

UNIVERSIDADE ESTADUAL PAULISTA  
Instituto de Geociências e Ciências Exatas  
*Campus de Rio Claro*

GEOPROCESSAMENTO E COMPUTAÇÃO INTELIGENTE:  
POSSIBILIDADES, VANTAGENS E NECESSIDADES

Carlos José de Almeida Pereira

Orientadora:  
Prof.<sup>a</sup> Dr.<sup>a</sup> Lucia Helena de Oliveira Gerardi

Tese de Doutorado elaborada junto ao Programa de  
Pós-Graduação em Geografia para obtenção do  
título de Doutor em Geografia.

Rio Claro (SP)  
2008

910.0285 Pereira, Carlos José de Almeida

P436g      Geoprocessamento e computação inteligente :  
possibilidades, vantagens e necessidades / Carlos  
José de Almeida Pereira. – Rio Claro : [s.n.], 2008  
193 f. : il., tabs., figs.

Tese (doutorado) – Universidade Estadual Paulista,  
Instituto de Geociências e Ciências Exatas  
Orientador: Lucia Helena de Oliveira Gerardi

1. Geografia – Programas de computador. 2. Sistemas de  
informação geográfica. 3. Lógica nebulosa. 4. Redes  
neurais. 5. Análise espacial. I. Título.

Ficha Catalográfica elaborada pela STATI – Biblioteca da UNESP  
Campus de Rio Claro/SP

## **COMISSÃO EXAMINADORA**

Prof. Dra. Lucia Helena de Oliveira Gerardi  
Orientadora

Prof. Dra. Dulce Consuelo Andreatta Whitaker

Prof. Dr. João Francisco de Abreu

Prof. Dr. Lindon Fonseca Matias

Prof. Dra. Mônica Giacomassi de Menezes de Magalhães

Carlos José de Almeida Pereira  
Aluno

Rio Claro, SP, 24 de novembro de 2008.

Resultado: **A P R O V A D O**

## DEDICATÓRIA

Dedico este trabalho aos grandes mestres que tive a honra e o prazer de encontrar ao longo da minha vida, e que tanto me ensinaram, inspiraram e motivaram, desta forma contribuindo para que eu completasse mais esta etapa:

- Professor Sylvio, do Colégio Pentágono, onde fiz parte do ensino básico (“primeiro grau”), no período de 1981 a 1984. Sua voz inconfundível transformou a matemática em música para meus ouvidos, e com seu carinho se tornou para mim um modelo de professor e principalmente de ser humano;
- Professor Sérgio Villié (o “titi”), da Associação Educacional Veiga de Almeida (agora Universidade Veiga de Almeida), onde fiz minha graduação no período de 1988 a 1990. Sua estatura física é diretamente proporcional a sua qualidade como professor e como ser humano. Nunca me esquecerei da sua tranquilidade ao falar e do seu carinho no trato dentro e fora da sala de aula;
- Mário Moutinho Duarte, programador visual aposentado do serviço público federal (atuou no IPEA, no BNDES e diretamente com o Ministro do Planejamento), artilheiro dos “veteranos do zumbi”, e como se não bastasse, Vascaíno! Profissionalmente, um exemplo de seriedade, criatividade, e especialmente de valorização do trabalho (perdi a conta das “brincas” que ele me deu porque eu não sabia dar preço no meu trabalho... quando eu finalmente estipulava um preço, ele aceitava, e no final pagava no mínimo o dobro!). Mais do que isso, um exemplo de vida e de ser humano, um amigo que me apoiou em um grande momento de dificuldade da minha vida.
- E por fim, mas não menos importante, à Professora Lucia Helena de Oliveira Gerardi, exemplo de seriedade e dedicação. Mesmo após uma longa carreira de contribuições à UNESP (incluindo a direção de uma unidade universitária), continua como aposentada dando sua colaboração voluntária à frente da AGETEO (Associação de Geografia Teórica) e à formação de novos pesquisadores, através da orientação de alunos no programa de pós-graduação em Geografia da UNESP de Rio Claro.

Se este programa de pós-graduação hoje tem um espaço físico onde conduzir suas atividades, isto se deve ao idealismo da Prof. Lucia, conforme atesta homenagem afixada numa de suas paredes:

*Este prédio, alicerçado no seu sonho, tem seus ideais misturados à sua argamassa, tem suas vigílias em seus tijolos, tem sua coragem em suas paredes, tem sua luta em sua concretude, e tem a nossa homenagem a você Prof. Lucia aqui gravada para sempre.*

Gravada aqui, também. Para sempre.

A todos, minha reverência.

