vetorial, e eles se encontram em níveis distintos de abstração (Câmara, 1997).

Essa análise também indica que a interface de usuário de um SIG deve, sempre que possível, refletir o universo conceitual e esconder detalhes dos universos de representação e implementação. No nível conceitual, o usuário lida com conceitos mais próximos de sua realidade e se abstém da complexidade envolvida nos diferentes tipos de representação geométrica (Simião, 1999).

7.2. Procedimentos para definição dos modelos

Segundo Câmara (1996), as etapas para a definição de um modelo de trabalho e suas características devem seguir o seguinte roteiro de procedimentos:

1) definir as classes básicas do modelo e estabelecer as suas relações dentro dos princípios de especialização, generalização e agregação;

2) estabelecer como é possível, a partir do modelo, definir um esquema conceitual para um banco de dados geográficos, por especialização das classes básicas.

As classes básicas do modelo são definidas por: região, geo-campo, geo-objeto, objetos não-espaciais, plano de informação e banco de dados geográficos.

Uma região geográfica “R” denota uma superfície qualquer, pertencente ao espaço geográfico, que pode ser representada num plano ou reticulado, dependente de uma projeção cartográfica.

A região geográfica serve de suporte geométrico para localização de entidades geográficas, pois toda entidade geográfica será representada por um ponto ou um conjunto de pontos em “R”. A definição de região geográfica proposta não restringe a escolha da representação geométrica (matricial ou vetorial) associada aos objetos geográficos.

Os geo-campos são formados por variáveis cujos valores são definidos em todas as posições da região geográfica de estudo, ou seja, são variáveis espacialmente contínuas. Exemplos de temas que atentem essas especificidades são: variáveis como temperatura, topografia, teor de minerais, mapa de solos, etc.

Usando uma abordagem mais formal, pode-se definir um geo-campo (f) como uma entidade matemática que representa a distribuição de uma variável espacialmente contínua sobre uma região geográfica (R).

$f = [R, V, \lambda]$; onde:

R : região geográfica definindo o domínio espacial

V : contradomínio de valores da variável na região geográfica

λ : mapeamento entre pontos (x,y) em R e valores em V ($\lambda : R \rightarrow V$)

Diversas representações de um mesmo geo-campo podem significar a variação no tempo ($t_1, t_2, \dots, t_{N-1}$). A partir desse conceito é possível estabelecer estudos vinculados à cronologia de eventos.

Os geo-campos podem ser especializados em:

Temático – em uma região geográfica qualquer, um geo-campo temático associa a cada ponto do espaço um tema de um mapa, por exemplo: um geo-campo de vegetação é caracterizado pelo conjunto de temas (floresta densa, floresta aberta, cerrado);

Numérico – dada uma região geográfica, um geo-campo numérico associa a cada ponto do espaço um valor real, por exemplo, de mapa de altimetria;

Dados de Sensor Remoto – esta classe é uma especialização do tipo numérico, obtida através de discretização da resposta recebida pela imagem gerada por um sensor remoto de uma área da superfície terrestre.

Os geo-objetos podem ser caracterizados como: elemento discreto que possui atributos não espaciais e está associado a múltiplas localizações geográficas

e representações gráficas. A localização pretende ser exata e o objeto é distinguível de seu entorno.

Objetos não-espaciais são entidades que possuem localizações geográficas, ou seja, objeto não-espacial é qualquer tipo de informação que não seja georreferenciada.

Os chamados Planos de Informação ou PI's são uma forma de interface entre o usuário e os conceitos de geo-campos e geo-objetos. Uma instância da classe, plano de informação representa, para uma dada região geográfica qualquer, o lugar geométrico de um conjunto de dados geográficos.

Finalizando, a estrutura organizacional de um banco de dados geográficos é: os conjuntos de um universo de estudo composto por geo-campos, geo-objetos e objetos não-espaciais.

7.3. Análise e operações espaciais

Não há dúvida que a grande potencialidade dos SIG's está na possibilidade de gerar análises espaciais, para isso, utiliza dados (atributos) espaciais e não-espaciais como subsídio para os procedimentos que geram simulações através de modelagens.

As operações de análise espacial são efetuadas sobre as entidades geográficas dentro dos SIG's, sendo estabelecida a seguinte natureza: operadores sobre geo-objetos, operadores sobre geo-campos, operadores de transformação entre geo-campos e geo-objetos e operadores mistos entre geo-objetos e geo-campos (Câmara, 1997).

Segundo Goodchild (1987); Maguire and Dangermond (1991); Burrough (1986); Egenhofer (1994) e ainda em diversos manuais de operações dos SIG's disponíveis no mercado, podem ser encontradas variadas tentativas de sistematização das operações em um SIG. Pode-se encontrar ainda diferentes possibilidades de operações espaciais envolvendo procedimentos de consulta sobre geo-objetos e operações de manipulação sobre geo-campos (Tomlin, 1990).

Como esta tese é baseada na plataforma do SPRING, serão avançados os conceitos de manipulação de processos algébricos para este software.

O SPRING possuiu uma linguagem especial disponível, o LEGAL (Linguagem Espacial para Geoprocessamento Algébrico), que é um instrumento muito importante para a intervenção nos dados geográficos de um banco.

Basicamente, ela é uma linguagem de consulta e manipulação espacial que realiza operações sobre dados geográficos dos tipos: Mapa Temático, Modelo Numérico de Terreno e Imagens e tem como grande qualidade a possibilidade de o próprio pesquisador interagir na construção das operações e realizar as adaptações

necessárias para suas necessidades, não ficando “preso” a algoritmos predefinidos como em outros softwares.

Seguirá abaixo uma visão geral de LEGAL, seus objetivos e características. O enfoque principal será sobre os operadores de álgebra de mapas, pois é o tema mais abordado nesta tese, restrito aos operadores sobre geo-campos e que será baseado nos conceitos de Câmara (1996). Outros operadores, extensões e aplicações de LEGAL podem ser vistos nos mecanismos de consulta e recuperação descritos no mesmo autor.

7.3.1. Classificação de LEGAL

No contexto de interfaces usuário-computador, o LEGAL é classificado como “interface por linguagem de programação”, possuindo as características, vantagens e desvantagens inerentes a esse tipo de interface.

Para executar um procedimento de análise espacial no LEGAL, o usuário utiliza um editor de texto para escrever programas em linhas de comando, e submete ao interpretador da linguagem do SIG. No caso do LEGAL, o interpretador foi desenvolvido como um módulo adicional ao SPRING.

7.3.2. Características do LEGAL

A linguagem LEGAL foi proposta com o objetivo de prover um ambiente único para análise geográfica, incluindo operações de manipulação, operações de consulta espacial e operações de apresentação.

Assim, enquanto outros sistemas tratam essas classes de operações de forma separada, obrigando o usuário a mudar de ambiente, no LEGAL, o usuário tem todas essas funcionalidades numa mesma linguagem, e estas podem expressar um procedimento completo através de um programa.

7.3.1. Classes do modelo de dados e sua representação no LEGAL

De acordo com o conteúdo que foi apresentado para o processo de modelagem em um SIG, o resultado da aplicação do conceito de modelagem dentro do SPRING são classes de dados de uso específicos com diferentes finalidades. Na prática, essas classes são nomes reservados da linguagem que permitem ao usuário organizar os dados da sua aplicação.

No LEGAL, os dados são representados por variáveis e é necessário que a classe da variável seja compatível com a classe de dados que ela representa. Assim, uma variável representa um dado pertencente ao banco de dados no ambiente do SPRING e, portanto, os tipos de variáveis disponíveis têm relação direta com o modelo de dados geográfico. Os modelos são:

1 – Cadastral para instâncias de cadastral
2 – Temático para instâncias de Temático
3 – Imagem para instâncias de Imagem
4 – Digital para instâncias de Numérico
5 – Objetos para instâncias de Geo-objeto
6 – Não-espacial para instâncias de dado Não-espacial
7 – Rede para instâncias de Rede

7.3.2. Seções de um programa no LEGAL

O formato geral de um programa escrito em LEGAL deve compreender as seções de declaração, instanciação e de operações de transformação como apresenta a Figura 2, em que cada uma tem seu respectivo objetivo:

7.3.3. Formato para uma programação em LEGAL

A seguir serão apresentados as funcionalidades, aplicações e exemplos para os três níveis de um programa em LEGAL: Declaração, Instanciação e Operação.

1) Declaração:

Na seção de declaração define-se o nome de uma ou mais variáveis que poderão ser utilizadas no decorrer do programa. Toda variável deve ser declarada antes de ser usada por algum comando da linguagem.

É através desses nomes de variáveis que o programa acessa os dados no banco de dados geográficos. Além de definir o nome de uma variável, a ação de declaração também determina que categoria de dados geográficos está presente no banco e que poderá posteriormente ser associada a esse nome. A Figura 3 apresenta os tipos de categorias para a declaração.

Figura 3 – Sintaxe das Declarações em LEGAL

Fonte: Adaptado de Spring (1996)

2) Instanciação:

A instanciação é caracterizada pelos comandos *Recupere* e *Novo*. O comando *Recupere* associa o nome de uma variável a um Plano de Informação do banco de dados geográficos, já o comando *Novo* cria um novo Plano de Informação (Figura 4).

Figura 4 – Sintaxe das Instanciações em LEGAL

Fonte: Adaptado de Spring (1996)

3) Operação:

Após a declaração e instanciação de variáveis, segue a definição das ações através da construção de expressões que, em LEGAL, são representadas por operações. Em uma operação, uma variável recebe o resultado do processamento de expressões envolvendo operadores da linguagem que atuam sobre as variáveis declaradas e instanciadas no programa. A figura 5 apresenta os possíveis relacionamentos em operações:

Figura 5 – Sintaxe geral para Operações em LEGAL

Fonte: Adaptado de Spring (1996)

Os operadores aritméticos “+”, “-”, “*”, “/” e “^”, assim como funções matemáticas (seno, tangente, etc.), são entendidos como pontuais ou locais, isto é, atuam sobre cada elemento de representações matriciais de imagens ou grades numéricas, ou sobre elementos vizinhos que são localizados relativamente a um elemento de referência.

A seguir será descrito o conteúdo de cada um das expressões por tipo de classe:

A) Expressão Imagem:

Expressões Imagem compõem o conjunto das operações possíveis sobre a classe Imagem. A Figura 6 apresenta a sintaxe para as operações sobre imagens.

Figura 6 – Sintaxe de Operações sobre Imagem

Fonte: Adaptado de Spring (1996)

B) Expressão Numérica:

Expressões Numéricas compõem o conjunto das operações possíveis sobre a classe Numérica. (Figura 7)

Figura 7 – Sintaxe de Operações sobre Numérico

Fonte: Adaptado de Spring (1996)

C) Expressão Temática:

Expressões Temáticas compõem o conjunto das operações possíveis sobre a classe Temática (Figura 8).

Figura 8 – Sintaxe de Operações sobre Temático

Fonte: Adaptado de Spring (1996)

D) Expressão Condicional:

Expressões Condicionais atuam sobre classes de dados indistintamente compondo as expressões já mencionadas (Figura 9).

Figura 9 – Sintaxe das expressões condicionais

Fonte: Adaptado de Spring (1996)

7.3.4. Operadores entre geo-campos

Os operadores entre geo-campos no LEGAL são dos tipos: Operadores Pontuais e os Operadores Locais e Zonais, a saber:

Operações Pontuais: se distinguem por atuarem em cada ponto do mapa baseado somente em seu valor, não levando em consideração os valores dos pontos vizinhos (Figura 10 letra a).

Operadores Pontuais Unários: esses operadores requerem que o usuário defina uma tabela de mapeamento entre os geo-campos de entrada e de saída. O usuário cria uma instância da classe Tabela do tipo: Tabela de fatiamento, Tabela de ponderação, Tabela de reclassificação, conforme o respectivo operador, Fatie, Pondere e Reclassifique (Figura 10 letra b).

Operadores Zonais: são um subconjunto de operações de vizinhança que na máscara são substituídas por classes de um geo-campo temático (10 letra c).

Figura 10 – Classe de operadores sobre geo-campos

Fonte: Adaptado de Spring (1996)

Abaixo serão apresentados os conceitos e exemplos no LEGAL para as diferentes possibilidades de operações sobre os geo-campos.

A) Fatie, para pontual unitário.

O operador Fatie transforma um modelo Numérico ou uma Imagem em um Temático. Sua tabela de mapeamento estabelece as faixas de valores do geo-campo que irá compor as geo-classes do PI temático a ser criado.

Exemplo de aplicação – Fatie.

Operação de fatiamento onde um mapa de declividade em graus é convertido para um mapa de classes de declividade a partir da transformação:

{(0-5%)-"baixa"; (5-15%)-"média"; (acima de 15%)-"alta"}. Figura 11

Figura 11 – Operação de Fatiamento LEGAL

<p>Operação de Fatiamento</p>
<pre> { // Declaração de Variáveis Tematico classes_decl ("Declividade"); Numerico decliv_num ("Declividade_Numerica"); Tabela tab_fatia (Fatiamento); // Definicao da tabela de fatiamento tab_fatia = Novo (CategoriaFim = "Declividade", [0.0, 5.0] : "Baixa", [5.0, 15.0]: "Media", [15.0, 45.0]: "Alta"); // Recuperação do PI de Declividade Numérica decliv_num = Recupere (Nome = "Declive_SJC"); // Geracao do PI de saida classes_decl = Novo (Nome = "Classes_Decl", ResX = 50, ResY = 50, Escala = 100000); // Operação de Fatiamento classes_decl = Fatie (decliv_num, tab_fatia); } </pre>	<p>Linhas de Comando do LEGAL</p>

B) Pondere, para pontual unitário.

O operador Pondere transforma um Temático em um Numérico através da uma tabela de ponderação. Sua tabela de mapeamento estabelece valores para o geo-campo de saída conforme as geo-classes de entrada.

Exemplo de aplicação – Pondere.

O operador de ponderação para a conversão de um mapa de solos em um mapa de solos ponderado. Neste caso, o Plano de Informação de entrada é Temático, um mapa de solos, com as classes { Le, Li, Ls,Aq }, e o Plano de Informação de saída é Numérico, cujos valores estão entre o intervalo de [0;1] e a operação de ponderação consiste na associação: {(Le:0.60), (Li:0.20), (Ls:0.35), (Aq:0.10)} (Figura 12).

Figura 12 – Operação de Ponderação em LEGAL

Operação de Ponderação
<pre>{ // Parte 1- Declaracao Tematico SOLOS ("Solos"); Tabela ponderaSOLO (Ponderacao); Numerico SOLOpond ("SoloPonderado"); // Definicao da Tabela de Pesos ponderaSOLO = Novo (CategoriaIni = "Solos", Le : 0.60, Li : 0.2, Ls : 0.35, Aq : 0.1); // Parte 2 - Instanciacao do mapa de solos SOLOS = Recupere (Nome = "SoloCE"); // Criacao do novo mapa de solos ponderado SOLOpond = Novo (Nome = "solop", ResX = 30, ResY = 30, Escala = 100000, Min = 0, Max = 1); // Parte 3 - Operacao de Ponderacao SOLOpond = Pondera (SOLOS, ponderaSOLO); }</pre>	Linhas de Comando do LEGAL

C) Reclassifique, para pontual unitário.

O operador Reclassifique transforma um mapa Temático em outro Temático de classe distinta. Sua tabela de mapeamento estabelece quais as geo-classes do Temático de entrada que irão compor as geo-classes do Temático de saída.

Exemplo de aplicação – Reclassifique.

Um mapa de cobertura do solo na Amazônia com diferentes classes {"Floresta Densa", "Floresta Várzea", "Rebrota", "Área Desmatada", "Cerrado"}. Este mapa Temático será reclassificado para um novo mapa apenas com as classes {"Floresta", "Desmatamento", "Cerrado"}. (Figura 13)

Figura 13 – Operação de Reclassificação em LEGAL

<pre> { // Parte 1 - Declaração Tematico cobertura ("Floresta"); Tematico desmat ("Desmatamento"); Tabela tab_recl (Reclassificacao); tab_recl= Novo(CategoriaIni = "Floresta", CategoriaFim = "Desmatamento", "FlorestaDensa" : "Floresta", "FlorestaVarzea" : "Floresta", "Rebrota" : "Desmatamento", "AreaDesmatada" : "Desmatamento", "Cerrado" : "Cerrado"); // Parte 2 - Instanciação- Recuperação da variável cobertura = Recupere (Nome = "Uso_JiParana"); // Criação do novo PI desmat = Novo (Nome = "Desmat_JiParana", ResX= 30, ResY = 30, Escala = 100000); // Parte 3 - Operação Reclassificação desmat= Reclassifique (cobertura, tab_recl); } </pre>	<p>Linhas de Comando do LEGAL</p>
--	---------------------------------------

Fonte: Adaptado de Spring (1996)

D) Atribua, para Operações Booleanas entre geo-campo.

É uma operação pontual unária que realiza transformações baseadas no valor de cada posição de mais de um geo-campo de entrada através de álgebra booleana. Esse tipo de operação recebe como entrada um Imagem, Numérico ou Temático e retorna um dado Temático.

É necessário informar um conjunto de regras booleanas para determinar quais condições dos dados de entrada irão satisfazer às classes dos dados de saída.

Exemplo de aplicação – Atribua.

A Tabela 2 exemplifica o uso de operação booleana, aplicado à classificação de aptidão agrícola:

Tabela 2 – Regras para Aptidão Agrícola

Aptidão	Solos	Declividade
Boa	Latossolo Roxo	0-3%
Média	Latossolo Vermelho-Amarelo	3-8%
Inapta	Areia Quartzosa	>8%

Fonte: Adaptado de Spring (1996)

As linhas de comando para criar um Temático a partir dos conceitos expostos na tabela acima. Figura 14

Figura 14 – Operação de Atribua em LEGAL

```
{
  // Parte 1 - Declaração
  Tematico solos ("Solos"), aptidao ("Aptidao"),
                                decliv ("Declividade");

  // Parte 2 - Instanciação
  decliv = Recupere(Nome = "Decliv94");
  solos = Recupere (Nome = "Solos94");
  aptidao = Novo (Nome = "apt94", ResX=50, ResY=50,
                  Escala = 50000);

  // Parte 3 - Operacao
  aptidao= Atribua (CategoriaFim = "Aptidao")
  { "Boa" : (solo.Classe = "LatosoloRoxo" &&
            decliv.Classe = "0-3"),
    "Media" : (solo.Classe = "LatosolVeAm" &&
              decliv.Classe = "3-8"),
    "Inapto" : (solo.Classe = "AreiaQuat" &&
               decliv.Classe = ">8")};
}
```

Fonte: Adaptado de Spring (1996)

E) Operações Matemáticas, para pontual unitário.

São operações matemáticas pontuais que atuam sobre PI's da Categoria Numérico e Imagem, onde as expressões válidas são:

Operações aritméticas: soma (+), subtração (-), multiplicação (*) e divisão (/);

Funções matemáticas: seno (sin), cosseno (cos), tangente (tan), arcosseno (asin), arco-cosseno (acos), arco-tangente (atan), logaritmo (log), logaritmo base 10 (log10), exponencial (exp), raiz quadrada (sqrt), inteiro (int), valor absoluto (abs);

Relações: menor que (<), maior que (>), menor ou igual (<=), maior ou igual (>=), igual (==), diferente (!=).

Exemplo de aplicação – Operações Matemáticas.

Tomando a figura 15, em que o PI da esquerda é um mapa de solos ponderado e o PI da direita é um mapa de declividade, considere-se que se deseje criar um indicador de adequação de solos a partir da soma do valor atribuído ao solo com o inverso da declividade.

A operação a seguir poderia ser utilizada como passo intermediário ao calcular um mapa de adequação de solos (quanto maior o valor, mais adequado):

Figura 15 – Operações Matemáticas em LEGAL

Operação Matemáticas
<pre> { // Parte 1 - Declaração Numerico solo_pond ("Solo_ponderado"), Decliv ("Declividade"), aptidao ("AdequacaoNumerico"); // Parte 2 - Instanciação decliv = Recupere (Nome = "Decliv94"); solo_pond = Recupere (Nome = "Solos94"); aptidao = Novo (Nome = "adequacao94", ResX=50, ResY=50, Min=0, Max=2, Escala = 50000); // Parte 3 - Operacao aptidao = solo_pond + 1/decliv; } </pre>	Linhas de Comando do LEGAL

Fonte: Adaptado de Spring (1996)

F) Reclatrib, reclassificação por atributo.

São operações pontuais que reclassificam, reagrupam classes baseadas em seus valores, ou operações que nos permitem gerar geo-campos a partir de geo-objetos.

Exemplo de aplicação – Operações de reclassificação por atributo.

Considerando o caso em que um mapa de distribuição da pobreza do Brasil que será obtido a partir dos dados do IBGE, agregados por estado. Um dos atributos é a renda *per capita*. Para isso é necessária uma composição de operações: primeiramente é gerado um modelo de terreno com a distribuição da variável renda *per capita*, depois fatia-se o modelo em classes. (Figura 16)

Figura 16 – Linhas do LEGAL para reclassificação por atributo

```
{
Colecao      estados      Estado_Brasil;
Tematico     mapa_estados  Mapa_IBGE;
Tematico     campo_renda  Campo_Renda;
Tematico     tab_fatia     Slice_Table;
Atributo     renda_per_capita  FLOAT;
Mapa_renda = Novo (nome = "Mapa Riqueza Brasil")
              (RES_X = 1000m, RES_Y = 1000m);
tab_fatia = Novo ( CLASS_OUT = RENDA,
                  ([0-500] : "Miseravel",
                   (500-1000] : "Pobre",
                   (1000-2000] : "Remediado",
                   >2000 : "Rico"));
mapa_renda = Fatie
              (Reclatrib(estados,renda_per_capita)
               ON MAP mapa_estados), tab_fatia);
}
```

Fonte: Adaptado de Spring (1996)

G) Operações por Vizinhança.

As operações de vizinhança levam em consideração os valores dos pontos próximos na mesma região do geo-campo de entrada para determinarem o valor para uma posição do geo-campo de saída.

O processamento de um operador de vizinhança se dá pela definição de uma máscara que se desloca sobre o geo-campo de origem, e a cada passo desse deslocamento, aplica uma operação que se baseia nos valores das posições compreendidas pela máscara.

Os Operadores locais são:

SomaL – Calcula a soma local dos pontos do geo-campo para uma vizinhança;

MédiaL – Calcula a média local dos pontos para uma vizinhança especificada;

MaxL – Determina o máximo local dos pontos do geo-campo, dada uma vizinhança;

MinL – Determina o mínimo local dos pontos do geo-campo, dada uma vizinhança;

StdevL – Calcula o desvio padrão dos pontos do geo-campo, dada uma vizinhança;

VarL – Determina o número de valores distintos do geo-campo, para uma vizinhança em torno de cada ponto.

A Sintaxe geral desses operadores é:

$\langle \text{Geo-campo} \rangle = \langle \text{operador_local} \rangle (\langle \text{Geo-campo} \rangle, \langle \text{Local_region} \rangle);$

H) Zonais entre geo-campos.

As operações zonais entre geo-campos são um subconjunto de operações de vizinhança em que as máscaras são substituídas por classes de um geo-campo temático.

O valor de cada posição do geo-campo gerado por uma operação, depende do valor do atributo em todas as posições geográficas que compõem a região no geo-campo de origem.

Operadores Zonais:

MaxZ – Determina o máximo zonal dos pontos do Geo-campo;

MinZ – Determina o mínimo zonal dos pontos do Geo-campo;

MedZ – Determina o médio zonal dos pontos do Geo-campo;

MaiZ – Determina a maioria zonal dos pontos do Geo-campo;

MinoZ – Determina a minoria zonal dos pontos do Geo-campo;

SomZ – Determina a soma zonal dos pontos do Geo-campo;

VarZ (ou variabilidade) – Determina a diversidade zonal dos pontos do Geo-campo.

A Sintaxe geral desses operadores é:

<code><campo> = <operador_zonal> (<Numerico>,<Temático>."Classe *");</code>

A Tabela 3 apresenta o resumo e a hierarquia das operações sobre geo-campos disponíveis em LEGAL:

Tabela 3 – Relação de Operadores sobre Geo-campos

Classificação	Operador
Operadores Pontuais sobre geo-campos:	
Operadores Unários:	
Pondere	Pondere
Fatie	Fatie
Reclassifique	Reclassifique
Operações Booleanas sobre Geo-campos	Atribua
Operações Matemáticas sobre Geo-campos	= <expressões matemáticas>
Operações Fuzzy sobre Geo-campos	Fuzzy, FuzzyR, FuzzyL
Operações de Vizinhança sobre Geo-campos	MaxZ, MinZ, MedZ, StdevL, SomZ, VarZ
Operações Zonais sobre Geo-campos	MaxZ, MinZ, MedZ, MaiZ, MinoZ, SomZ, VarZ

Fonte: Adaptado de Lucena (1998)

7.4. Redes Neurais Artificiais

Existe uma série de problemas que os seres vivos e os seres humanos, em particular, parecem resolver de uma maneira inata, utilizando seu cérebro, como por exemplo: processamento de imagens; reconhecimento de fala; recuperação de informações de maneira associativa; aprendizado de novos fatos e ideias; seleção de informações, etc. As RNA's foram criadas inspiradas no funcionamento do cérebro humano, e buscam, de forma geral, o desenvolvimento de um modelo de resolução de problemas complexos

É possível encontrar na literatura diversas definições para as RNA's, abaixo seguem algumas definições de diferentes autores que caracterizam e sintetizam a estrutura de funcionamento delas:

Para Hernandez (2007), pode-se definir que redes de neurônios artificiais são sistemas de computação adaptativos, inspirados nas características de processamento de informação encontradas nos neurônios reais, biológicos e nas características de suas interconexões. Ainda, são sistemas de computação massivamente paralelos e podem ser implementados tanto em *softwares* quanto em *hardware*, destacando que individualmente os elementos têm capacidades relativamente limitadas.

Haykin (2001) define uma RNA como sendo um processador maciço e paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental, e aplicá-lo para resolver problemas.

Para Dougherty (1995), a RNA é uma terminologia genérica que abrange uma grande quantidade de arquiteturas e paradigmas, que têm como objetivo compreender o funcionamento do cérebro humano e, de alguma forma, procurar produzi-lo. As RNA's são compostas de um número grande de elementos de processamento, denominados neurônios.

Em Cybenko (1989), lê-se que as redes neurais artificiais podem apresentar uma ou mais camadas intermediárias ou escondidas de neurônios. No tipo de rede denominada MLP (Multilayer Perceptron), pode-se implementar qualquer função contínua em uma rede com uma camada intermediária. Já a utilização de duas camadas intermediárias permite a aproximação de qualquer função.

7.4.1. Redes Neurais Artificiais – Histórico

Neste item será apresentado um breve histórico sobre o surgimento e desenvolvimento das RNA's, baseado na bibliografia do curso Inteligência Computacional e Redes Neurais em Engenharia Elétrica (Hernandez, 2007).

As primeiras informações mencionadas sobre a neurocomputação datam de 1943, em artigos de Warren McCulloch e Walter Pitts, em que sugeriam a construção de uma máquina baseada ou inspirada no cérebro humano. Estruturalmente, podemos definir como sendo o primeiro modelo artificial de um neurônio, tendo como característica principal deste trabalho descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais. Esse modelo pouco apresentou técnicas de aprendizado.

Donald Hebb escreveu um livro intitulado *The Organization of Behavior* (A Organização do Comportamento), no qual perseguia a ideia de que o condicionamento psicológico clássico está presente em qualquer parte dos animais, pelo fato de ser uma propriedade de neurônios individuais. Suas ideias não eram completamente novas, mas Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios. Esse primeiro e corajoso passo serviu de inspiração para que muitos outros pesquisadores seguissem a mesma ideia.

O trabalho de Donald Hebb mostrou como a plasticidade da aprendizagem de redes neurais é conseguida através da variação dos pesos de entrada dos nós. Ele propôs uma teoria para explicar o aprendizado em nós biológicos baseada no reforço das ligações sinápticas entre os nodos excitados.

A regra de Hebb, como é conhecida a sua teoria na comunidade de RNA's, foi interpretada do ponto de vista matemático e é hoje utilizada em vários algoritmos de aprendizado. Mais tarde, Widrow e Hoff sugeriram uma regra de aprendizado, conhecida como regra de Widrow-Hoff ou regra delta, que é ainda hoje bastante utilizada. Esta, por sua vez, é baseada no método do gradiente para minimização do erro na saída de um neurônio com resposta linear.

Também, proveniente deste período de tempo, é a construção do primeiro neurocomputador, denominado Snark, por Marvin Minsky em 1951. O Snark operava com sucesso a partir de um ponto de partida técnico, ajustando seus pesos automaticamente, entretanto, ele nunca executou qualquer função de processamento de informação interessante, mas serviu de inspiração para as ideias de estruturas que o sucederam.

Em 1956, no *Dartmouth College* nasceram os dois paradigmas da Inteligência Artificial, o da simbólica e o conexionista. A Inteligência Artificial Simbólica tenta simular o comportamento inteligente humano desconsiderando os mecanismos responsáveis por tal. Já a Inteligência Artificial Conexionista acredita que construindo um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros.

Em 1953, Frank Rosenblatt demonstrou com o seu novo modelo, o *perceptron*, que se fossem acrescentadas de sinapses as RNA's, com nodos desenvolvidos por Pitts e McCulloch, poderiam ser treinadas para classificar certos tipos de padrões.

O primeiro neurocomputador a obter sucesso (*Mark I Perceptron*) surgiu entre os anos de 1957 e 1958 e foi criado por Frank Rosenblatt, Charles Wightman e outros. Devido à profundidade de seus estudos, suas contribuições técnicas e de sua maneira moderna de pensar, muitos veem Frank Rosenblatt como o fundador da neurocomputação na forma em que se tem hoje.

Seu interesse inicial para a criação do *Perceptron* era o reconhecimento de padrões. Ele descreveu uma topologia de RNA, estruturas de ligação entre os nós, e o mais importante, propôs um algoritmo para treinar a rede para executar determinados tipos de funções.

Esse tipo elementar de *perceptron* comporta-se como um classificador de padrões, dividindo o espaço de entrada em regiões distintas para cada uma das classes existentes. Inicialmente a saída da rede é aleatória, mas pelo ajuste gradual dos pesos, o *perceptron* é treinado para fornecer saídas de acordo com os dados do conjunto de treinamento.

Após Rosenblatt, Bernard Widrow desenvolveu um novo tipo de elemento de processamento de redes neurais chamado de *Adaline*, equipado com uma poderosa lei de aprendizado que, diferente do *Perceptron*, ainda permanece em uso. Widrow também fundou a primeira companhia de hardware de neurocomputadores e componentes.

Nos anos 70, a abordagem conexionista ficou “adormecida”, em grande parte pela repercussão do trabalho de Misnky e Papert, o qual dizia que o *perceptron* era limitado a resolver problemas linearmente separáveis, ou seja, problemas cuja solução pode ser obtida dividindo-se o espaço de entrada em duas regiões através de uma reta (espaço R2). Alguns pesquisadores continuaram trabalhando nessa área, entre eles, podem ser citados Igor Aleksander (redes sem peso) na Inglaterra, Steven Grossberg (sistemas autoadaptativos) nos EUA, Kunihiro Fukushima (cognitron e neocognitron) no Japão e Teuvo Kohonen (associativas e auto-organizáveis) na Finlândia.

Nos anos 80, muitos pesquisadores foram bastante corajosos e passaram a publicar diversas propostas para a exploração de desenvolvimento de redes neurais, bem como suas aplicações. Porém, talvez o fato mais importante desse período tenha ocorrido quando Ira Skurnick, um administrador de programas da DARPA (*Defense Advanced Research Projects Agency*), decidiu ouvir os argumentos da

neurocomputação e seus projetistas e, divergindo dos caminhos tradicionais dos conhecimentos convencionais, fundou em 1983 as pesquisas em neurocomputação. Esse ato não só abriu as portas para a neurocomputação, como também deu à DARPA o *status* de uma das líderes mundiais em "moda" tecnológica.

Outra "potência" que emergiu nesse período foi John Hopfield, renomado físico de reputação mundial, que se interessou pela neurocomputação, e escreveu artigos que percorreram o mundo todo persuadindo centenas de cientistas, matemáticos e tecnólogos altamente qualificados a se unirem nesta nova área emergente.

Em 1982, John Hopfield publicou um artigo mostrando a relação entre redes recorrentes autoassociativas e sistemas físicos, o que também abriu espaço para a utilização de teorias correntes da física para estudar tais modelos. Não obstante, a descrição do algoritmo de treinamento *backpropagation*, alguns anos mais tarde mostrou que a visão de Misnky e Papert sobre o *perceptron* era bastante pessimista. As RNA's de múltiplas camadas são capazes de resolver problemas não-lineares ou "difíceis de aprender". A partir de meados da década de 80, houve nova explosão de interesse pelas RNA's na comunidade internacional.

Apesar de um terço dos pesquisadores da área ter aderido à mesma pela influência de Hopfield, foi em 1986 que esse campo de pesquisa "explodiu" com a publicação do livro *Parallel Distributed Processing* (Processamento Distribuído Paralelo), editado por David Rumelhart e James McClelland.

Em 1987, ocorreu em São Francisco a primeira conferência de redes neurais em tempos modernos, a *International Conference on Neural Networks* (IEEE), e também foi formada a *International Neural Networks Society* (INNS). A partir desses acontecimentos decorreu a fundação do *INNS journal* em 1989, seguido do *Neural Computation* e do *Transactions on Neural Networks* em 1990.

Desde 1987, muitas universidades anunciaram a formação de institutos de pesquisa e programas de educação em neurocomputação. Alguns dos fatos mencionados são listados:

Neurofisiologista McCulloch e o matemático Walter Pitts (1943), cujo trabalho fazia uma analogia entre células vivas e o processo eletrônico, simulando o comportamento do neurônio natural, em que o neurônio possuía apenas uma saída, que era uma função de entrada (*threshold*) da soma do valor de suas diversas entradas;

O psicólogo Donald Hebb (1949) demonstrou que a capacidade da aprendizagem em redes neurais vem da alteração da eficiência sináptica, isto é, a conexão somente é reforçada se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas.

Rosenblatt (1958) mostrou em seu livro *Principles of Neurodynamics* o modelo dos *Perceptrons*. Nele, os neurônios eram organizados em camadas de entrada e saída, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica. (Figura 17)

Figura 17 – Rede de perceptrons proposta por Rosenblatt

Fonte: Adaptado de Tubb (1993)

Em 1960 surgiu a rede ADALINE (*Adaptative Linear Network*) e o MADALINE (*Many ADALINE*) *perceptron*, proposto por Widrow e Hoff. O ADALINE/MADALINE utilizou saídas analógicas em uma arquitetura de três camadas. (Figura 18)

Figura 18 – Redes ADALINE e MADALINE

Fonte: Adaptado de Tubb (1993)

Muitos históricos desconsideram a existência de pesquisa nessa área nos anos 60 e 70 e apontam uma retomada das pesquisas com a publicação dos trabalhos do físico e biólogo Hopfield (1982) relatando a utilização de redes simétricas para otimização, através de um algoritmo de aprendizagem que estabilizava uma rede binária simétrica com realimentação.

Rumelhart, Hinton e Williams introduziram o poderoso método *Backpropagation*. A Figura 19 apresenta a estrutura desse método.

Figura 19 – Estrutura do método *Backpropagation*

Fonte: Adaptado de Tubb (1993)

Cooper, Cowan, Fukushima, Von der Malsburg e muitos outros foram pesquisadores dos anos 60 e 70, cujos estudos devem ser citados:

Fatos relevantes em ordem cronológica:

1943: McCulloch e Pitts estabeleceram as bases da neurocomputação, com modelos matemáticos.
1949: Hebb traduziu matematicamente a sinapse dos neurônios biológicos.
1951: Minski constrói o Snark, primeiro neurocomputador com capacidade de aprendizado, ou seja, ajustava automaticamente os pesos entre as sinapses. Não executou nenhuma função útil.
1957: Rosenblatt concebeu o " <i>perceptron</i> ", que era uma rede neural de duas camadas, usado no reconhecimento de caracteres.
1967: Fim das verbas destinadas à pesquisa de redes neurais.
1974: Werbos lançou bases para o algoritmo de retropropagação (<i>backpropagation</i>).

Até agora podemos definir que os modelos neurais procuram aproximar o processamento dos computadores ao cérebro. A Tabela 4 traça um comparativo entre o cérebro humano e o computador:

Tabela 4 – Comparação cérebro humano/computador

Parâmetro	Cérebro	Computador
Material	Orgânico	Metal e plástico
Velocidade	Milissegundos	Nanossegundos
Tipo de Processamento	Paralelo	Sequencial
Armazenamento	Adaptativo	Estático
Controle de Processos	Distribuído	Centralizado
Número de elementos processados	10 e 11 a 10 e 14	10 e 5 a 10 e 6
Ligações entre elementos processados	10000	<10

Fonte: Adaptado de Hernandez (2007)

O mesmo paralelo pode ser traçado comparando o computador com as redes neurais. Para tanto, a comparação não se dará com um computador específico encontrado no mercado, mas sim com o paradigma predominante nos computadores atuais. (Tabela 5)

Tabela 5 – Comparativo entre computadores e neurocomputadores

Computadores	Neurocomputadores
Executa programas	Aprende
Executa operações lógicas	Executa operações não lógicas, transformações, comparações
Depende do modelo ou do programador	Descobre as relações ou regras dos dados e exemplos
Testa uma hipótese por vez	Testa todas as possibilidades em paralelo

Fonte: Adaptado de Hernandez (2007)

7.4.2. Modelo básico do neurônio artificial e a arquitetura da rede neural

O Neurônio Artificial é a unidade fundamental de processamento de uma RNA. Dentro de uma RNA um neurônio recebe uma ou mais entradas, transformando-as em saídas. Cada entrada tem um peso associado que determina sua intensidade (Tubb, 1993).

Segundo Haykin (1994), um modelo computacional básico para o neurônio considera a soma ponderada de entradas que são submetidas a uma função de ativação contínua com saturação. A figura 20 apresenta a estrutura do neurônio na forma de um esquema conceitual de funcionamento.

Figura 20 – Estrutura básica de um neurônio

Fonte: Adaptado de Haykin (1994)

Onde:

X_n : Camada de Entrada, onde os padrões são apresentados à rede;

W_{kn} : Conexões ponderadas, pesos;

Σ : Soma ponderada

φ : Função de ativação, funciona como um limitante à amplitude da saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, geralmente $[0,1]$ ou $[-1,1]$;

Y_k : Camada de Saída, onde o resultado final é concluído e apresentado.

As redes neurais artificiais são estruturas e compostas de diversos neurônios conectados em diferentes camadas. A figura 21 apresenta um exemplo dessa estrutura.

Figura 21 – Estrutura de uma arquitetura de rede neural artificial

Fonte: Adaptado de Freeman (1991)

Onde:

E = neurônios da camada de entrada

P_1 = neurônios da camada oculta

P_3 = neurônio da camada de saída

De acordo com o esquema de funcionamento apresentado na Figura 21, as RNA's podem ser definidas como unidades (neurônios interconectados) que trabalham em paralelo e geram dados de saída (Hassoun, 1995).

O funcionamento da RNA é baseado na interconexão entre os neurônios (unidades), onde os dados são ponderados e partir de dados de entrada, os pesos que representam a associação entre os neurônios são ajustados. Após o ajuste, para cada conjunto de dados apresentado à rede na primeira camada de neurônios (camada de entrada), a rede propaga sinais para as seguintes camadas, em função dos pesos predeterminados. (Freeman, 1991)

A atividade de uma unidade influencia no nível de ativação de outras unidades da rede, assim sucessivamente, até que a saída seja atingida (Hertz, 1991). De forma geral, a operação de um funcionamento da rede se resume em:

1. Sinais são apresentados à camada de entrada;
2. Cada sinal é multiplicado por um peso que indica sua influência na saída do neurônio para a próxima camada;
3. É feita a soma ponderada dos sinais que produz um nível de atividade;
4. É propagado o valor de saída para o seguinte neurônio.