## AGRADECIMENTOS

À minha orientadora, Profa. Lucia Helena de Oliveira Gerardi, pela sua orientação firme e precisa, e especialmente pelo seu apoio. Se consegui chegar ao final deste trabalho, devo em grande parte por sua aceitação ao desafio de orientar um aluno que reside a mais de 1300 km de distância;

A Mário César Schössler Barboza, pelas valiosas dicas sobre as redes neurais de Kohonen e sobre o método de Ward para agrupamento hierárquico;

À Inajara Federsom de Moraes (no “primeiro tempo”) e Ubirajara Gerardim Junior (no “segundo tempo”), pelo apoio administrativo direto do prédio da pós-graduação em Geografia;

À equipe da seção de pós-graduação do IGCE: Eliana Corrêa Contiero, Mariê Uehara Stein, Sandra Regina Cônego Minatti Sartori, Thalita Meireles Hilsdorf e Vivian Meireles Coelho, por todo apoio administrativo;

A Bruno Boaventura, da *GNOME foundation*, pelas dicas de uso da biblioteca GTK;

A Marcelo Cunha Santos, pelos artigos preciosos que me disponibilizou através de seu acesso privilegiado na Suécia;

À Ísis Agarez, pelo auxílio na tradução do resumo;

A Enivaldo Freire do Ó Filho, Eric Silva Abreu, Gilberto Ribeiro de Queiroz, Lúbia Vinhas e Mario Rocco Pettinati, do INPE, pelo apoio na utilização da biblioteca TerraLib;

A Ed Fisher, pela permissão de uso da imagem que serviu de base para a tela de entrada do software GAIA;

A Mário Moutinho Duarte, pela montagem gráfica que resultou na belíssima ilustração que compõe a tela de entrada do software GAIA;

Ao colega de doutorado Thiago Salomão de Azevedo (Bizzu), pela hospedagem em Rio Claro (na sua casa bem-assombrada, onde os cobertores se materializam do nada no meio de uma noite fria...);

Ao colega de doutorado Rubens Hardt, pelas impressões de versões preliminares deste texto para entrega a minha orientadora, economizando assim alguns envios por SEDEX;

A Renato Russo, Blues Brothers, INXS, Rolling Stones, Supertramp, Beatles, Guns n'Roses e Jean Michel Jarre pela trilha sonora;

E, principalmente, à Elis, minha companheira de vida, por tudo:

*“Diante da vastidão do espaço e da imensidade do tempo, é uma  
alegria para mim partilhar um planeta e uma época com Elis”*

*(adaptado da dedicatória de “Cosmos”, Carl Sagan)*

*“Não é o fim da Geografia mas sim o início de uma nova era onde máquinas inteligentes trabalham como extensão da criatividade e das habilidades tradicionais dos geógrafos, levando a abordagem de novas e antigas questões para um patamar mais elevado de realização do que o que era possível anteriormente.”*

Stan & Christine Openshaw,  
“Artificial Intelligence in Geography”, tradução do autor.

## RESUMO

As técnicas de análise de dados e de busca de soluções fornecidas pela Computação Inteligente tiveram, nos últimos tempos, um grande avanço em seu desenvolvimento. Essas técnicas têm sido utilizadas com eficácia e eficiência no tratamento de problemas complexos e/ou que possuam uma grande quantidade de dados a serem processados. A integração destas técnicas com as ferramentas computacionais de produção e análise de informações geográficas (Geoprocessamento) é, portanto, muito vantajosa, especialmente com relação à grande quantidade de dados geralmente envolvida nas questões de natureza espacial. Este trabalho apresenta dois exemplos de uso de técnicas de Computação Inteligente em procedimentos de produção e análise de informações geográficas: um Sistema de Raciocínio Nebuloso (baseado na Lógica Nebulosa) para a construção de um mapa de fertilidade de solos, e uma Rede Neural Artificial para a identificação de agrupamentos espaciais em dados sócio-econômicos. Os dois exemplos foram conduzidos utilizando-se um software especialmente construído para esta finalidade, denominado GAIA – Geoprocessamento Apoiado por Inteligência Artificial –, e que doravante está disponível como Software Livre para qualquer pesquisador interessado em utilizar estas ferramentas. O estudo conclui que o uso das técnicas provenientes da computação inteligente, em comparação com técnicas tradicionais de análise de dados, contribuiu para um aumento da qualidade dos resultados obtidos.

Palavras-chave: Geoprocessamento; Computação Inteligente; Inteligência Artificial; Lógica Nebulosa; Redes Neurais Artificiais.