As funções de ativação mais usadas nas redes neurais são:

A – Sigmoide

B – Tangente Hiperbólica

C – Linear

A Figura 22 apresenta o gráfico correspondente a cada uma das funções de ativação mais usadas em RNA's.

Figura 22 – Representação das funções de ativação

7.4.3. Tipologia das Redes Neurais Artificiais

Existem diversos tipos de RNA's e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado, podendo ser supervisionada e não supervisionada (Anderson, 1995).

No aprendizado supervisionado são sucessivamente apresentados à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante esse processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada “lei” de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo desejado. Exemplos desse tipo de processamento ocorrem na RNA do tipo *perceptron*, *adaline* e *madaline*, *backpropagation* (Hecht-Nielsen, 1989; Freeman e Skapura 1991; Beale e Jackson, 1992).

Nos modelos não supervisionados, não existe um sinal externo mostrando que valor uma dada unidade de saída deve assumir, ou indicando que os valores daquela saída são adequados ou não. De forma que uma rede não supervisionada deve descobrir por si só padrões, características, regularidades, correlações ou categorias embutidas nos dados de entrada e codificá-las na saída (Hassoun, 1995).

Dessa forma, a rede “analisa” os conjuntos de dados apresentados a ela, determina algumas propriedades dos conjuntos de dados e “aprende” a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades que a rede irá “aprender” sobre os dados podem variar em função do tipo de arquitetura utilizada e da lei de aprendizagem. Por exemplo, Mapa Auto-Organizável de Kohonen, Redes, de Hopfield, e Memória Associativa Bidirecional são alguns métodos de aprendizado não supervisionado (Kohonen, 1997; Hopfield, 1984).

As redes também podem ser classificadas quanto à sua estrutura de alimentação:

a) As redes diretas ("feedforward") são aquelas cujo grafo não tem ciclos. É comum representar estas redes em camadas e neste caso são chamadas redes em camadas. Nesta topologia, os neurônios que recebem sinais são chamados de camada de entrada, ou primeira camada. Os neurônios que têm sua saída como saída da rede pertencem à camada de saída, ou última camada. Os neurônios que não pertencem nem à camada de entrada nem à de saída são neurônios internos à rede e pertencem a uma ou mais camadas internas, também chamadas de camadas intermediárias ou camadas escondidas ("*hidden layers*"). Alguns autores também chamam essas camadas de ocultas (Barreto, 1995).

b) Redes com "feedback" são aquelas cujo grafo de conectividade contém pelo menos um ciclo. Por esta razão McCulloch chamou-as de "*networks with cycles*", ou redes com ciclos. Quando além disso envolvem neurônios dinâmicos, contendo um retardo, são chamadas de *recorrentes*. Exemplos dessas redes são as redes propostas por Hopfield e algumas redes bidirecionais com unidades de neurônios realimentadas (Barreto, 1995).

Para o desenvolvimento de um modelo ou projeto baseado em redes neurais artificiais são necessárias diversas etapas descritas conforme Caudill (1991): definição do problema; coleta dos dados de treinamento e de teste; pré e pós-processamento dos dados; projeto da estrutura da rede; treinamento; teste e validação. (Figura 23)

Figura 23 – Estrutura para o desenvolvimento de uma RNA

Fonte: Adaptado de Caudill (1991)

Na elaboração do projeto da RNA ideal para solucionar um determinado problema, uma das tarefas mais difíceis é determinar o número de elementos de processamento da camada oculta, bem como o número de camadas ocultas.

Não existem regras para isso, entretanto, Cybenko (1989) define que uma única camada oculta é suficiente para representar qualquer função ou para resolver a maioria dos problemas de generalização, pois qualquer função contínua pode ser uniformemente aproximada por uma rede neural artificial contínua de apenas uma camada.

No âmbito da Geografia as RNA's são empregadas em aplicações para modelagem, simulação, reconhecimento de padrões e séries temporais (Hewitson e Crane, 1994; Openshaw e Openshaw, 1997). As mais usadas são as redes multicamadas do tipo *feedforward*, que utilizam a lei de aprendizagem *backpropagation* (Hecht-Nielsen, 1989; Freeman e Skapura, 1991; Beale e Jackson, 1992; Rich e Knight, 1993) ou suas variações, tais como *resilient backpropagation*, *quickpropagation* e *backpercolation* (Zell *et alii*, 1991).

Também são utilizadas as redes do tipo SOM – Kohonen Self-Organizing Map, ou mapa auto-organizável de Kohonen (Hecht-Nielsen, 1994; Freeman e Skapura, 1991; Beale e Jackson, 1992; Zell *et alii*, 1991) em aplicações que envolvem o reconhecimento de padrões, tais como a classificação não supervisionada de imagens de sensoriamento remoto.

Para aplicação nesta tese e com base nos conceitos teóricos apresentados, será utilizada uma RNA do tipo multicamadas do tipo *Multilayer Perceptron* com método de aprendizagem supervisionado e algoritmo *backpropagation*.

7.4.4. Rede Multilayer Perceptron

As arquiteturas do tipo *perceptron* de múltiplas camadas (MLP) constituem os modelos neurais artificiais mais utilizados e conhecidos atualmente. Tipicamente, essa arquitetura consiste em um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída (Hagan, 1996).

Assim, essa RNA é composta por vários neurônios distribuídos em camadas. A primeira camada é chamada de camada de entrada e tem a função de armazenar os dados de entrada na rede. Nas camadas intermediárias denominadas de camadas escondidas ocorrem os processamentos da rede. A última camada é definida como de saída.

Essas unidades são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma RNA vem das interações entre as unidades de processamento da rede (Luk, 2000).

A maioria dos modelos de redes neurais possui alguma regra de treinamento, em que os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas “aprendem através de exemplos”.

7.4.5. Algoritmo de aprendizagem MLP

A regra utilizada para treinar uma rede MLP é conhecida como *backpropagation*, ou regra delta, esse algoritmo é fundamental para o sucesso dos trabalhos desenvolvidos com redes neurais em arquitetura MLP (Dangermond, 1990).

O algoritmo de retropropagação foi desenvolvido por Paul Werbos em 1974 e redescoberto por Parker (1982) e Rumelhart (1986). Desde sua redescoberta, ele tem sido muito utilizado como um algoritmo de aprendizado para as redes diretas e múltiplas camadas (Barreto 1999).

A Retropropagação é uma regra de aprendizado supervisionado. Apresenta-se à rede um exemplo e verifica-se a saída da rede, esta saída é comparada à saída esperada dando um erro. Calcula-se o gradiente desse erro com relação aos valores sinápticos da camada de saída que é atualizada por um passo escolhido, na direção

da diminuição deste erro, podendo-se então calcular o erro da saída da penúltima camada, e assim por diante, propagando para trás o erro (origem do termo "*backpropagation*") por todas as camadas de conexões (Barreto 1999).

A seguir apresenta-se mais um exemplo (pode ser o mesmo repetido) e continua-se o processo. O processo de redução gradativa do erro, que acompanha a minimização, denomina-se convergência. À medida que a rede aprende, o valor do erro converge para um valor estável, normalmente irreduzível. O processo de aprendizagem prossegue, até que algum critério seja estabelecido, como, por exemplo, um valor mínimo global, ou uma diferença sucessiva mínima entre erros calculados para cada iteração (Barreto 1999).

A retropropagação tem passos "*forward*" (para frente) e "*backpropagation*" (para trás). Esses passos são feitos para cada apresentação, durante o treinamento da rede, visando ao ajuste dos pesos e à minimização do erro, entre a saída que a rede oferece (com ajuste de seus parâmetros) e a saída que se deseja obter.

Assim, é possível dividir as etapas de treinamento na rede em duas:

1º - Propagação:

O passo propagação (*forward*) começa com a apresentação de cada padrão de entrada para cada elemento de entrada da rede e continua com os cálculos do nível de ativação propagando para frente através das unidades das camadas escondidas. Nas camadas sucessivas, soma as entradas a cada elemento de processamento e então aplica uma função que poderá ser, por exemplo, uma função linear para computar sua saída. As unidades da camada de saída produzem a saída da rede. Para ilustrar esse processo é apresentada a Figura 24 (Russel, 1995).

Figura 24 – Propagação do erro em RNA em MLP

Fonte: Adaptado de Dayhoff, 1992

2º - Retropropagação ("backpropagation"):

O passo Retropropagação (backpropagation) começa com a comparação dos padrões de saída com o vetor de saída e quando há diferença, o erro é calculado. O passo backpropagation calcula os valores de erro para as unidades escondidas e troca seus pesos, começando com a camada de saída e movendo para trás através das sucessivas camadas intermediárias e continua corrigindo os pesos de maneira a decrescer o erro, esse processo é apresentado na figura 25. (Russel, 1995)

Figura 25 – Retropropagação do erro na RNA em MLP

Fonte: Adaptado de Dayhoff (1992)

Durante a fase de treinamento deve ser apresentado um conjunto formado com valores de entrada para a rede e um valor desejado para resposta da entrada. A saída será comparada ao valor desejado e será computado o erro global da rede, que influenciará na correção dos pesos no passo de retropropagação. Apesar de não haver garantias de que a rede forneça uma solução ótima para o problema, esse processo é muito utilizado por apresentar uma boa solução para o treinamento de *Perceptrons* Multicamadas (Hagan, 1996).

O poder da retropropagação está na habilidade de *scanear* camadas escondidas, isto é, quando duas ou mais camadas de pesos são ajustadas, cada camada escondida age como uma camada detectora de característica, que responde a características específicas do padrão de entrada. Sendo assim, conhecendo as características do padrão, a rede pode identificar características efetivas automaticamente. O aprendizado de retropropagação tem como principal finalidade encontrar o ponto de erro mínimo, mas muitas vezes a superfície de erro pode conter pontos de erro mínimo local que não representa o melhor ponto, o chamado erro mínimo global (Algarve, 1994).

8. Caracterização da área de estudo

No capítulo 8 serão apresentadas as características gerais do município de Itirapina – SP, focando na descrição dos aspectos físicos da área que serão o suporte para a construção da cartografia de síntese da tese.

Abaixo segue a localização geográfica do município dentro dos limites do estado de São Paulo.

8.1. Breve histórico da formação Município de Itirapina

Por volta de 1820 surgiu um pequeno núcleo populacional às margens do ribeirão Claro que se chamou Itaqueri da Serra, onde foi construída uma capela de Nossa Senhora da Conceição da Serra, em 16 de maio de 1839. Em 5 de julho de 1852, a capela recebe o título de freguesia do município de Rio Claro, passando a se chamar freguesia de Nossa Senhora da Conceição de Itaqueri. Em torno da capela, o povoado cresceu e a sede da freguesia foi transferida, em 1873, para Itaqueri da Várzea, localizada à margem do ribeirão Itaqueri.

O impulso definitivo para o desenvolvimento do local ocorreu quando em 1885, a Companhia Paulista de Estradas de Ferro inaugurou a linha até São Carlos e um ramal para Jaú, construindo a estação de Morro Pelado nas terras da ainda freguesia, atraindo um contingente significativo de população. Em 8 de janeiro de 1890, a freguesia mudou o nome para Morro Pelado e, posteriormente, em 28 de setembro de 1900, para Itirapina. A autonomia político-administrativa ocorreu em 25 de março de 1935, com a criação do município.

No cenário político/econômico do início do século XX, a economia paulista se baseava na produção de cana de açúcar e de café. Na região de Rio Claro, desde o início do século XIX, fazendeiros paulatinamente aumentavam o tamanho de suas propriedades de terra, que eram utilizadas para o plantio da cana, em sua maioria com a prática da remoção da cobertura vegetal através da queimada.

Já na primeira metade do século XIX a cana de açúcar era substituída pelo café; nesta época, estruturavam-se os latifúndios paulistas concentrados nas mãos dos barões do café, espalhados pelo interior.

Até a década de 30 a cultura do café é predominante na região de Itirapina, e a partir da década de 40, com as dificuldades do café no mercado externo ocorre a substituição dessa cultura por outras mais vantajosas, mas a estrutura fundiária consagrada pelo café mantém-se a mesma.

A década de 50 é marcada pelos esforços de industrialização no Brasil; essa mudança de enfoque econômico gera uma queda no setor primário, isso ocorreu, em muito pelas dificuldades de concorrência de produtos nacionais no concorrido mercado externo, mas também pela própria política nacional vigente concentrando seus esforços no desenvolvimento do setor secundário.

Na década de 60, o advento do desenvolvimento industrial provoca a explosão do êxodo rural, e, em fins da década de 60 e em 70, ocorre novamente um

aumento da produção agrícola, só que desta vez voltado para a cana de açúcar, muito impulsionada pelos planos de substituição do petróleo.

Portanto, todos esses processos de ocupação, desse a introdução do café até a expansão da cana, marcam um forte processo de alteração da paisagem natural da área de Itirapina.

Nesse sentido, o município de Itirapina, no ano de 1983, através do Decreto Estadual nº 20.960, foi integrado na ampliação das áreas das APA's (Áreas de Proteção Ambiental) do estado de São Paulo, tendo parte de sua área incluída na APA Corumbataí, Botucatu e Tejuapá.

As APA's são uma categoria de Unidades de Conservação. Elas são entendidas como um ambiente de uso múltiplo onde se propõe conciliar as atividades humanas com proteção natural, não sendo necessária a desapropriação na área. Nesse sentido, é possível identificar uma vocação antropocêntrica inerente a tal concepção de unidade de conservação.

Parte da área do Município de Itirapina foi inserida no Perímetro Corumbataí (272.692 hectares). A figura 29 demonstra essa unidade, que conta com os municípios de Dois Córregos, Santa Maria da Serra, Corumbataí, Analândia, Torrinha, Brotas, São Carlos, Ipeúna, Rio Claro e Barra Bonita. A APA ainda conta com mais dois Perímetros: Botucatu (218.306 hectares) e o Tajupá (158.258).

Figura 26 – APA's na região do Município de Itirapina

Cabe destacar que uma das principais motivações para a criação dessas APA's foram as características peculiares dessas áreas. A APA está inserida em uma região de afloramento do aquífero Gurany. De acordo com o Atlas das Unidades de Conservação Ambiental do Estado de São Paulo (2000), 33% da área de afloramento deste reservatório estão contidas nos três perímetros desta APA. Como na região solos de areias quartzosas ocorrem com frequência, o abastecimento do lençol é garantido pela permeabilidade alcançada pelas águas das chuvas, em compensação, a vulnerabilidade e suscetibilidade aos processos erosivos se tornam fato presente.

A drenagem da região está associada à Bacia do Rio Piracicaba, cujas nascentes localizam-se no relevo das Cuestas Basálticas, ou seja, esses rios têm sua origem em terrenos acidentados, muitas vezes apresentando patamares abruptos, possibilitando a formação de quedas d'água.

As formações vegetais que permaneceram correspondem aos cerrados, cerradões e matas ciliares. Grande parte da área é ambiente útil à criação extensiva

de gado bovino, plantação de café, cana de açúcar, laranja e pinus de eucalipto. Importantes remanescentes de vegetação original localizam-se, principalmente, nas vertentes e escarpas das Cuestas Basálticas e em fundos de vales. O conjunto desses dados confere a esta APA importante valor de preservação.

8.2. Aspectos Geomorfológico-Geológicos

O município de Itirapina situa-se na região de contato de duas Províncias Geomorfológicas, a Depressão Periférica e as Cuestas Basálticas. Segundo Ab'Saber (1954), o relevo da região apresenta dois tipos de modalidades dominantes: Morros Alongados e Espigões, onde são predominantes os interflúvios, topos achatados e vertentes ravinadas, apresentando em seu conjunto uma drenagem de média densidade.

Para Christofoletti (1968), não há, entre a Depressão Periférica e as Cuestas Basálticas, uma exata correspondência entre limites geológicos e geomorfológicos. Onde o entalhamento é mais profundo, formaram-se relevos de morros como os relevos mistos do tipo morros de topos achatados.

Segundo Penteado (1968), a região de Itirapina situa-se no contato da Depressão Periférica paulista; pode ser caracterizada por apresentar um relevo deprimido entre as escarpas mais avançadas da zona de cuestas, que delimitam a borda oriental dos derrames basálticos, e o Planalto Cristalino Atlântico, que é uma das unidades morfológicas com características do estado de São Paulo.

Ainda o mesmo autor dá uma definição morfológica da região de Itirapina como sendo um compartimento interplanáltico bem definido morfológicamente no conjunto da Depressão Periférica. Apresenta desníveis de 200 a 300 metros em relação às escarpas basálticas, situadas a oeste e norte, local designado como Serra Itaqueri e Serra Santana.

Para o Instituto de Pesquisas Tecnológicas (1981), a área está localizada no contexto de litologias da Bacia Sedimentar do Paraná. As litologias presentes são de idades Paleozoicas e Cenozoicas, representadas pelo Grupo São Bento (Formação Serra Geral, Formação Pirambóia e Formação Botucatu) e Grupo Bauru (Formação Itaqueri). Além de coberturas Cenozoicas, areias e cascalhos.

Segundo Ferreira (2001), a Formação Pirambóia se manifesta morfológicamente através de morros testemunhos e paredões verticais de arenito nas vertentes das mais altas serras como a Serra Itaqueri, ainda se verifica que as bordas dos derrames basálticos apresentam-se como cuevas bastante elevadas e o reverso da cuesta basáltica mostra-se como um planalto de relevo plano esculpido nos arenitos da Formação Itaqueri.

Serão, a seguir, definidas as unidades geológicas da área resumidamente.

8.2.1. Grupo São Bento

O Grupo São Bento é constituído por três formações: Formação Pirambóia, Formação Botucatu e Formação Serra Geral.

Almeida e Barbosa (1953) admitem que as duas formações, Pirambóia e Botucatu, representam um ciclo úmido de sedimentação, refletindo condições climáticas que, de quentes e úmidas, evoluíram para desérticas. Porém, distinguiram um membro inferior, o Arenito Pirambóia, de caráter predominantemente aquoso, e outro eólico, correspondente ao Arenito Botucatu. Quando ainda perduravam condições desérticas, iniciou-se a atividade vulcânica basáltica da Formação Serra Geral.

Formação Pirambóia (Triássico/Jurássico) caracteriza-se por apresentar arenitos finos a médios, de coloração esbranquiçada a avermelhada, podendo apresentar porções siltico-argilosos. As estruturas predominantes são estratificações cruzadas de pequeno porte. Uma característica dessa unidade é a presença de

níveis de folhelhos e arenitos argilosa de cores variadas. A ambiência desta unidade é considerada de origem fluvial e de planície de inundação (IPT, 1981).

Formação Botucatu (Jurássico/Cretáceo) apresenta arenitos de granulação fina a média com grãos bem arredondados e superfície fosca, bem selecionados e de baixa porcentagem de finos, Nishiyama (1991) podem ser observados localmente arenitos conglomeráticos na base do pacote. As estruturas sedimentares mais comuns são estratificações cruzadas planares de grande porte e tangenciais à base. A ambiência dessa formação caracteriza-se por um ambiente desértico com seus vários subambientes.

Formação Serra Geral (Jurássico/Cretáceo) caracteriza-se por derrames basálticos de composição toleítica, de coloração cinza a preta, textura afanítica, podendo ocorrer intercalações de arenito intertrape. Estão incluídos aqui os derrames de lava, soleiras e diques de diabásico (IPT, 1981).

Segundo Oliveira e Prado (1984), o material proveniente do intemperismo dessas rochas deu origem a vários solos: Latossolos Roxo, Terra Roxa Estruturada, Latossolo Vermelho-Escuro e Litossolo substrato basalto ou diabásico.

8.2.2. Grupo Bauru

Formação Itaqueri (Cretáceo/Terciário Inferior) – esta formação é assunto de grande discussão, em função puramente de questões de denominação, contudo a sua ocorrência é confirmada na região da Serra de Itaqueri e é caracterizada por arenitos grosseiros conglomeráticos, com fácies pouco calcíferas e localmente com cimento silicoso, variando lateralmente para arenitos calco-conglomeráticos. Esses sedimentos podem ser considerados de idade Cenozoica suprabasálticas. Apresenta colorações rósea, vermelha e amarelada. Podem ser observados ainda seixos de quartzo centimétricos a decimétricos dispersos em uma matriz arenosa e siltosa. (Nishiyama, 1991)

As estruturas sedimentares não são muito distintas, podendo-se caracterizar estratificação plano-paralela ou cruzada nos arenitos, disposição caótica dos clásticos nos conglomerados mais grossos e estratificação de corrente nos mais finos. Tais características apontam ambiente fluvial, podendo-se acrescentar que a disposição foi realizada em ambiente muito energético, sujeito a bruscas mudanças de velocidade de transporte. (Almeida, 1953)

A Formação Itaqueri deu origem aos Latossolos Vermelho-Amarelos, desenvolvido a partir de muito material argiloso, e nas áreas dissecadas, onde o arenito está pouco profundo, desenvolveram-se os solos Podzólicos Vermelho-Amarelos (Oliveira, 1984). Veja a Tabela 6.

Tabela 6 – Litologia e Pedologia da Área do Município

	Litologia	Pedologia
Grupo Bauru	Itaqueri	Latossolos Vermelho-Amarelos Podzólicos Vermelho-Amarelos
Grupo São Bento	Serra Geral Botucatu Pirambóia	Latossolos Roxo Terra Roxa Estruturada Latossolo Vermelho-Escuro Litossolo

8.3. Aspectos Pedológicos

De acordo com o mapeamento pedológico realizado pelo Instituto Agrônomo, Divisão de Solos e Seção Pedológica da Secretaria de Agricultura do Estado de São Paulo, que abrange o Município de Itirapina, foram identificadas oito classes de solos no perímetro que compreende o município de Itirapina. (Tabela 7)

Tabela 7 – Classes de solos

Discriminação	Nomenclatura
Areia Quartzosa	AQ
Latossolo Roxo	LR
Latossolo Vermelho-Amarelo	LV
Latossolo Vermelho-Escuro	LE
Podzólico Vermelho-Amarelo	PV
Terra Roxa	TE
Solos Hidromórficos	Hi
Solos Litólicos	Or

A seguir serão apresentadas as características gerais dos solos da área estudada e suas descrições básicas.

8.3.1. Latossolos Roxos

São solos originários de matérias provenientes do intemperismo de rochas básicas, constituídos, na região, por basaltos e diabásicos, apresentando elevados teores de óxido de ferro. Geralmente esses solos atingem vários metros de profundidade, apresentando textura argilosa ou muito argilosa, com menos de 10% de areia grossa.

8.3.2. Latossolos Vermelho-escuros

Em geral esses solos de cores vermelho-escuros e bruno-avermelhado-escuros, o município apresenta uma predominância dos LE-2 com texturas médias, resultante do intemperismo e retrabalhamento de arenitos com contribuição de rochas básicas.

8.3.3. Latossolos Vermelho-amarelos

A área apresenta uma única unidade do latossolo vermelho-amarelo (LV-2) que apresenta textura média, com predominância de áreas grossas sobre a fina; são solos muito profundos. Eles são solos resultantes do intemperismo de arenitos e estão associados às áreas quartzosas.

8.3.4. Podzólicos Vermelho-amarelos

A região apresenta o predomínio do Podzólico vermelho-amarelo (PV-2) que se caracteriza em textura arenosa em superfície e média em subsuperfície, onde a cor mais comum na camada superficial é a bruno-escura. São solos que se desenvolvem sobre arenitos da Formação Botucatu/Pirambóia.

8.3.5. Terra Roxa Estruturada

Esta classe de solos compreende os derivados de rochas basálticas, apresentando texturas argilosas ou muito argilosas, ocorrendo principalmente associados aos solos litólicos substrato basalto, em relevos fortemente ondulados e escarpados esculpidos em rochas da Formação Serra Geral.

8.3.6. Solos Litólicos

Os solos litólicos apresentam como característica principal sua pequena espessura e a ausência de horizonte diagnóstico de subsuperfície ou, quanto à existência, ele é muito pouco espesso. São solos provenientes do basalto ou diabásio e também das Formações Botucatu e Pirambóia.

8.3.7. Solos Hidromórficos

Os solos hidromórficos da área apresentam as seguintes classes de solos: solo orgânico, *gley* húmico e *gley* pouco húmico.

Os solos orgânicos apresentam uma camada superficial de material orgânico (horizonte turfoso) igual ou superior a 40 cm de espessura, enquanto os gleis húmicos e os poucos húmicos apresentam uma camada de material inferior a 40 cm.

Sua textura vai desde arenosa, abaixo da camada orgânica, até argilosa, sendo esta a mais comum.

Os solos hidromórficos situam-se nas áreas das planícies aluvionais, podendo ser observados nas margens do ribeirão Lobo, por exemplo.

8.3.8. Áreas Quartzosas Profundas

As áreas quartzosas profundas são solos profundos com espessura superior a 200 cm, não hidromórficos, desenvolvidos sobre material de origem arenosa. A fração areia representada pelo quartzo é igual ou superior a 70%, e a fração argila é inferior a 15%. As áreas quartzosas profundas possuem uma variação considerável em cor no horizonte superficial, desde vermelho-acinzentado até bruno-avermelhado-claro, porém a mais comum é a bruno-escura. Na camada subsuperficial a cor varia desde vermelho-fraca até bruno-amarelada, sendo a predominância para a bruno-avermelhada.

8.4. Aspectos Climáticos

Em linhas gerais, o clima da região do Município de Itirapina é o subtropical, que na classificação climática de Köppen é representado pelo tipo Cwa, com duas estações bem definidas, com inverno seco e verão chuvoso.

Os meses mais secos vão de março a setembro apresentando, de modo geral, o equivalente a 20% das precipitações anuais, correspondendo às médias de 250 mm. Para o mês de setembro temos as mais altas médias, ficando em 45 mm de precipitação, os meses com menores índices de precipitação são os de julho e agosto com 25 mm em média (Duarte, 1980).

Os períodos mais chuvosos concentram-se nos meses de outubro e fevereiro, sofrendo influência da massa tropical, com 80% das precipitações anuais, podendo chegar até índices de 1.200 mm (Duarte, 1980).

Para valores térmicos, a região apresenta em média 18 °C a 21 °C, mas nas regiões com altitudes acima de 1.000 m, como a Serra de Itaqueri, são registradas temperaturas médias inferiores a 19 °C constituindo um clima tropical de altitude nessas áreas, segundo dados do DAEE (Departamento de Águas e Energia) nas estações de Analândia e Corumbataí, municípios vizinhos à Itirapina (Duarte, 1980).

8.5. Vegetação

A vegetação primitiva pode ser caracterizada, principalmente, por campos cerrados e cerradões. Essa vegetação é constituída por uma cobertura herbácea mais ou menos contínua e um dossel descontínuo de elementos e arbustivos, de galhos retorcidos, cascas espessas e folhas coriáceas (Adaloni, 1996).

A cobertura vegetal primitiva das matas, que recobriu os solos de Nitossolo formados a partir das rochas basálticas e os solos podzolizados de siltitos de topo de colinas, foi quase totalmente modificada e também quase nada mais resta de revestimento natural dos cerrados e campos das partes mais elevadas do relevo tabular em latossolos formados de arenitos (Adanoli, 1986).

Ainda o mesmo autor descreve que a vegetação primária, em muitas partes da área foi substituída por áreas de pasto e posteriormente pela cultura canavieira e de *citrus* e que ainda existem áreas com reflorestamento de Pinos vinculados à indústria de papel e celulose; cabe destacar que ainda existem áreas com vegetação primária, resultado das condições típicas do meio físico (altas declividades) e são caracterizadas como áreas de conservação.

Tabela 8 – Quantificação de cobertura vegetal

Classes	Área	Porcentagem
Capoeira	42,58	7,43
Mata	91,06	15,89
Reflorestamento	85,34	14,89
Total de Área do Município	573,03	38,21

A figura 27 apresenta as áreas de mata e capoeira do município, esse mapa esboço foi produzido a partir do banco de dados geográficos elaborado nesta pesquisa.

Figura 27 – Esboço dos principais núcleos de cobertura vegetal

Fonte: Elaborado a partir do processamento digital de Imagem de Satélite LandSat 5 TM bandas 3,4,5 órbita 220/73 de 2008

9. Matérias, Métodos e Construção do banco de dados geográficos

Neste capítulo serão apresentados os procedimentos para a criação do banco de dados geográficos (BDG) que irá servir de base para o processamento da inferências geográficas proposto neste estudo.

9.1. Elaboração do Banco de Dados Geográficos e Modelagem

O primeiro passo para a utilização de um SIG é a criação e modelagem dos dados geográficos. Essa modelagem é essencialmente a criação de categorias, que especifica os tipos de dados que serão utilizados.

No SPRING temos os seguintes tipos: Imagem, Numérico, Temático, Cadastral, Rede e Tabela não espacial. Assim essas categorias determinam os tipos de dados e as possíveis manipulações. Na Tabela 6 são apresentadas as características de cada um dos modelos.

Tabela 9 – Estrutura de Modelagem de Dados no Sistema SPRING

Modelo	Característica
IMAGEM	Categoria do modelo Imagem refere-se a dados provenientes de sensoriamento remoto em formato matricial. Exemplos: imagens TM/LANDSAT, SPOT, NOAA, fotografias aéreas transformadas em imagens digitais através de “scanners” etc.
NUMÉRICO	Categoria do modelo Numérico refere-se a dados que possuem uma variação contínua de seus valores numéricos em função de sua posição na superfície. Exemplos: altimetria, pH do solo, magnetometria, temperatura de superfície etc.
TEMÁTICO	Categoria do modelo Temático refere-se a dados que classificam uma posição geográfica quanto a um determinado tema. Ex: tipos de solo, classificação de vegetação etc.
CLASSES	Para as categorias de dados do modelo temático é necessário definir as Classes Temáticas, as quais são especializações da categoria. Tomando-se como exemplo uma categoria tipos de solo, cada um dos diferentes tipos de solos constituirá as classes. Por exemplo, latossolo roxo, argissolo e litossolo.

OBJETO	Categoria de dados do modelo Objeto refere-se à especialização de um tipo de objeto geográfico. Exemplo: municípios, logradouros, propriedades etc.
CADASTRAL	Categoria do modelo Cadastral refere-se aos mapas que contêm a representação de determinado tipo de objeto, por exemplo: Divisão política é a categoria cadastral que conterá o mapa com as representações dos municípios.
REDE	Categoria do modelo Rede refere-se aos dados geográficos que possuem relações de fluxo e conexão entre os inúmeros elementos que se deseja representar e monitorar. Ex: rede de energia elétrica, esgoto, água, drenagem, telefonia etc.
NÃO-ESPACIAL	Categoria do modelo Não-Espacial refere-se aos dados que não possuem representação espacial como, por exemplo, os dados de cadastros rurais e urbanos.

Fonte: Adaptado de Spring (1996)

O primeiro passo para a construção de um BDG é o estabelecimento de informação para a georreferenciamento dos dados. Neste banco foi utilizada projeção UTM / Córrego Alegre delimitada pelas coordenadas geográficas:

190421.467000 m, 230772.720000 m(canto inferior)
190421.467000 m, 230772.720000 m (canto superior)
Zona UTM – 23
Meridiano Central: Oeste 45 ⁰
Datum – Córrego Alegre

Dentro do SPRING foi criado o Projeto da Pesquisa com base nas características geográficas mencionadas acima, também foram definidas diversas Categorias de diferentes Modelos de Dados. Nessas categorias estão contidos os diversos Planos de Informação (PI), também conhecidos como *layers*, *coverages* ou níveis temáticos em outros *softwares* de geoprocessamento. Cada PI pertence a uma única categoria, as Categorias e os Modelos criados estão descritos na Tabela 10:

Tabela 10 – Descrição dos Modelos de Dados e Categorias do Banco de Dados

Categoria	Modelo
Altimetria	Numérico
Geologia	Temático
Pedologia	Temático
Hidrografia	Cadastral
Limite	Temático
Imagem	Imagem

Na aplicação das metodologias que serão estudadas, serão utilizados como base para os estudos os seguintes mapas temáticos:

Solos, Geologia, Declividades e Uso da Terra e Cobertura Vegetal
--

9.2. Procedimentos – Planos de Informação

A seguir serão apresentadas as metodologias de obtenção e inserção de cada um dos mapas temáticos selecionados no banco de dados geográficos.

9.3. Plano de Informação Declividades

Para a elaboração do mapa de declividades foram utilizados os mapas analógicos topográficos, da base do IBGE, de forma a cobrir a área total do Município de Itirapina. Para isso foi necessário articular quatro folhas na escala 1:50.000.

Esses mapas foram submetidos a um processo de digitalização das isolinhas de 20 metros no *software* R_{2v}. Depois esses vetores foram exportados com topologia X,Y,Z, que são as coordenadas geográficas e cotas.

No SPRING foi criado um único Plano de Informação a partir de um mosaico desses quatro arquivos, cada um desses arquivos é referente a cada carta topográfica digitalizada, tendo como resultado uma superfície contínua que deu origem ao PI. Cotas Topográficas (figura 28).

Esse mapa passa a representar um modelo topográfico digital que abrange a área total do município, essa é uma condição indispensável para a execução dos procedimentos seguintes.

Foi elaborada sobre essa base topográfica georreferenciada uma modelagem da superfície, ou como também é conhecido nos SIG's, foi criado o Modelo Digital do Terreno (MDT). O MDT busca representar as superfícies através de uma estrutura matemática – matriz (Teixeira, 1992).

O processo de geração de um modelo de grade ou MDT compreende a construção de uma malha regular ou irregular, e também da definição de funções interpolantes locais; essas funções são definidas para cada elemento da malha (Câmara, 1998).

Em grades triangulares (própria do modelo de dados gráfico vetorial), para cada elemento básico (triângulos) se define uma função interpolante, que é válida nos pontos internos ao elemento da função de ajuste, geralmente um polinômio, é definida utilizando-se os vértices dos elementos, em muitos casos os vértices (no caso triângulos) dos elementos vizinhos também (Câmara, 1998).

Ainda o mesmo autor esclarece que, considerando as arestas dos triângulos, essa modelagem permite que as informações morfológicas importantes como as descontinuidades representadas por feições lineares de relevo (crista) e drenagem (vales) sejam consideradas durante a geração da grade triangular, possibilitando assim modelar a superfície do terreno preservando as feições geomórficas da superfície.

Figura 28 – Mapa Topográfico do Município de Itirapina

Figura 29 – Representação de Grade Irregular Triangular (TIN)

Fonte: Adaptado de Câmara (1998)

Dessa forma procedeu-se para a elaboração da MNT do Município de Itirapina pela geração da grade triangular, ou Triangulated Irregular Network (TIN), como também é conhecido este processo, o MDT é apresentado na figura 30.

Figura 30 – Grade Irregular Triangular do Município de Itirapina

A partir da elaboração do modelo digital do terreno é possível gerar um produto significativo para a modelagem ambiental, o Mapa de Declividades. Burrough (1996), esclarece que a elaboração de Mapa de Declividade a partir de um Modelo Numérico, é uma das aplicações do MDT em geoprocessamento.

Ainda sobre o Mapa de Declividades, no SPRING as Declividades são representadas a partir da definição no Modelo Numérico podendo ser expressas em intervalos de fatias a partir das cotas. Essas fatias podem representar intervalos em percentagens ou graus. Assim é possível obter uma imagem temática, onde cada fatia da imagem está associada a um intervalo de cotas, produzindo dessa forma uma classificação (daí a expressão fatiamento) da superfície analisada.

O mapa de declividade do município de Itirapina obtido (Figura 31) está expresso em graus e foi adotada a proposta de De Biase (1992) para a seleção do fatiamento. A seguir, também é apresentado um gráfico que estabelece a distribuição da área em km² por classe

Gráfico 1 – Distribuição das Classes do Plano de Informação Declividades

Figura 31 – Mapa de Declividades

. Pode-se observar no Gráfico 1 que 72% da área do município estão compreendidos no intervalo de 0° a 12° , inferindo-se que a maior parte de território está em baixas declividades, principalmente na depressão periférica, associadas às areias quartzosas. Ainda pode-se destacar que 6% da área estão incluídos no intervalo acima de 30° , em geral referentes às cuestas

9.3.1. Plano de Informação Solos

O Mapa de Solos foi digitalizado no R_{2v} e enviado para o SPRING para ser processada a edição vetorial e incluído no banco de dados geográficos. Esse PI contém os tipos de solos do município de Itirapina (figura 34).

Esse banco geográfico abrange oito diferentes classes de solos que foram extraídas do mapa analógico confeccionado pelo Convênio Embrapa Secretaria da Agricultura e Abastecimento do Estado de SP e Coordenadoria de Pesquisa Agropecuária, Instituto Agrônomo – Divisão de Solos – Seção de Pedologia.

Gráfico 2 – Distribuição das Classes do Plano de Informação Pedologia

No Gráfico é observado o predomínio dos latossolos vermelho-amarelos (250 km² na depressão periférica e planalto), e neossolo quarteazarênico (150 km², principalmente na depressão periférica), a incidência desses dois diferentes tipos de solos na depressão está ligada ao substrato rochoso.

Figura 32 – Mapa de Solos

9.3.2. Plano de Informação Geologia

Neste Plano de Informação, após digitalização no R_{2v} e a importação no sistema SPRING, procedeu-se a construção do Banco de Dados Geográficos com base nas informações litológicas da área (figura 33), que é composto de quatro classes e a nomenclatura adotada é a do Instituto Geológico (Tabela 11).

Tabela 11 – Classes Geológicas

Nomenclatura	Descrição
Jbp	arenitos, siltitos e folhelhos - Formação Botucatu
Ksg	basaltos e diabásicos - Formação Serra Geral
Kb	arenitos, siltitos e folhelhos
H	areias, argilas e cascalhos

Figura 33 – Mapa de Geologia

No gráfico 3 é observado que entre as classes litológicas do município de Itirapina há predomínio da Formação de Botucatu (Jbp) com aproximadamente 300 km², compreendendo as áreas da depressão periférica, e as outras classes (Ksg, Kb e H) estão compreendidas entre 50 a 100 km², onde estão os arenitos (Planalto) e os basaltos (Cuesta).

Gráfico 3 – Distribuição das Classes do Plano de Informação Geologia

9.3.3. Plano de Informação Uso da Terra e Cobertura Vegetal

O mapa de uso da terra e cobertura vegetal foi confeccionado a partir das técnicas de sensoriamento remoto. A imagem de satélite utilizada foi do Landsat 5, bandas 3, 4 e 5, do dia 23/20/ 2008 em órbita 220 ponto 073.

Essas imagens foram importadas para o SPRING, onde foram processadas a correção geométrica e a elaboração de uma imagem sintética, cores "naturais", com as bandas 3 (filtro azul), 4 (filtro verde) e 5 (filtro vermelho), para compor a chamada imagem em RGB.

Posteriormente, efetuou-se a segmentação da imagem, foram gerados polígonos em função da similaridade dos valores e área; para a identificação desses polígonos foi utilizado o método de Classificação Supervisionada, onde a escolha das amostras e das classes foi feita em função do conhecimento da área de estudo.

Após a classificação supervisionada foi feita a edição poligonal (interpretação e exclusão dos polígonos irrelevantes gerados na classificação supervisionada, apoiando-se na imagem sintética), e assim a geração do mapa de uso da terra e cobertura vegetal (Figura 34).

A Tabela 12 apresenta as classes que foram estabelecidas e qual o tipo de alvo que está compreendido. Ainda foi possível, através da classificação, obter uma estatística em relação aos tipos de classes e suas respectivas áreas, essa relação é expressa no Gráfico 4.

Tabela 12 – Categorias classificadas no PI Uso da Terra e Cobertura Vegetal

Tipo	Descrição
Capoeira	Formações arbustivas espaçadas
Cultivos de Ciclo Curto	Cana e Milho
Cultivos de Ciclo Longo	Café e Laranja
Mata	Naturais e galeria
Pasto	Com baixo pisoteio
Reflorestamento	Eucaliptos / Pinos
Solo Exposto	Solo aparentemente sem cobertura
Urbano	Cidade e pequenos núcleos populacionais

Figura 34 – Mapa de Uso da Terra e Cobertura Vegetal

Gráfico 4 – Distribuição da Classificação do PI Uso da terra e Cobertura Vegetal

A classe Pasto aparece com a maior extensão territorial, aproximadamente 145 km² (27%), e provavelmente está relacionada à retirada e substituição da cobertura vegetal primária. Em seguida, com menor quantidade a cultura do tipo Ciclo Curto (cana de açúcar, milho) em torno de 115 km² (21%). A classe Mata tem aproximadamente 91 km² (17%), essas áreas ocupam principalmente as cuestas basálticas – em altas declividades – e ao longo dos cursos dos rios. Destacamos a categoria reflorestamento com 85 km² (16%), essa está associada à presença da indústria do papel e celulose, responsável pela expressiva área de mata reflorestada.

Segundo Penteado (1968), a cobertura vegetal primitiva das matas foi quase totalmente retirada, bem como o revestimento natural dos cerrados das regiões mais elevadas do Município de Itirapina.

9.4.3. Padronização dos Mapas Temáticos

Para a aplicação das técnicas de inferências geográficas e RNA é necessária a transformação de todos os Planos de Informação Vetoriais em Planos de Informação Matriciais, assim é possível associar às células dessas matrizes valores. Isso possibilita a manipulação desses modelos numéricos (matrizes). Em geral esse

processamento viabiliza a aplicação de operações aritméticas, e no caso deste estudo, o uso da RNA.

A padronização do banco de dados dessa pesquisa é apresentada na Tabela 13, onde ocorreu a migração em função do tipo de cada mapa e para o modelo matricial.

Tabela 13 – Padronização dos Mapas para o Modelo Numérico

Nome	Tipo	Padronização
Geologia	Vetor	Numérico
Pedologia	Vetor	Numérico
Uso da Terra/Cobertura Vegetal	Vetor	Numérico
Declividades	Numérico	Numérico

Após a padronização dos Planos de Informação é preciso fazer a associação de valores referentes a cada classe de tema. A figura 35 demonstra como ocorre esse processo de padronização. No exemplo, a definição numérica para classe é aplicada a um mapa de solos, onde os valores propostos para as classes são:

Le = 0.60, Li = 0.20, Ls = 0.35, Aq = 0.10.

Figura 35 – Exemplo de Padronização de Mapa Temático (Vetor) para um Mapa Numérico (Matriz)

Como comentado anteriormente, uma das questões centrais na criação de modelos matemáticos em geografia é a avaliação a ser realizada quanto à definição

das classes temáticas (qualitativos) em valores (quantitativos); é preciso estabelecer um valor adequado para cada dado qualitativo em função do objetivo que pretende ser alcançado; essa avaliação é importante, pois implica diretamente os resultados finais e as possíveis tomadas de decisões.

Assim, a participação direta do pesquisador na padronização do modelo é fundamental para a obtenção de um “produto cartográfico adequado” que irá expressar o fenômeno estudado.

Nesta pesquisa adotou-se uma metodologia empírica de avaliação, consultando especialistas para a determinação de um *ranking* (valor numérico ordenado) a ser atribuído às variáveis que compõem os Mapas Temáticos – esta atribuição numérica foi norteadada para o estabelecimento do panorama ambiental do município de Itirapina, apontando áreas em estabilidade e instabilidade à erosão. Foi tomada como base a proposta de Martines (2006) para o conjunto de variáveis dos temas que compreendem a área do município.

Para a construção dessa proposta de modelagem numérica para as variáveis dos temas, o autor distribuiu um questionário para professores de universidades federais e estaduais e também profissionais da área de pesquisa de empresas privadas que trabalham com a questão da erosibilidade do solo.

Nesse questionário, cada profissional opinou sobre qual o valor mais adequado a ser atribuído para cada uma das variáveis temáticas apresentadas em função de um *ranking* proposto. Para isso, eles deveriam levar em consideração seu julgamento pessoal em função dos seus conhecimentos acumulados e experiência de trabalhos e pesquisas realizadas sobre processos erosivos.

Para que o preenchimento do questionário pelo participante seja de uma forma “amigável”, foi desenvolvido um aplicativo autoexecutável em uma plataforma de *Visual Basic* de simples manipulação, onde o participante ia realizando seus julgamentos por tema e variáveis. Nesse processo de avaliação individual, cada

participante atribuiu valor dentro do seguinte critério: os pesos devem ser dados dentro do intervalo de [1, 5], sendo que um (1) significa que a variável analisada apresenta “maior resistência e/ou estabilidade ao processo erosivo” e cinco (5) “maior fragilidade e/ou instabilidade”.

Foram respondidos trinta questionários. De posse de todos os questionários preenchidos foi gerada, inicialmente, uma compilação dos resultados e efetuada uma média aritmética para cada uma das variáveis avaliadas, descartando os maiores e menores valores atribuídos às variáveis. E posteriormente foi feita uma média aritmética dos valores resultantes.

As tabelas que seguem abaixo demonstram os resultados consolidados para as variáveis por cada um dos temas propostos: Geologia na Tabela 14, Uso da Terra e Cobertura Vegetal na Tabela 15, Declividades na Tabela 16 e Solos na Tabela 17.

Tabela 14 – Valores consolidados para o tema geologia

Geologia		
Sigla	Descrição	Média
H	Areias, Argilas e Cascalhos	5,00
kb	Fm. Itaqueri (arenitos e arenitos conglomeráticos)	3,63
Ksg	Fm. Serra Geral intrusivas basálticas	1,28
Jbp	Fm. Botucatu (arenitos, siltitos e folhelhos)	3,75

Tabela 15 – Valores consolidados para tema uso da terra e cobertura vegetal

Uso da terra/Cobertura Vegetação		
Tipo	Descrição	Média
Mata	Naturais e galeria	1,00
Reflorestamento	Eucaliptos / Pinos	2,21
Capoeira	Formações arbustivas espaçadas	2,29
Pasto	Com baixo pisoteio	3,29
Solo Exposto	Sem cobertura	5,00
Cultivos de Ciclo Longo	Café, Laranja	3,29
Cultivos de Ciclo Curto	Cana e Milho	4,43

Tabela 16 – Valores consolidados para o tema declividade

Declividade	
Porcentagem	Média
0 - 6	1,11
06 - 12	2,11
12 - 20	3,22
20 - 30	4,22
> 30	5,00

Tabela 17 – Valores consolidados para o tema solos

Solos			
Sigla	Classe	Descrição	Média
LRe	Latossolo Roxo	Eutrófico, A moderado.	1,67
LRd		Distrófico, A moderado.	2,08
LE-1	Latossolo Vermelho-escuro	Álico, A moderado, textura argilosa.	1,75
LE-2		Álico, A moderado, textura média.	2,33
LV-1	Latossolo Vermelho-amarelo	Álico, A moderado, textura média.	3,00
LV-2		Álico, A proeminente, textura muito argilosa ou argilosa.	2,33
PV-1	Argissolo Podzólico (Vermelho-amarelo)	Abruptico, Álico, A moderado, textura arenosa / média.	3,83
PV-2		Distrófico, A moderado, Textura média ou média / argilosa.	3,17
TE-1	Nitossolo (Terra Roxa Estruturada)	Eutrófico ou distrófico, A moderado.	1,33
TE-2		Eutrófica ou distrófica Intermediário para Latossolo Roxo, A moderado.	1,33
AQ	Neossolo Quartzarênico (Areias Quartzosas Profundas)	Álica, A moderado.	5,00
Li	Neossolo (Solos Litólicos)	Eutróficos e distróficos, A moderado, textura indiscriminada.	4,17
Or	Vertissolo (Solo Hidromórfico)	Solos orgânicos, com ou sem gley úmido.	2,58

10. Experimento: Área de teste para a aplicação das metodologias

Esta etapa da pesquisa é destinada à validação e consolidação das metodologias a serem estudadas. A estratégia será a criação de uma pequena área amostral para testar, aplicar e desenvolver as metodologias propostas. A área que está em destaque na Figura 36 é o trecho destinado a esta etapa de desenvolvimento e prospecções.

Figura 36 – Área de treinamento de teste

Nos itens abaixo serão apresentadas as metodologias e seus processos técnicos de aplicação que foram utilizados e desenvolvidos nesta pesquisa.

10.1. Operações Pontuais de Soma – OPS (Modelo de Soma Álgebraica)

Em linhas gerais, as operações locais resultam em campos função de valores associado ao mesmo local por uma ou mais representações de campos.

Essa técnica geralmente é utilizada para produção de mapas sínteses através da combinação de matrizes. Por exemplo realizar cálculo de índices de vegetação com base em modelo de imagem gerando grades numéricas como resultado, através de operações aritméticas aplicado a cada “pixel” da imagem. Ou, atribuir vulnerabilidade a unidades territoriais, como base em princípios da ecodinâmica, através de uma operação aritmética simples envolvendo uma ponderação de mapas temáticos. (Câmara, 1997)

A utilização desse procedimento técnico dentro do SPRING constituiu-se em selecionar os mapas (critérios) de interesse, e então somá-los através da linguagem LEGAL.

Neste estudo foi realizado esse procedimento técnico de soma aritmética associado a uma normalização para efeito de comparação com, as outras metodologias. Assim a normalização foi realizada partindo de que têm-se quatro temas, portanto, tem-se como fator de normalização o valor 0.25, assim a soma da normalização total é 1.

Partindo da metodologia acima apresentada, foi escrito na linguagem do LEGAL um programa para executar a tarefa de aplicar o OPS sobre os temas do banco de dados geográficos. Abaixo segue a programação em LEGAL.

<pre>{ // Definicao dos dados de entrada Tematico var1 ("Decliv"); Tematico var2 ("Uso_terra2"); Tematico var3 ("geologico"); Tematico var4 ("pedologico"); Tabela tab1 (Ponderacao); tab1 = Novo (Categorialni = "Decliv" , "0 - 5":1.11, "5 - 12":2.11, "12 - 30":3.22, "30 - 47":4.22, "> 47":5.0); Tabela tab2 (Ponderacao); tab2 = Novo (Categorialni = "Uso_terra2" , "campo_antropico":3.29, "ciclo_longo":3.29, "ciclo_curto":4.43, "reflorestamento":2.21, "mata":1.0, "urbano":1.0, "solo_nu":5.0, "capoeira":2.29, "agua":1.0); Tabela tab3 (Ponderacao); tab3 = Novo (Categorialni = "geologico" , "H":5.0, "Kb":3.63, "Ksg":1.28, "Jbp":3.75); Tabela tab4 (Ponderacao);</pre>	<pre>tab4 = Novo (Categorialni = "solos" "LRe":1.67, "LRd":2.08, "LE2":2.33, "LE1":1.75, "LV2":2.33, "LV1":3.0, "PV2":3.17, "PV1":3.83, "TE2":1.33, "TE1":1.33, "AQ":5.00, "Li":4.17, "Or":2.58); // Definicao do dado de saida Numerico var5 ("OPS_1a5"); // Recuperacao dos dados de entrada var1 = Recupere (Nome="Decliv_tin_biase_"); var2 = Recupere (Nome="class-T_"); var3 = Recupere (Nome="Geo"); var4 = Recupere (Nome="solo"); // Criacao do dado de saida var5 = Novo (Nome="OPS", ResX=30, ResY=30, Escala=100000, Min=1, Max=5); // Geracao do OPS var5 = 0.25*(Pondere(var1, tab1)) + 0.25*(Pondere(var2, tab2))+ 0.25*(Pondere(var3, tab3))+ 0.25*(Pondere(var4, tab4)); }</pre>
--	---

Resumindo a aplicação da metodologia, tem-se: o OPS é aplicado às matrizes numéricas de cada um dos temas construídos, com os respectivos valores das variáveis somadas e multiplicadas pelos fatores de normalização, como demonstra a figura 37.

Figura 37 – Fórmula para a aplicação dos Pesos do OPS para os Temas

The diagram consists of a large rectangular box with a solid border. Inside this box, at the top, is a smaller rectangle with a dashed border. Inside the dashed rectangle is the formula: $MR = 0,25 (MUT/CV) + 0,25 (MP) + 0,25 (MD) + 0,25 (MG)$. Below the dashed rectangle, within the same large box, are four lines of text defining the variables: **MR = Matriz Resultante**, **MT/CV = Matriz Uso da Terra e Cobertura Vegetal**, **MD = Matriz Declividade**, and **MG = Matriz Geologia**.

$$MR = 0,25 (MUT/CV) + 0,25 (MP) + 0,25 (MD) + 0,25 (MG)$$

MR = Matriz Resultante
MT/CV = Matriz Uso da Terra e Cobertura Vegetal
MD = Matriz Declividade
MG = Matriz Geologia

Como resultado dessa técnica, tem-se um mapa síntese constituído em um modelo numérico (MDT) que expressa um grau de importância relativa em função do *ranking* (valores numéricos) assumido para cada classe.

Assim, com os critérios estabelecidos (Geologia, Pedologia, Declividade e Uso da Terra e Cobertura Vegetal) e aplicando o OPS, tem-se como resultado um modelo numérico sintético (Figura 38) apresentado em forma de mapa e expresso em diferentes níveis de cinza.

Para interpretar este produto cartográfico é necessário ter como parâmetro a estrutura de atribuição do *rank* para cada uma das variáveis dos temas. Onde os menores valores, próximos ao valor um (1), deveriam representar as variáveis mais estáveis e os valores próximos ao cinco (5) as mais instáveis.

Assim, ao “olhar” no produto cartográfico gerado pela aplicação do OPS, os pixels com as cores próximas à cor branco são os representantes das áreas mais instáveis, ao passo que os próximos ao preto os das mais estáveis.

Figura 38 – Área teste – Modelo numérico do *Operações Pontuais de Soma*

10.2. Analytical Hierarchical Process – AHP

O *Analytical Hierarchical Process* – AHP é uma teoria com base matemática que permite organizar e avaliar a importância relativa entre critérios e medir a consistência dos julgamentos.

Requer a estruturação de um modelo hierárquico, que geralmente é composto por meta, critérios e uma avaliação de comparação pareada por importância relativa, preferências ou probabilidade entre dois critérios com relação ao critério no nível superior.

Esse método foi proposto por Thomas Saaty (1990), definido como uma técnica de escolha baseada na lógica da comparação pareada. Nesse procedimento, os diferentes fatores que influenciam a tomada de decisão são comparados dois (2) a dois (2) e um critério de importância relativa é atribuído ao relacionamento entre estes fatores, conforme uma escala predefinida.

Portanto, os objetos são comparados em pares, levando um, depois o outro, e então, levando de novo o primeiro e segundo, e assim por diante, até que se forme um julgamento quanto ao peso relativo de cada par de objetos.

Com relação ao processo de consistência dos relacionamentos entre o julgamento dos pares, Saaty afirma que quanto mais uma pessoa conhece a situação, mais consistente espera-se que ela possa representá-la. Comparações pareadas permitem melhorar a consistência dos julgamentos para aumentar o número de informações disponíveis.

Pode-se exemplificar o processo de elaboração de comparação pareada desenvolvendo-se uma escala de prioridades em relação ao brilho ou à luminosidade para cadeiras em uma sala. O julgamento será obtido por um indivíduo

que fica fora da sala e tenta elaborar um questionamento como: Qual está mais iluminada: a cadeira B ou a cadeira A? Ele dará como resposta um dos números escolhidos para as comparações descritas na tabela abaixo, e esse julgamento entrará na matriz na posição (B,A).

Tabela de valores para julgamento
se A e B forem iguais em importância, colocar 1
se A for um pouco mais importante do que B, colocar 3
se A for muito mais importante que B, colocar 5
se A for claramente ou muito fortemente mais importante do que B, colocar 7
se A for absolutamente mais importante do que B, colocar 9
se um elemento for igualmente importante quando comparado a ele mesmo, isto é, quando na matriz de posição (B,B), coloca-se 1.

Fonte: Adaptado de Saaty (1990)

Uma Matriz elaborada com esses princípios para elucidar nosso exemplo seria:

Iluminação	A	B	C	D
A	1	5	6	7
B	1 / 5	1	4	6
C	1 / 6	1 / 4	1	4
D	1 / 7	1 / 6	1 / 4	1

Fonte: Adaptado de Saaty (1990)

Para o julgamento da consistência dos valores atribuídos a cada variável, Saaty (1990) destaca que geralmente o que se quer dizer com consistência é que, quando se tem uma quantidade básica de dados, todos os outros dados podem ser logicamente deduzidos deles.

Ao fazer a comparação pareada para relacionar em “n” atividades de modo que cada uma seja representada nos dados pelo menos uma vez, precisa-se de “n-1” comparações pareadas. Assim, todos os outros julgamentos podem ser deduzidos usando-se esse tipo de relação.

Para a consistência, tem-se que se a atividade “A₁” é 3 vezes mais dominante do que a atividade “A₂”, e a atividade “A₁” é 6 vezes mais dominante que a atividade “A₃”, então “A₁ = 3(A₂)” e “A₁ = 6(A₃)”. Se os valores numéricos do julgamento na posição (2,3) forem diferentes de 2, então, a matriz será inconsistente. O processo matemático para o cálculo da consistência da matriz pareada será discutida mais à frente.

Após a verificação da consistência dos julgamentos, o próximo passo é a computação de um vetor de prioridade da matriz. Aplicando esse procedimento no citado exemplo da iluminação das cadeiras, o vetor de prioridade é 0.51, 0.30, 0.15, 0.04, para o brilho relativo das cadeiras A, B, C e D.

Para a aplicação do AHP nesta pesquisa o primeiro passo foi estabelecer a hierarquização dos temas. Para isso, tomou-se como base a computação da média aritmética da resposta à questão de hierarquização respondida nos questionários que foram distribuídos aos especialistas (Martines, 2006), em que uma das questões solicitava que os especialistas hierarquizassem os temas, iniciando pelo mais importante até o menos importante para o estabelecimento de processos erosivos.

Dessa forma foi definida a seguinte ordem de importância: Mapa de Uso da Terra e Cobertura Vegetal (mais determinante); Mapa de Solo e Declividades (equivalentes na importância) e o Mapa Geológico (menos determinante). A Figura 39 apresenta os temas dispostos pela intensidade de importância na forma de um fluxograma.

Figura 39 – Hierarquização da intensidade de importância dos temas da pesquisa

Com base na hierarquização, procedeu-se à definição da importância relativa entre as evidências (temas) – essa relação é utilizada como dado de entrada em uma matriz de comparação pareada e parte da ideia de comparação qualitativa, gerando um valor quantitativo para os julgamentos aplicados.

Na Tabela 18, são apresentadas as variáveis qualitativas e os correspondentes valores numéricos para os julgamentos a serem realizados entre os pares.

Tabela 18 – Escala de Valores de AHP para Comparação Pareada

Intensidade de Importância	Definição Importância	Explicação
1	igual	Os dois fatores contribuem igualmente para o objetivo com importância moderada – um fator é ligeiramente mais importante que o outro.
3	moderada	Um fator é ligeiramente mais importante que o outro.
5	essencial	Um fator é claramente mais importante que o outro.
7	demonstrada	Um fator é fortemente favorecido e sua maior relevância foi demonstrada na prática.
9	extrema	A evidência que diferencia os fatores é da maior ordem possível.
2,4,6,8	intermediários entre julgamentos	Possibilidade de compromissos adicionais.

Fonte: Adaptado de Saaty (1990)

Com o subsídio dessa tabela e as considerações da hierarquização da intensidade de importância dos temas, foi estabelecida a matriz de comparações pareadas diretas e reversas da pesquisa (Figura 40).

Figura 40 – Matriz de Comparação Pareada

TEMAS	Uso da Terra/ Cobertura Vegetal	Solo	Declividade	Geologia
Uso da Terra/ Cobertura Vegetal	1	2	2	6
Solo	1/ 2	1	1	3
Declividade	1/ 2	1	1	3
Geologia	1/ 6	1/ 3	1/ 3	1

Após a elaboração da Matriz Pareada, foi construída uma matriz normalizada que calcula os vetores de prioridades.

Para isso, dividem-se os elementos de cada coluna pela soma daquela coluna (normalização), e então, somam-se os elementos em cada linha resultante e divide-se esta soma pelo número de elementos da linha, calculando assim o vetor de prioridade de cada tema, que é o peso estimado. A Figura 41 é a Matriz de Comparação Normalizada com o Vetor de Prioridade estimado para cada um dos temas.

Figura 41 – Matriz de Comparação Normalizada e Vetor de Prioridade estimado

TEMAS	Uso Terra	Solo	Declivida- de	Geolo- gia	Vetor Coluna	Vetor Prioridade
Uso Terra	0,6429	0,4618	0,4618	0,4615	1,8480	0,461
Solo	0,2315	0,2309	0,2309	0,2307	0,9240	0,231
Declividade	0,2315	0,2309	0,2309	0,2307	0,924	0,231
Geologia	0,074	0,0762	0,0762	0,0769	0,3035	0,077
Total					3,995	1

Com a elaboração da Matriz Ponderada foi calculado o peso de cada um dos critérios considerados. Assim, os pesos por critérios foram estabelecidos da seguinte forma (Tabela 19).

Tabela 19 – Pesos do AHP por critérios

Temas	Pesos Estimados
Mapa de Uso da Terra/ Vegetação	0,461
Mapa de Solos	0,231
Mapa de Declividades	0,231
Mapa Geológico	0,077
Total	1

Selecionando os pesos estimados é possível calcular a consistência dos julgamentos aplicados, para isso deve-se seguir alguns passos:

Inicialmente multiplica-se a matriz pareada pelo vetor coluna tendo como resultado um novo vetor.

$$\begin{vmatrix} 1 & 2 & 2 & 6 \\ 1/2 & 1 & 1 & 3 \\ 1/2 & 1 & 1 & 3 \\ 1/6 & 1/3 & 1/3 & 1 \end{vmatrix} \parallel \begin{vmatrix} 0,461 \\ 0,231 \\ 0,231 \\ 0,077 \end{vmatrix} = \begin{vmatrix} 1,847 \\ 0,9235 \\ 0,9235 \\ 0,30245 \end{vmatrix}$$

Com a obtenção do resultado, divide-se o primeiro componente do novo vetor pelo primeiro componente do vetor de prioridade, o segundo componente do novo vetor pelo segundo componente do vetor de prioridade, e assim por diante. Se dividir-se a soma dos componentes deste vetor pelo número de componentes, ter-se-á uma aproximação para o $\lambda_{\max}$ (chamado de autovetor).

$$\frac{1}{4} \left| \begin{array}{cccc} 1,847 & 0,9235 & 0,9235 & 0,30245 \\ 0,461 & 0,231 & 0,231 & 0,077 \end{array} \right| = 15,93$$

Para o cálculo de Índice de Consistência (IC), aplica-se a fórmula representada por $(\lambda_{\max} - n)/(n - 1)$. O resultado do IC, segundo Saaty (1990), deve estar dentro do intervalo de $[0 - 1]$, o que significa que os resultados dos julgamentos são adequados.

Aplicando essa fórmula aos resultados obtidos, tem-se:

$$IC = \frac{15,9 - 4}{3} = 0,0058$$

Neste trabalho o resultado foi $IC = 0,0058$, sendo assim apropriada a consistência dos julgamentos. Sobre essas matrizes foi aplicado o peso dos critérios da comparação pareada e efetuada a álgebra de mapas.

Partindo da estratégia acima apresentada foi escrito na linguagem do LEGAL um programa para executar a tarefa de aplicar o AHP sobre os temas do banco de dados geográficos.

Abaixo segue a programação em LEGAL:

<pre>{ // Definicao dos dados de entrada Tematico var1 ("Decliv"); Tematico var2 ("Uso_terra2"); Tematico var3 ("geologico"); Tematico var4 ("pedologico"); Tabela tab1 (Ponderacao); tab1 = Novo (Categorialni = "Decliv" , "0 - 5":1.11, "5 - 12":2.11, "12 - 30":3.22, "30 - 47":4.22, "> 47":5.0); Tabela tab2 (Ponderacao); tab2 = Novo (Categorialni = "Uso_terra2" , "campo_antropico":3.29, "ciclo_longo":3.29, "ciclo_curto":4.43, "reflorestamento":2.21, "mata":1.0, "urbano":1.0, "solo_nu":5.0, "capoeira":2.29, "agua":1.0); Tabela tab3 (Ponderacao); tab3 = Novo (Categorialni = "geologico" , "H":5.0, "Kb":3.63, "Ksg":1.28, "Jbp":3.75); Tabela tab4 (Ponderacao);</pre>	<pre>tab4 = Novo (Categorialni = "solos" "LRe":1.67, "LRd":2.08, "LE2":2.33, "LE1":1.75, "LV2":2.33, "LV1":3.0, "PV2":3.17, "PV1":3.83, "TE2":1.33, "TE1":1.33, "AQ":5.00, "Li":4.17, "Or":2.58); // Definicao do dado de saida Numerico var5 ("AHP_1a5"); // Recuperacao dos dados de entrada var1 = Recupere (Nome="Decliv_tin_biase_"); var2 = Recupere (Nome="class-T_"); var3 = Recupere (Nome="Geo"); var4 = Recupere (Nome="solo"); // Criacao do dado de saida var5 = Novo (Nome="AHP", ResX=30, ResY=30, Escala=100000, Min=1, Max=5); // Geracao do AHP var5 = 0.231*(Pondere(var1, tab1)) + 0.461*(Pondere(var2, tab2))+ 0.077*(Pondere(var3, tab3))+ 0.231*(Pondere(var4, tab4)); }</pre>
--	---

Figura 42 – Aplicação dos Pesos do AHP para os Temas

<div style="border: 1px dashed black; padding: 10px; text-align: center;"> MR = 0,461 (MUT/CV) + 0,231 (MP) + 0,231 (MD) + 0,077 (MG) </div> <p> MR = Matriz Resultante MT/CV = Matriz Uso da Terra e Cobertura Vegetal MD = Matriz Declividade MG = Matriz Geologia </p>

Cabe destacar que, para estabelecer as Matrizes Temáticas envolvidas na álgebra de mapas, foi utilizada a atribuição dos valores referentes aos modelos numéricos de classes, estabelecidos na consulta aos especialistas.

Como resultado dessa técnica, obteve-se um mapa numérico sintético, que é apresentado com graduação de cores – no tom cinza. Assim, para os tons mais próximos do branco, estão os maiores valores numéricos e as cores mais próximas ao preto são os menores valores numéricos.

Como resultado dessa técnica, tem-se um mapa numérico sintético, representado em diferentes níveis de cinza.

Para realizar a leitura interpretativa desse produto cartográfico é necessário ter como parâmetro a definição do *rank* que foi atribuído para cada variável dos temas. Onde os menores valores, próximos ao valor um (1), deveriam representar as variáveis mais estáveis e os valores próximos ao cinco (5), as mais instáveis. Então, após a aplicação da álgebra de mapas, os pixels com as cores próximas ao branco são representantes das áreas mais instáveis e os próximos ao preto, as mais estáveis.

Figura 43 – Modelo Numérico resultado da aplicação da técnica AHP

10.3. Redes Neurais Artificiais

Neste item, serão apresentados todos os procedimentos desenvolvidos e necessários para trabalhar com redes neurais artificiais usando o SPRING em associação com o SNNS. Esses procedimentos são destinados à obtenção de um mapa síntese derivado de diversos outros mapas temáticos.

10.3.1. Normalização dos dados

Para isso, a primeira etapa para o trabalho com redes neurais artificiais usando o SPRING e o SNNS é a obrigatoriedade da normalização dos dados. Aqui, o que está sendo chamado de dados são as classes que compõem cada um dos mapas temáticos.

As RNA's trabalham com intervalos numéricos entre $[-1;1]$, sendo, portanto, necessária a padronização do banco de dados geográficos para esse intervalo, transformando assim todo o conjunto de dados em um formato compatível com o “entendimento” delas.

A definição do intervalo dos dados é importante para a construção da rede neural artificial, pois, na escolha da função de ativação da rede neural artificial é esse conjunto de dados que deve ser levado em consideração, assim a escolha da função de ativação deve ser compatível com esse intervalo.

Neste estudo, foi utilizada a função de ativação “logic”, que trabalha com intervalos de $[0;1]$, sendo coerente com o conjunto de dados do banco de dados geográficos normalizado, pois eles foram normalizados para o intervalo $[0;1]$.

Existem outras funções de ativação nas RNA's, por exemplo: a “Hiperbólica” $[-1;1]$, utilizada quando os dados compreendem valores negativos e positivos. Portanto, é necessário estar atento na escolha da função de ativação quando for

fazer a configuração do neurônio. No SNNS, além destes dois exemplos citados, ainda existem outras funções de ativação disponíveis para a construção da rede neural artificial e configuração de cada neurônio.

Para a normalização dos PI's temáticos foi utilizada uma programação em LEGAL, esta normalização foi realizada sobre os geo-campos numéricos que foram criados quando da aplicação das álgebras de mapas para a obtenção dos modelos numéricos do AHP e OPS.

Assim, o processo foi recuperar esses geo-campos temáticos e redefinir para o intervalo de $[0;1]$, para isso foi utilizada uma normalização linear. Essa normalização consiste em considerar os valores máximos e mínimos de cada pixel para ajustar seu intervalo de valor. Além disso, mapear os valores de um campo no intervalo $[1;0]$ e manter a distância entre os valores normalizados proporcionais aos valores originais. Abaixo, segue a fórmula matemática utilizada:

$$N = (n - \text{Min}) / (\text{Max} - \text{Min})$$

Onde:

N = valor normalizado

n = valor a ser normalizado

Min = menor valor

Max = maior valor

Essa expressão foi utilizada dentro das linhas de comando em LEGAL, e viabilizou a criação desses novos geo-campos numéricos, agora normalizados.

Abaixo, seguem as linhas de comando para a elaboração desses produtos. O exemplo é para o mapa solos.

```
{
Numerico grd, resul ("solo");
grd = Recupere (Nome = "solo");
resul = Novo (Nome = "solo_norm", ResX = 30, ResY = 30, Escala = 100000, Min = 0, Max = 1);
// min 1 e max 5
resul = (grd - 1.0 ) / ( 5 - 1.0 );
}
```

Dessa forma foram obtidos os modelos numéricos normalizados de todos os mapas:

Mapa de Solos, Uso da Terra, Geologia, Declividade e os modelos resultantes da álgebra de mapas pelas metodologias OPS e AHP.

Cabe considerar o porquê de se fazer a normalização também dos modelos OPS e AHP. Como a estratégia é tentar obter mapas equivalentes entre os modelos, estes dados normalizados serão o arquivo *pattern* da RNA.

10.3.2. Formação do arquivo de “resultados esperados”

O chamado arquivo pattern, dentro do SNNS, é o arquivo de dados padrão. É composto pelos modelos numéricos que servirão como “resultados esperados” no processo de treinamento da RNA.

Ainda sobre esse procedimento, como foi exposto anteriormente, a arquitetura usada neste estudo é a MLP, essa arquitetura realiza treinamento “supervisionado”, ou seja, para que a RNA seja treinada para “prever” um evento é necessário realizar um treinamento com os dados (valores numéricos) exatos ou chamados de “esperados” para um conjunto de amostras de um universo, e assim, após a RNA

ser treinada e ajustados adequadamente seus pesos, ela seja capaz de realizar previsões.

Para visualizar o arquivo *pattern* e sua funcionalidade, segue a tabela 20 como exemplo:

Tabela 20 – Exemplo de arquivo *pattern* para uma rede neural artificial

Amostras	Dados Amostra				Valor Esperado	Classe
	PI A	PI B	PI C	PI D		
1	0,11	0,40	0,60	0,70	0,45	Baixo
2	0,90	0,85	0,80	0,40	0,73	Alto
3	0,20	0,90	0,40	0,10	0,40	Baixo
Dados Univeso					Valor Previsto	
4	0,30	0,80	0,30	0,20	"?"	"?"

Na tabela 20 as amostras “1 a 3” demonstram o que seria a funcionalidade de um arquivo *pattern*. Nas colunas “PI A,B,C,D” estão os valores que foram atribuídos para as classes das variáveis dos PI’s, já normalizados para o intervalo [0;1]. Na coluna “Valor Esperado”, o valor desejado para aquela combinação de números que foi derivada da álgebra de mapas.

O que é desejado então? Que a partir da realização do treinamento da rede neural artificial, tendo como parâmetros de saída os valores gerados pela álgebra de mapas, a rede tenha a capacidade de prever os valores (resultados) para as combinações desconhecidas. Para isso, o treinamento da rede neural artificial deve gerar valores de saída o mais próximo o possível do gerado pela álgebra de mapas.

O que é esperado neste estudo é que a RNA que foi treinada com os valores da área amostral tenha a capacidade de calcular valores calibrados para os dados

que serão apresentados da área total, e assim, seja possível criar um mapa de geo-campos e comparar com os resultados obtidos pela álgebra de mapas.

No exemplo proposto da tabela 20, obtidos os dados através da RNA é possível estabelecer classes temáticas, como é sugerido na coluna “Classe”, e depois aplicá-los para construir, por exemplo, um mapa temático de vulnerabilidade ou de áreas críticas por exemplo. Após a explicação do funcionamento e utilização do arquivo “*pattern*”, prossegue-se a sequência dos processos técnicos para a aplicação da RNA para a obtenção de mapa síntese.

Após a realização de toda a normalização dos geo-campos numéricos, a próxima etapa é a exportação de todos esses modelos do SPRING. São os quatro PI’s temáticos, que serão as entradas para RNA, e mais os PI’s AHP e OPS. Estes dois últimos serão utilizados como arquivo *pattern*. Para essa exportação, será utilizada a função de “exportação” do SPRING com a seguinte configuração:

Formato: ASCII-Spring; Separador: Nenhum; Entidade: Grade Reg.
--

Essa exportação irá criar um arquivo de texto, é adequado quando for realizar manipulação de grandes arquivos em “ASCII”, usar um editor mais potente do que o tradicional *notepad* do *windows*, no caso deste trabalho foi utilizado o “UltraEdit”, pois esses editores mais tradicionais podem ter “problemas” para ler grandes arquivos.

O próximo passo é edição de todos os arquivos criados e exportados, deles devem ser retirados os cabeçalhos, como é apresentado o exemplo abaixo, figura 44.

Figura 44 – Edição dos Cabeçalhos exportados do SPRING

[illegible]

Após esse procedimento, foi utilizado um aplicativo desenvolvido pelo INPE chamado “mixerrgbr.exe”. O aplicativo tem como objetivo realizar a junção de matrizes. Esse será um procedimento necessário para criar o arquivo que será recebido pelo SNNS.

Antes de executar esse procedimento de junção das matrizes é necessário criar um arquivo de identificação, que deve ser utilizado junto com o “mixerrgbr.exe.” Este arquivo pode ser chamado de “tudo”, ou qualquer outro nome, e com extensão “txt”. Esse arquivo é necessário para que o “mixerrgbr.exe.” tenha a capacidade de ler os outros arquivos e juntar todas as matrizes em um único.

Dentro desse arquivo “tudo.txt”, devem ser escritas as seguintes linhas de comando:

Na primeira linha o nome de saída (exemplo “sai.pat”), na linha de baixo digite “1”, depois são colocados os nomes dos arquivos que foram exportados e editados do SPRING, por exemplo: “Uso_da_terra.spr”, “Declividade.spr”, “Solo.spr” e “Geologia.spr”.

Abaixo, segue um exemplo de como devem ser escritas as linhas de comando do arquivo “tudo” (Figura 45).

Figura 45 – Linhas de Comando do Arquivo “tudo”.

O procedimento a seguir é colocar todos os arquivos em uma mesma pasta dentro do Windows ou do sistema operacional que for usado. São as matrizes exportadas do SPRING (referentes aos PI's), o arquivo “tudo” e o “mixerrgbr.exe”. E executar.

Com isso, será criado um arquivo com o nome “sai”. Esse arquivo é uma montagem com todas as matrizes dispostas sequencialmente, respeitando suas posições de origem. Na figura 46, é apresentado um esquema conceitual de como são o processamento e a montagem dessa combinação de matrizes.

Figura 46 – Junção de matrizes “sai”

Assim, a Figura 46 ilustra como foi montado o arquivo “sai” e como o “mixerrgbr.exe” funciona. Como dito, ele lê cada um dos arquivos com as matrizes e vai sequenciando, respeitando as posições de cada valor no arquivo original, e assim “constrói” este novo arquivo no formato ideal para ser recebido pela RNA.

Realizada essa construção do arquivo “sai” é necessário configurar nele o cabeçalho para que as informações referentes ao conteúdo sejam “lidas” no SNNS.

O Cabeçalho dever ter as seguintes linhas de comando:

```
SNNS pattern definition file V3.2
generated at mm/dd/aa
No. of patterns : 1
No. of input units : 1
No. of output units : 1
No. of variable input dimensions : 2
Maximum input dimensions : [ 126 708 ]
No. of variable output dimensions : 2
Maximum output dimensions : [ 126 177 ]
```

Essas linhas de comando devem ser definidas a partir das dimensões das matrizes de entrada. Na linha de comando “Maximum input dimensions”, o número de colunas deve ser multiplicado pelo número de PI’s de entrada. No caso do exemplo acima existem três matrizes 2 X 2. A linha de comando para SNNS seria:

Maximum input dimensions [2, 6].

Já a linha de comando da saída da matriz será exatamente igual às entradas, portanto, a linha ficaria assim:

Maximum output dimensions [2, 2]

No caso do cabeçalho apresentado como exemplo, as dimensões das matrizes são as utilizadas na área de teste, com 177 colunas por 126 linhas.

10.3.3. Construção da RNA no SNNS

Com a edição do cabeçalho do arquivo “sai”, o arquivo para a importação está pronto. O próximo passo é ir para o SNNS e realizar a construção da RNA que receberá os dados do arquivo “sai” para a realização do treinamento.

Para isso é necessário inicialmente a abertura do SNNS. O software é composto na para superior do menu, onde encontra-se diversas funções e na parte inferior um quadro em branco onde é destinado para a manipulação das redes de uma forma visual e interativa. (Figura 24).

Para adicionar os neurônios utilizam-se as funções:

Tools <> Create <> Layer

Na Figura 24 é apresentada uma rede com 4 neurônios de entrada, referente a cada uma das entradas do arquivo "sai"; 5 neurônios na camada escondida; um neurônio de saída. Esta arquitetura será a base para os treinamentos com a RNA.

Figura 47 – Painel do SNNS e RNA com 4 entradas e 1 saída – Estrutura

A Figura 47 apresenta o painel de visualização do SNNS com a arquitetura neural configurada. Na tela de visualização, cada um dos quadrados azuis são os símbolos gráficos associados a cada um dos neurônios artificiais que compõem a RNA.

Da esquerda para a direita estão dispostos em linha vertical 4 neurônios que correspondem aos de entrada, os 5 neurônios do meio são os da camada escondida e o da direita, isolado, é o de saída. Todos os neurônios estão ligados por uma linha, deve ser notado que cada um dos neurônios está conectado a todos os outros neurônios da sua camada e da camada subsequente.

Ao acompanhar a “ligação” entre os neurônios é possível verificar a existência de um valor entre os neurônios. Esse valor é o peso que cada uma das ligações neurais tem e que é aplicado na passagem dos dados por essa “ligação”. Esses pesos é que variam quando a rede neural artificial está realizando seu treinamento.

10.3.4. Configuração individual dos neurônios

No processamento da RNA, cada neurônio é uma unidade de processamento único e no SNNS é possível efetuar os ajustes individuais através da tela abaixo (Figura 48).

Figura 48 – Tela de configuração de neurônio no SNNS

Essa configuração individualizada é importante, pois é nela que será definido qual o tipo de neurônio e a ação que este irá realizar. No exemplo acima, a opção “Unit Type” está definida como “input”, o que significa que este neurônio terá o papel de entrada. Os outros neurônios que compõem a arquitetura devem ser configurados para outra natureza de acordo com a camada a que devem pertencer. Como “hidden” para os que compõem a camada escondida e “output” para a de saída.

Ainda dentro dessas opções de configuração, aqui será definida a opção de função de ativação. No campo “Activation Function” está selecionada a função “Act_Logist”, que é definida em função do tipo de intervalo dos dados, como explicado anteriormente.

Com a estrutura da arquitetura da RNA configurada, a próxima ação é a importação do arquivo “sai”, para dar início ao processo de treinamento.

10.3.5. Importação dos dados pelos SNNS

A importação deve ser feita pelo “Menu” do SNNS utilizando-se os botões:

Assim que for carregado o arquivo no sistema, será apresentada na barra de Menu do SNNS a confirmação da leitura do arquivo sai. A figura 49 ilustra essa etapa de importação.

Figura 49 – Barra de Menu do SNNS com parâmetros de importação

Como apresenta a figura, automaticamente o sistema identificou o conjunto de valores para o treinamento, que são os valores dos PI's normalizados, apresentados em “Training pattern set”, e o conjunto de valores esperados em “Validation pattern”. Como os dois conjuntos estão contidos no mesmo arquivo, o SNNS apresenta o mesmo nome de arquivo para as duas situações, neste caso o nome “sai”.

10.3.6. Processamento dos dados no SNNS

Agora, é necessária para a manipulação do sistema a ativação do painel de controle em:

Tools <> Control Painel.

10.3.6.1. Inicialização da RNA

O painel de controle é dividido com diversas “abas”, destinadas às diferentes manipulações e configurações. Para o treinamento é necessário realizar uma inicialização dos pesos da RNA de forma randômica, pressionando o botão “Init”.

A atenção é para a alteração do *default* da SNNS do campo <Parameters>. As redes neurais artificiais trabalham com intervalos de no máximo $[-1;1]$ e estes valores já vêm fixados neste campo.

Como os conjuntos de dados estudados estão no intervalo de $[0;1]$, então, foi ajustado o campo <Parameters> para este intervalo como demonstra a Figura 50.

Figura 50 – Parametrização da inicialização randômica

Ainda, sobre a inicialização, a escolha da forma randômica é necessária para que no primeiro ciclo do treinamento não aconteça com valores “zero” nos pesos da ligação de cada um dos neurônios.

A inicialização randômica propiciará à rede valores aleatórios de multiplicação para este primeiro ciclo, quando também será realizado o primeiro cálculo do erro. A Figura 51 apresenta duas arquiteturas de RNA's, na primeira é possível observar que o peso da ligação dos neurônios está zerado, e na figura abaixo é possível notar a arquitetura com valores nas ligações, fruto da execução randômica.

Figura 51 – Neurônios com valores antes e depois da inicialização randômica

Ainda, na configuração do painel de controle é necessário antes de inicializar o treinamento a configuração da aba <Subpatterns>. Nesta aba deve ser fixado o número de neurônios de entrada e de saída.

Os neurônios de entrada correspondem ao número de PI's, que neste estudo são quatro. Assim, o SNNS traz como *default* <1> e a alteração deve ser realizada para:

<Input Size 4>;

<Input Step 4>,

10.3.6.2. Configuração do arquivo Subpatterns

A figura 52 apresenta duas abas de configuração do arquivo *subpartterns*. A primeira demonstra como é o default do SNNS e abaixo onde deve ser efetuado o ajuste.

Figura 52 – Ajustes para os arquivos do campo Subpatterns

<p>Subpatterns Default</p>
<p>Subpatterns Configuração</p>

10.3.6.3. Aprendizagem da RNA

Seguindo a configuração do painel de controle para dar início ao treinamento, a próxima “aba” a ser configurada é a <Learning>, destinada às configurações do treinamento.

Serão ajustados os campos <Learning Function> e <Cycles>. O campo “Learning Function” é onde é selecionado o tipo de treinamento a que os neurônios serão submetidos. Esse treinamento deve estar em acordo com a arquitetura da rede neural que foi construída.

Neste estudo foi utilizada a arquitetura de RNA em MLP, que utiliza o treinamento “backpropagation”. Já o número de ciclo corresponde às quantas vezes a RNA irá tentar diminuir o erro médio quadrático.

Na literatura não existe nenhuma citação de quantos ciclos seria o ideal, assim fica a critério do pesquisador ir aplicando um número de ciclos e ir observando o comportamento do erro. No SNNS o default é de 100 ciclos. Foram utilizados diferentes ciclos de acordo como os testes que foram sendo realizados. A Figura 53 apresenta a “Aba” de treinamento e as configurações que foram ajustadas.

Figura 53 – Configuração do sistema de aprendizagem do SNNS

10.3.6.4. Acompanhamento do treinamento da RNA

Ainda nas possibilidades de acompanhamento do treinamento, o SNNS disponibiliza duas ferramentas muito úteis. O monitoramento do gráfico do erro e o log, onde a cada ciclo é apresentado graficamente o comportamento do erro médio quadrático e da soma do erro para cada ciclo de ajustes de pesos que a RNA está realizando. A Figura 54 apresenta o gráfico do erro e o log com os valores dos ciclos.

A Figura 54 apresenta dois gráficos: um para a soma do erro médio quadrático do universo das amostras e outro para o erro médio quadrático do experimento.

Figura 54 – Gráficos e Tabelas de Log do Erro SSE e MSE

A partir dos testes realizados e apresentados acima para exemplificar o processo de treinamento e de análise. Os testes foram realizados sobre uma arquitetura de RNA em MLP com 4 neurônios de entrada e 5 na camada escondida com uma aprendizagem em 500 ciclos, tendo esta configuração obtido os melhores resultados.

Analizando os resultados, pode-se notar que à medida que os ciclos vão se sucedendo, a RNA vai ajustando os pesos e diminuindo o erro médio quadrático (MSE), conforme o fechamento de cada ciclo.

Outra ferramenta importante que o SNNS disponibiliza é o gráfico da soma do erro quadrado (SSE), que também auxilia no monitoramento do comportamento do aprendizado da RNA.

Mas uma pergunta que se coloca é: Qual seria a melhor medida para o MSE?

Segundo Zell (1991), o importante é ter em mente que o quanto mais baixo for esse indicador significa que melhor será o desempenho da RNA. O autor ainda considera que para ser bem-sucedido usando RNA's, você precisa ter uma atitude de experimentação, usar da capacidade de mudar rapidamente a arquitetura de RNA, conjuntos-padrão diferentes, modificar os parâmetros de formação, e reinicializar e requalificar a rede neural artificial. Aproveitar esses recursos para tentar maximizar o desempenho de sua rede neural artificial sobre o problema que tenta solucionar.

Neste estudo foram testadas diversas arquiteturas variando o número de neurônios na camada escondida, e foi obtido o melhor resultado utilizando-se a estratégia de o número de neurônios ser o número de entradas mais um.

Observando o MSE que foi gerado para esse conjunto de amostras, o erro de aproximadamente 0,000009 pode ser considerado bom, pois está muito perto do zero, como sendo objetivo proposto por Zell (1991).

Com essa última etapa é fechado o ciclo de construção da arquitetura da RNA. Os pesos, o número de neurônios nas diversas camadas e a função de ativação, tudo é congelado e a RNA já está pronta para gerar previsões, de acordo com os ajustes realizados no treinamento.

10.3.7. Exportação dos dados para o SIG

Encerrado o processo de treinamento da RNA e a aplicação sobre os dados, é necessário enviar o resultado para o SPRING, para poder visualizar os resultados na forma de um mapa temático numérico sintético. Então começa a etapa de normalização para realizar o processo de “volta” do SNNS para o SPING. Para isso, os dados resultados do treinamento devem ser salvos usando a função:

<File> <Salve Data>.

A tela de salvamento é apresentada na Figura 55.

Figura 55 – Salvamento de resultado da rede neural artificial

Nessa janela serão salvos os dados do resultado do treinamento, o SNNS vai gerar um arquivo com extensão *.res, que é o padrão proprietário deste software. O desafio agora é transformar esse arquivo no formato de uma grade retangular para que possa ser interpretada pelo SPRING.

Este arquivo *.res é apresentado da seguinte forma: (Figura 56)

Figura 56 – Formatação do arquivo *.res

```
SNNS result file V1.4-3D
generated at Wed Aug 19 12:37:07 2009

No. of patterns      : 2530
No. of input units   : 4
No. of output units  : 1
startpattern         : 1
endpattern           : 1
#1.1
0.40803
#1.2
0.40803
#1.3
0.40803
#1.4
```

Nesse arquivo, diferentemente de uma matriz, os dados são dispostos como uma tabela de uma só coluna, que deve ser interpretada da seguinte forma:

A numeração “#1.1” indica que esse é o valor correspondente ao calculado para os quatro valores da matriz apresentados à rede na entrada da posição “ $A_1:A_1$ ”. Para essa posição, a RNA calculou como valor de saída 0.40803.

Esses valores são apresentados para todos os dados gerados até o último; no caso do experimento realizado, foi o “#2530”. O número de cálculos aparece no cabeçalho do arquivo com o nome de “No. of patterns”, como pôde ser observado na figura acima.

Para transformar essa “tripa” de valores em uma matriz é necessário utilizar um programa auxiliar, o “res2xxx.exe”. Esse programa tem como objetivo montar a matriz que será recebida no SPRING.

Para isso, é necessário colocar os dois arquivos em uma mesma pasta do Windows ou do sistema operacional com que se esteja trabalhando, isto é, copiar o arquivo de saída da RNA “*.res” e o aplicativo “res2xxx.exe” e executar.

Ao executar, o programa solicita que seja definido o número de colunas para a montagem do arquivo final. O número de colunas deve ser igual ao número do arquivo inicial, que foi exportado no SPRING. Assim esse novo arquivo terá o mesmo tamanho dos iniciais.

Definido o número de colunas, o “res2xxx.exe” começa a ler o arquivo “*.res” e montar a matriz. Cada posição horizontal será mantida na posição vertical como é demonstrado na Figura 57.

Figura 57 – Criação da matriz de resultados a partir dos dados do SNNS

Arquivo Patterns	Res2xx	Matriz Resultado	
# 1.1	Definição para 2 colunas	0.45	0.54
0.45		0.23	0.15
# 1.2		0.67	0.86
0.54			
# 1.3			
0.23			
#1.4			
0.15			
# 1.5			
0.67			
# 1.6			
0.86			

Finalizada a etapa de formação da matriz com os valores resultados do treinamento da RNA, é necessário copiar o cabeçalho do arquivo que foi inicialmente exportado do SPRING.

Esse procedimento se justifica para que o SPRING tenha capacidade de “ler” esse arquivo como uma grade numérica e seja capaz de transformar esses valores em uma imagem. Após ajustar o cabeçalho, é necessário inserir a palavra “End” no final do arquivo. A figura 58 apresenta a inserção do cabeçalho, este procedimento deve ser feito em um editor de texto.

Figura 58 – Configuração do cabeçalho do arquivo *.res para o Spring

10.3.8. Importação dos dados pelo SPRING

Com o cabeçalho inserido, o arquivo está configurado para ser recebido no SPRING, para isso deve ser usada a ferramenta de importação:

Arquivo <> Importar <> Grd Retangular

Agora no SPRING há uma imagem formada por uma grade numérica que foi obtida no processamento do SNNS. Ela pode ser visualizada na forma de uma gradiente de cinza ou ser gerado um mapa temático coropético a partir dessa mesma grade.

Com o recebimento e a geração dos modelos dentro do SPRING ficam concluídos todos os procedimentos técnicos/metodológicos desenvolvidos para a criação de mapa síntese a partir de redes neurais artificiais.

10.3.9. Aplicação da RNA na área teste

Finalizados e definidos esses procedimentos, eles foram aplicados na área teste para a criação de modelos numéricos tendo como arquivo *pattern* os modelos obtidos pelos AHP e OPS.

O primeiro treinamento foi realizado para os valores obtidos com o modelo OPS como resultados esperados. Foram testadas diversas arquiteturas e o melhor desempenho foi obtido em uma arquitetura de 4 neurônios de entrada, 5 na camada escondida e um na camada de saída.

Durante o treinamento para este universo de dados amostrais, o resultado do erro médio quadrático é de 0,000009, e exportado o arquivo da RNA e importado no SPRING, foi obtido o mapa sintético apresentado na Figura 59.

Figura 59 – Modelo gerado pelo RNA para o arquivo *pattern* OPS

O segundo treinamento foi realizado para os valores obtidos com o modelo AHP, usando esses como o arquivo *parttern*. No treinamento foi obtido o melhor resultado usando uma arquitetura com 4 neurônios de entrada, na camada escondida e um na camada de saída. Tendo com resultado do treinamento um erro médio quadrático de 0,000011. Aplicando a metodologia desenvolvida, o arquivo resultado da RNA foi recebido no SPRING e gerou o modelo abaixo. Figura 60

Figura 60 – Modelo gerado pelo RNA para o arquivo *pattern* AHP

11. Aplicação das metodologias para toda a área estudada e comparação dos modelos

Neste estudo foram desenvolvidos e apresentados todos os processos técnicos/metodológicos para a obtenção de mapas sínteses para a área teste, a partir de três possibilidades distintas de modelagem cartográfica.

O passo a seguir foi replicar as metodologias para a área total do município de Itirapina. Portanto, foram obtidos modelos numéricos síntese a partir das metodologias propostas, o OPS, AHP e RNA para toda a área, da seguinte forma:

Primeiro, foram replicadas as expressões de álgebra de mapas que foram obtidas a partir das diferentes concepções metodológicas expostas, o AHP e o OPS. Foram obtidos como resultado os modelos numéricos apresentados na Figura 61.

Figura 61 – Modelos numéricos gerados para o AHP e OPS

Esses mapas (Figura 61) são constituídos de modelos numéricos em diferentes graus de cinza e estão normalizados para o intervalo numérico de $[0;1]$, onde cada pixel representa uma área de 30 x 30 metros.

Eles devem ser interpretados considerando que as áreas mais instáveis estão próximas do valor “0”, sendo 0 a cor branca. As áreas mais estáveis estão próximas ao valor “1”, o preto é associado a esse valor.

O segundo procedimento foi a criação dos modelos numéricos a partir das RNA's para toda a área do município de Itirapina. Foram replicados os processos técnicos e metodológicos desenvolvidos e aplicados para a área teste. Desse modo, foram obtidos dois modelos, um para o OPS e outro para o AHP.

Portanto, os modelos numéricos que geraram esses mapas foram submetidos à arquitetura das RNA's desenvolvida na fase do teste. Sendo mantidos os pesos e a estrutura da RNA que foi desenvolvida durante o treinamento, cada um dos modelos foi submetido à sua respectiva RNA.

Nessa etapa, a RNA não tem mais nenhuma mudança nos seus pesos, sua configuração é fixa. Ou seja, os valores de saída da RNA são calculados diretamente sobre a arquitetura que foi construída e treinada, e assim, gerando valores de saída.

Esses valores de saída são gerados sem nenhum tipo de correção ou comparação aos valores apresentados para a RNA como entradas, como é feito na etapa de treinamento. É aqui que a RNA está gerando suas previsões, a partir da “aprendizagem” que ela obteve durante o treinamento.

Abaixo são apresentados os mapas sínteses calculados pelas RNA's para cada um dos modelos na Figura 62.

Figura 62 – Modelos gerados pelas RNA's para o AHP e OPS

A interpretação desse produto cartográfico deve seguir a mesma metodologia dos mapas algébricos, onde eles estão expressos em um gradiente numérico de intervalo $[0;1]$, sendo áreas instáveis próximo a zero e estáveis próximo a um.

Portanto, foi finalizada a etapa de aplicação dos procedimentos que geraram os modelos para as três metodologias e colocou-se o desafio de uma nova fase: A comprovação da hipótese desta tese, o quanto os modelos gerados pela RNA são próximos aos exemplos apresentados.

Para o tratamento da eficiência das RNA's, adotou-se o seguinte princípio: redes neurais artificiais em arquitetura MLP realizam “previsões” baseadas em treinamento supervisionado, assim, a estratégia foi verificar o quanto os modelos das RNA's se assemelham com os modelos gerados pelas álgebras de mapas.

Então, a ideia foi verificar se é possível, a partir de um processamento de aproximação de funções (RNA) comparado com um processamento algébrico, ter como resultado modelos numéricos que possam levar à mesma tomada de decisão.

Estabelecida a forma de estratégia, na prática o que foi realizado foi a comparação dos mapas sínteses do AHP e do OPS com o modelo gerado pelas RNA's. O que é esperado é que tenhamos mapas muito parecidos e que a hipótese da tese seja confirmada.

Aplicado o processamento para obtenção dos mapas com RNA's e comparando os resultados como os outros modelos, não foi observada nenhuma diferença nos modelos, partindo de uma análise feita de forma visual.

Mas, por ser gerado a partir de uma concepção matemática diferente, e também buscando localizar possíveis diferenças entre os modelos gerados que não sejam perceptíveis a uma análise a “olho nu”, foi adotado um procedimento de comparação espacial entre os modelos numéricos.

Foi realizado um processamento de subtração espacial “pixel a pixel” para cada um dos modelos numéricos através do LEGAL. As figuras 63 e 64 apresentam os dois modelos numéricos em forma de mapas, um para o AHP e OPS, e os produzidos a partir da aplicação das RNA's.

Os mapas são apresentados em dois conjuntos de figuras: na parte inferior, o mapa síntese, resultado da subtração dos dois modelos. Na parte superior, são apresentados os modelos AHP e OPS, um em cada conjunto de mapas e ao lado, o modelo correspondente gerado a partir da RNA.

Como é possível de ser observado ao comparar e interpretar os mapas sínteses resultados das álgebras e os das redes neurais artificiais, podemos notar que eles são praticamente idênticos em uma interpretação visual, mas na parte inferior da figura é apresentado o mapa de subtração, onde é possível visualizar os pixels da diferença espacial entre os modelos.

Os mapas da diferença são expressos em um gradiente de diferentes níveis de cinza, sendo a menor diferença nos tons de cinza e a maior diferença nos tons mais escuros.

A Figura 63 apresenta a comparação entre o AHP e a RNA e a Figura 64 apresenta a comparação entre o OPS e RNA.

Figura 63 – Comparação espacial dos modelos AHP e RNA

Figura 64 – Comparação espacial dos modelos OPS e RNA

Para a interpretação dos mapas, deve ser entendido que no valor zero é onde foram obtidos os valores de pixel com máxima exatidão pela RNA, e a partir daí, os valores da diferença em cada uma das células das matrizes são justamente a diferença da obtenção do valor do mapa original e o da RNA.

As tabelas 21 e 22 apresentam a diferença da precisão da previsão realizada pelas RNA's para cada um dos modelos – AHP e OPS.

Tabela 21 – Variação do valor e quantidade de pixel da diferença da RNA para OPS

OPS (No. PIXEL)					
Valor	No.	Valor	No.	Valor	No.
0,000000417	22759	0,000007764	40	0,000017479	44
0,000000626	2506	0,000008196	10329	0,000017911	7
0,000001103	305	0,000008449	7	0,000018165	72
0,000001291	27	0,000008851	655	0,000019416	49
0,000001729	3516	0,000009708	299	0,000020072	11
0,000001907	77	0,000010103	1693	0,000020713	23
0,000002354	4761	0,000010356	42	0,000021398	93
0,000002623	841	0,000011005	262	0,000022665	45
0,000003234	104	0,000011414	2650	0,000023305	2
0,000003636	15980	0,000011683	58	0,000023946	66
0,000003844	1568	0,000012070	72	0,000024632	25
0,000003878	17	0,000012949	154	0,000025928	18
0,000004381	31	0,000013381	256	0,000027180	12
0,000004530	111	0,000013605	42	0,000027865	1
0,000004947	18893	0,000014246	118	0,000029147	7
0,000005156	33	0,000014663	113	0,000030398	1
0,000005573	1980	0,000014916	266	0,000033647	1
0,000006475	233	0,000016183	36	0,000000000	942677
0,000006884	13390	0,000016600	13	TOTAL DIFERENÇA	87615
0,000007093	402	0,000016838	19	% DA DIFERENÇA	9,2943
0,000007115	81				

Tabela 22 – Variação do valor e quantidade de pixel da diferença da RNA para AHP

AHP (No. PIXEL)			
Valor	No.	Valor	No.
0,000000002	2	0,000258982	10129
0,000000007	394	0,000259012	53
0,000000015	4579	0,000388384	1
0,000000030	6338	0,000388399	2
0,000129461	7369	0,000388414	1
0,000129467	74	0,000388429	39
0,000129469	98	0,000388436	25
0,000129476	2138	0,000388443	37
0,000129491	3459	0,000388473	12
0,000129499	27	0,000517875	6
0,000129506	784	0,000517890	5
0,000129521	264	0,000517897	24
0,000258923	198	0,000517905	36
0,000258934	90	0,000517935	2
0,000258937	203	0,000000000	942677
0,000258952	550	TOTAL DIFERENÇA	27594
0,000258967	1027	% DA DIFERENÇA	2,9272

Tomando como parâmetro de análise os resultados obtidos com as RNA's e o objetivo desta tese da verificação da qualidade dos modelos, é amplamente aceitável dizer que os modelos produzidos pelas RNA's comparados com os AHP e OPS levariam às mesmas interpretações, e então é possível afirmar que as previsões realizadas pela RNA foram de boa previsão e é possível aplicar essa metodologia para produção de mapa sintieses com boa confiabilidade.

A despeito das pequenas diferenças que ocorrem nos modelos na ordem de 10^{-5} a 10^{-7} são considerados nesta tese amplamente aceitáveis, dada a escala e destinação do objetivo deste estudo.

12. Considerações Finais

Nos últimos anos, é crescente a demanda por estudos aplicados que envolvam profissionais da geografia trabalhando em equipes multidisciplinares. Exemplos disso são os estudos de impactos ambientais (EIA), estudos de áreas de instabilidade, de fragilidade, de desigualdade ambiental e social etc.

Em todos esses estudos, são possíveis a aplicação de modelagens cartográfica e a construção de mapas sínteses, o que acrescentaria a esses estudos uma contribuição importante na compreensão dos fenômenos e casos estudados.

Por isso, é necessário que os geógrafos que atuam nesses projetos tenham o domínio e o entendimento da potencialidade que esses produtos cartográficos, mapas sínteses, podem trazer. Para isso, é imprescindível que se tenha o domínio das técnicas e processos metodológicos para o desenvolvimento desses produtos.

Os processos técnicos/metodológicos apresentados nesta tese são amplamente aplicáveis em diferentes áreas de estudos da Geografia, no sentido da obtenção, construção e interpretação de mapas sínteses.

Como apresentado aqui, independente da escolha do processo técnico/metodológico que será utilizado para a obtenção de um mapa síntese, que pode ser de uma forma mais simples ou mais complexa, a participação do pesquisador é diretamente decisiva no resultado do produto cartográfico, que é o mapa. E é ele que dará subsídio às futuras tomadas de decisão ou interpretação dos fenômenos estudados.

Além da importância da participação direta do pesquisador, outra questão importante é a escolha de qual processo técnico/metodológico deve ser adotado para desenvolvimento de um estudo. Esta tese pode indicar possíveis escolhas diferenciadas, relacionadas com o tipo de estudo a que será submetido o processo de criação de um mapa síntese.

É possível apontar alguns caminhos para essa escolha, se o estudo se encerra em si mesmo, ou seja, ele não tem intenção de ser replicado em outras situações/casos similares. É amplamente recomendado que se utilizem processos de álgebra de mapas. Esta tese apresenta duas opções para esse tipo de estudo, sendo expostos e desenvolvidos todos os procedimentos técnicos/metodológicos para o AHP e ou OPS como instrumento gerador de uma modelagem sintética.

Assim, a escolha para estes casos/estudos únicos é a construção de modelos baseados em uso da álgebra de mapas fundamentada em pesos e expressões.

Para o caso da aplicação do uso das redes neurais artificiais voltadas para a construção de modelos sínteses, elas poderiam ser amplamente utilizadas para os estudos em que as variáveis utilizadas para a análise de uma determinada situação/caso sejam similares, e poderiam ocorrer em outra área a ser estudada.

Portanto, a grande vantagem de se utilizar as redes neurais artificiais direcionadas para criação de mapa de síntese é a possibilidade de replicar os conceitos que estão embutidos nas RNA's para outras áreas.

Essa possibilidade contempla uma economia de tempo e investimento que são gastos para a criação do primeiro cenário avaliativo, e para a aplicação em novas áreas não seria mais necessário o parecer de um corpo de diversos especialistas que desenvolveram a avaliação do primeiro cenário.

Assim, ao utilizar os conceitos técnicos/metodológicos das RNA's para criar um mapa síntese e replicar a arquitetura neural em uma nova área, está se utilizando da natureza da RNA de poder ser treinada para realizar previsões a partir de exemplos. Isso daria a ela a possibilidade de guardar em si todo o conjunto de conhecimento dos especialistas que foi aplicado para a criação da primeira geração.

Assim, essa RNA poderia ser aplicada novamente em diversas outras áreas, sem o custo do desenvolvimento do capital humano despendido para o primeiro

cenário. Para a aplicação nessas novas áreas, bastaria se utilizar a arquitetura da RNA que foi desenvolvida e se obteria um mapa síntese para estes novos casos.

Isso teria como consequência imediata a economia de recursos financeiros e humanos altamente qualificados que seriam despendidos na primeira elaboração da RNA e não seriam mais necessários para as próximas áreas estudadas.

Podem ser citadas aplicações das RNA's na geografia física para a construção de modelos sínteses, por exemplo, na criação de áreas de risco, avaliação ambiental, diagnósticos ambientais, potenciais áreas de mineração, etc.

Um exemplo específico na geografia física seria uma RNA treinada para realizar previsões sobre áreas de risco de processos erosivos para o estado de São Paulo. A rede poderia ser aplicada para todos os municípios, o que forneceria um panorama para os gestores das áreas críticas para uma futura atuação.

Na geografia humana as RNA's também poderiam ser amplamente utilizadas, como exemplo, para serem aplicadas na identificação de áreas críticas, como a identificação de diferentes níveis de desigualdade social. Inicialmente criada e treinada uma RNA, baseada em temas relevantes para esse objetivo, essa rede poderia ser replicada nas diversas capitais brasileiras apontando as áreas com maior desigualdade social.

13. Bibliografia

AB'SABER, A. N. **Geomorfologia do Estado de São Paulo** in Aspectos Geográficos da Terra Bandeirante. Rio de Janeiro, IBGE, 1954.

ADANOLI, J.; MACEDO, J.; AZEVEDO, L. G.; NETO, J. M. Caracterização da Região de Cerrado. In: **Solos dos Cerrados** – tecnologia e estratégia de manejo. 1. Edição. GOERDT, Wenceslaw J. São Paulo: Nobel, Brasília: EMBRAPA, Centro de Pesquisas Agropecuárias dos Cerrados, 1986.

ALGARVE; ALMORACI S. **Algoritmos Genéticos** - Revisão da Teoria e Exemplo Didático Simples - GPEB – UFSC, 1994.

ALMEIDA, F. F. M.; BARBOSA, O. Geologia das quadrículas de Piracicaba e Rio Claro, Estado de São Paulo. In: **Boletim. Divisão Geologia e Mineralogia/DNPM**, São Paulo, n. 143, 96 p., 1953

ANDERSON, J. A. **An Introduction to Neural Networks**. Cambridge: The MIT Press, 1995.

ANTENUCCI, J.C. ; BROWN, K ; CROSWELL, P.L. ; KEVANY, M.J. ; ARCHER, H. **Geographic Information Systems: A Guide to the Technology**. New York: 1991.

BARRETO, Jorge Muniz. **Redes Neurais** - Fundamentos e Aplicações. 2º. Simpósio Brasileiro de Automação Inteligente, CEFET-PR: 1995.

_____. **Inteligência Artificial no Limiar do Século XXI**. 2. ed., Florianópolis: Duplic Edições, 1999.

BEALE, R.; JACKSON, T. **Neural Computing**. Bristol – UK: Institute of Physics Publishing, 1992.

BECKER, B. K.; EGLER, C. A. G. **Detalhamento da Metodologia para Execução do Zoneamento Ecológico-Econômico pelos Estados da Amazônia Legal**. Brasília: SAE-Secretaria de Assuntos Estratégicos/ MMA-Ministério do Meio Ambiente, 1996.

BÉDARD, Y.; T. MERRETT & J. HAN. Fundamentals of Spatial Data Warehousing for Geographic Knowledge Discovery, In : **Geographic Data Mining and Knowledge Discovery, Taylor & Francis**, Vol. Research Monographs in GIS, Chap. 3, pp. 53-73. 2001.

BERRY J.K. Cartographic Modeling: the analytical Capabilities of GIS In:GOODCHILD, M; PARKS, B. O.; STEYAEART, L.T. **Environmental modeling with GIS**. New York: Oxford University, 1993.

BOROUGHSHAKI, S.; MALCZEWSKI, J. 'Implementing an extension of the Analytical Hierarchy Process using Ordered Weighted Averaging operators with fuzzy quantifiers in ArcGIS'. **Computers and Geosciences** 24, pp. 399-410. 2007.

BURROUGH, P. A. **Principles of Geographic Information Systems for Land Resources Assessment**. Oxford: Oxford University Press, 1986.

BREGA, J.R.F. **A utilização de redes neurais artificiais em um sistema de gerencia de pavimentos**. Tese de Doutorado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 1996.

CÂMARA, G.; MEDEIROS, J. S. **Geoprocessamento para Projetos Ambientais**. Tutorial. São José dos Campos: INPE, 1996.

CÂMARA, G.; CASANOVA, M. A.; MEDEIROS, C. B.; HEMERLT, A.; MAGALHÃES, G. **Anatomia de Sistemas de Informação Geográfica**. Curitiba: Sagres Editora, 1997.

CÂMARA, G.; ORTIZ, M. J. Sistemas de Informação Geográfica para Aplicações Ambientais e Cadastrais: Uma Visão Geral. In: **Cartografia, Sensoriamento e Geoprocessamento**. Lavras: UFLA/SBEA, 1998.

CAUDILL, M. **Expert Network**. **Byte**. pp 108-116. October, 1991.

CLIFF, A. D. & ORD, J. K. **Spatial Process: Models and Applications**. London: Pion, 1981.

CHRISTOFOLETTI ; QUEIROZ NETO, J. P. A. Ação do escoamento superficial das águas pluviais na Serra de Santana (E. S. Paulo). In: **Boletim Paulista de Geografia**, São Paulo, n. 45, p. 59-71, 1968.

CYBENKO, P. G. Approximation by Superpositions of a Sigmoidal function. *Mathematics of Control, **Signals and Systems***, vol. 2 n°. 4, pp. 303-314. 1989.

_____. Continuous valued neural networks with two hidden layers are sufficient. **Technical Report**. Department of Computer Science, Tufts University, Medford, MA, 1988.

DANGERMOND, K. A. Classification of software components commonly used in geographic information systems. In: **Introductory Readings in Geographical Informations Systems**. Philadelphia: Taylor and Francis, pp.31-51. 1990.

DAYHOFF, Judith E. **Neural Networks Architectures**. New York: Van Nostrand Reinhold, 1992.

DE BIASI, M. DE A. Carta Clinográfica: os Métodos de Representação e sua Confecção. **Revista do Departamento de Geografia**. São Paulo: FFLCH, n°. 6, p.45-60, 1992.

DOUGHERTY, M. A review of neural networks applied to transport. **Transportation Research**, Part C, v.3, n. 4.1995.

DUARTE, E. **Geologia Ambiental da Área de São Pedro – SP**: Vetor Águas Subterrâneas –Tese de Doutorado – Instituto de Geociências da USP, São Carlos – SP: 1980.

EGENHOFER, M. Spatial SQL: A Query and Presentation Language. **IEEE Transactions on Knowledge and Data Engineering**, 6, pp. 86-95, 1994.

FERREIRA, F.R.B. **Modelagem de Parâmetros Morfométricos da Bacias em Sistemas de Informação Geográfica**. Dissertação de Mestrado, UNESP. Rio Claro: 2001.

FREEMAN, J. A.; SKAPURA, D. M. **Neural Network. Algorithms and Programming Techniques**. Addison- Wesley Pub. Co.; New York; 1991

GOMES, J.M.; VELHO, L. **Computação Visual**: Imagens. Rio de Janeiro: SBM, 1995.

GOODCHILD, F. M. A Spatial Analytical Perspective on Geographical Information Systems. **International Journal of Geographical Information Systems**, 1:pp. 327-334, 1987.

GOODCHILD, F. M.; PARKS O.B.; STEYAERT T.L. **Environmental modeling with GIS** – New York: Oxford University Press, pp. 488, 1993

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. **Neural Network Design**, Boston: PWS Publishing Company, 1996.

HASSOUN, M. H. **Fundamentals of Artificial Neural Networks**. Cambridge: The MIT Press, 1995.

HAYKIN, S. **Redes Neurais**: Princípios e Prática. 2. ed, Porto Alegre: Bookman, 2001.

_____. **Neural networks: a comprehensive foundation**. New York: Macmillan College Publishing Company, 1994.

HECHT-NIELSEN, R. **Neurocomputing**. San Diego: Addison-Wesley. 1989.

HERNANDEZ, E.D.M. Inteligência Computacional e Redes Neurais em Engenharia Elétrica – Material do Curso - **Práticas de Eletricidade e Eletrônica II** Seminário 2– São Paulo: Departamento de Engenharia Elétrica da USP, 2007.

HERTZ, J., KROGH, A.; PALMER, R., **Introduction to the Theory of Neural Computation**, Addison-Wesley, Redwood City, California, 1991.

HEWITSON, B. C.; CRANE, R. G. (ed). **Neural Nets**: Applications in Geography. Dordrecht: Kluwer Academic Publishers, 1994.

HOPFIELD, J.J. Neurons with a graded response have collective computational properties like those of two-state neurons. **Proc. of the National Academy of Science** of Sciences of the U.S.A., vol. 81, pp.3088-3092. 1984.

IPT INSTITUTO DE PESQUISAS TECNOLÓGICAS. **Mapa Geomorfológico do estado de São Paulo**, IPT (Série Monografia, 5). 2v. Escala 1:500.000, 1981 b.
KOHONEN, T. **Self-Organizing Maps**, Springer Verlag (Berlim), 2nd edition, 1997

LOVETT A. A. GIS for Environmental Decision Making In: **Innovations in SIG**. University of East Anglia, Norwich, England, UK, 2007.

LONGLEY A.P.; GOODCHILD F.M.; MAGUIRE J.D.; RHIND W.D. **Geographical Information Systems**: Principles, Techniques, Management and Applications. Second Edition, New Jersey: Abridget, 2005.

LUCENA, S.I. **Projeto de interfaces para álgebra de mapas em geoprocessamento no ambiente Spring**. Dissertação de Mestrado. São José dos Campos: INPE, 1998.

LUK, K.C.; BALL, J.E. e SHARMA, A. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. **Journal of Hydrology**, v.227, pp. 56-65. 2000.

MAGUIRE, D.; DANGERMOND, J. The Functionality of GIS. In: MAGUIRE, D.; GOODCHILD, M.; RHIND, D. (eds). **Geographical Information Systems**: Principles and Applications. New York: John Wiley and Sons, 1991.

MALCZEWSKI J. 'Multicriteria Decision Analysis for Collaborative GIS'. In: **Collaborative Geographic Information Systems**, New York ed. S. Balram and S. Dragicevic (Hershey: Idea Publishing), pp. 167-185. 2006.

MARTINES, R. M. **Inferência Geografias: O Processo analítico hierárquico e o Modelo Booleano ponderativo aplicado no diagnóstico da estabilidade ambiental do município de Itirapina**. Dissertação de Mestrado. São Paulo: Departamento de Geografia da USP – 2006.

NISHIYAMA, L. **Mapeamento Geotécnico Preliminar da Quadrícula de São Carlos**. Dissertação de Mestrado. São Carlos: DGS/EESC (USP), 1991.

NUNNARI, G.; NUCIFORA, A. F. M.; RANDIERI, C. The application of neural techniques to the modelling of time-series of atmospheric pollution data. **Ecological Modelling**, v.111, p.187-205. 1998.

OLIVEIRA, J. B.; PRADO, H. **Memorial Descritivo**. Levantamento pedológico semi-detalhado do Estado de São Paulo: quadrícula de São Carlos, II. Campinas: Instituto Agrônomo, 1984.

OPENSHAW, S.; **Artificial Intelligence in Geography**. Chichester: John Wiley & Sons Ltd., 1997.

_____. Neuroclassification of Spatial Data . In: HEWITSON, B. C.; CRANE, R. G. (eds.). **Neural Nets: Applications in Geography**. Dordrecht: Kluwer Academic Publishers, 1994.

PARK C. J., The distribution of weighted linear combinations of cell frequency counts: two samples from continuous distributions, In: **The Indian Journal of Statistics**, Volume 32, Séries A, Nebraska Pt. 2, pp. 225-232, 1970.

PENTEADO, M.M. **Geomorfologia do setor centro-oeste da depressão periférica paulista**. Tese de Doutorado (geografia física). UNESP. Rio Claro: 1968.

RUSSEL, S. J.; NORVIG, P. **Artificial Intelligence: a modern approach**. London, UK: Prentice Hal, 1995.

RICH, E.; KNIGHT. K. **Inteligência Artificial**. São Paulo: Makron Books, 1993.

SAATY, L. T. **Multicriteria Decision Making: The Analytic Hierarchy Process**, Vol. 1, AHP Series, New York RWS Publications, 502p.1990.

SMITH, T.; PEUQUET, D.; MENON, S.; AGAEWAL, P. KBGIS-II, a Knowledge-Based Geographical Information System. **International Journal of Geographical Information Systems**. Vol 1. n. 2, pp. 149-172. 1987.

SIMIÃO S. M. **Banco de dados geográficos e redes neurais artificiais: tecnologias de apoio a gestão do território**. Tese de Doutorado. São Paulo: Departamento de Geografia da USP, 1999.

SILVA, M.A.S. **Mapas Auto-Organizáveis na Análise Exploratória de Dados Geoespaciais Multivariados**. Dissertação de Mestrado. São José dos Campos: INPE, 2004.

SPRING: Integrating remote sensing and GIS by object-oriented data modelling Camara G, Souza RCM, Freitas UM, Garrido J Computers & Graphics, 20: (3) 395-403, May-Jun 1996.

TEIXEIRA, A. L. A.; MORETTI, E.; CHRISTOFOLETTI, A. **Introdução aos Sistemas de Informação Geográfica**. Rio Claro – São Paulo: ed. de Autor, 79p., 1992.

TOMLIN, D. **Geographic Information Systems and Cartographic Modeling**. New York: Prentice Hall, 1990.

TUBB, N.R. A development path to sucess in neural computing. **Expert Systems Applications**, v.9, n.5 , p.5-9.1993.

VENTURIERI, A. **Utilização da Segmentação de Imagens e Lógica Nebulosa para Treinamento de uma Rede Neural Artificial na Caracterização de Classes de Uso da Terra na Região de Tucuruí (PA)**. Dissertação de Mestrado. São José dos Campos: INPE, 1995.

WINTER, K.; HEWITSON, B. C. Self Organizing Maps – Application to Census. In: HEWITSON, B. C.; CRANE, R. G. (eds). **Neural Nets**: Applications in Geography. Dordrecht: Kluwer Academic Publishers, 1994.

WORBOYS, M. **GIS: A Computing Perspective**. London: Taylor and Francis, 1995.

XAVIER-DA- SILVA, J. **Geoprocessamento para análise ambiental**. Rio de Janeiro: 2001.

ZAIDAN, R. T.; XAVIER-DA-SILVA, J. **Geoprocessamento e Análise Ambiental: aplicações**. Rio de Janeiro: Bertrand Brasil, 2004.

ZELL, A.; MAMIER, G.; VOGT, M.; MACHE, N.; HÜBNER, R.; DÖRING, S. *et al.* **Stuttgart Neural Net Simulator** - User Manual, Version 4.1. Stuttgart: IPVR - University of Stuttgart. 1991.