## ABSTRACT

Data analysis and problem solving techniques supplied by Soft Computing have had, lately, a great advance in their development. These techniques have been used with effectiveness and efficiency to deal with complex problems and/or problems that have too much data to be processed. The integration of such techniques with the tools for computational geographic information analysis (Geocomputation) is therefore very advantageous, especially in relation to the great quantity of data normally involved in spatial matters. This study presents two examples on how to use Soft Computing techniques in conjunction with geographic information analysis procedures: a Fuzzy Reasoning System (based on Fuzzy Logic) to build a soil fertility map, and an Artificial Neural Network to identify spatial clusters in socio-economic data. Both examples were conducted using a software specifically developed towards this objective, called GAIA - Artificial Intelligence Supported Geocomputation, from now on available as a Free Software to any interested researcher. The study arrives at the conclusion that the use of soft computing techniques, as compared to classical procedures, leads to an increased quality on the final results.

**Keywords:** Geocomputation; Soft Computing; Artificial Intelligence; Fuzzy Logic; Artificial Neural Networks.

## LISTA DE FIGURAS

	Página
Figura 1: Representação de variáveis geográficas através de camadas .....	22
Figura 2: Representações baseadas em superfícies .....	24
Figura 3: Exemplo de SIG integrando localização e atributos .....	28
Figura 4: Arquitetura básica de um SIG .....	32
Figura 5: Informação geográfica temática .....	33
Figura 6: Informação geográfica numérica .....	34
Figura 7: Informação geográfica do tipo imagem .....	35
Figura 8: Informação geográfica do tipo cadastral .....	35
Figura 9: Informação geográfica do tipo rede .....	36
Figura 10: Representação computacional da letra 'A' .....	37
Figura 11: Deixou de ser a letra 'A' ? .....	38
Figura 12: Níveis hipotéticos de reconhecimento de uma letra 'A' por uma Rede Neural Artificial .....	39
Figura 13: Integração entre o GAIA, o TerraView e a TerraLib .....	52
Figura 14: Onde termina o vermelho? Onde começa o amarelo? .....	55
Figura 15: Comparação entre as teorias de conjuntos: clássica e nebulosa .....	58
Figura 16: Pontos, propriedades químicas e limites do estado de Santa Catarina .....	62
Figura 17: Grade regular gerada pelo GAIA para a propriedade química alumínio .....	63
Figura 18: Grade regular recortada usando os limites do Estado .....	64
Figura 19: Classes para a propriedade química “Alumínio trocável” .....	65
Figura 20: Conjuntos nebulosos hipotéticos para a propriedade química “Alumínio” .....	66
Figura 21: Vários tipos de conjuntos definidos a partir de quatro parâmetros .....	67
Figura 22: Conjunto nebuloso AL_muito_pouco .....	68
Figura 23: Conjunto nebuloso AL_pouco .....	68
Figura 24: Conjunto nebuloso AL_medio .....	69
Figura 25: Conjunto nebuloso AL_muito .....	69
Figura 26: Classes de fertilidade através do método convencional .....	70
Figura 27: Conjuntos nebulosos para as classes de fertilidade do solo .....	71
Figura 28: Classes de fertilidade do solo processadas através da lógica nebulosa .....	73
Figura 29: Mapeamento temático da grade resultante do sistema de inferência nebuloso ...	74
Figura 30: Um neurônio biológico .....	76
Figura 31: Uma rede de neurônios .....	77
Figura 32: Um neurônio artificial .....	78
Figura 33: Uma RNA com quatro camadas .....	79
Figura 34: Um mapa auto-organizável de Kohonen .....	82
Figura 35: Localização do córtex cerebral .....	84
Figura 36: Uma RNA SOM treinada .....	85

Figura 37: Visualização das distâncias (diferenças) entre os pesos dos neurônios de uma RNA SOM já treinada .....	87
Figura 38: Configuração espacial do IDH-M no Estado de São Paulo .....	90
Figura 39: Configuração espacial do IDH-M, com significância estatística .....	91
Figura 40: Malha municipal brasileira, inserida no TerraView .....	92
Figura 41: Malha municipal do Estado de São Paulo .....	92
Figura 42: Malha municipal do Estado de São Paulo já com valores componentes do IDH-M inseridos .....	93
Figura 43: Tela de configuração do módulo RNA do GAIA .....	94
Figura 44: Colunas geradas pelo módulo RNA do GAIA .....	97
Figura 45: Mapeamento automático da coluna “grupo01” .....	98
Figura 46: Características dos grupos identificados no processamento .....	99
Figura 47: Mapa temático dos grupos de IDH-M .....	100
Figura 48: Mapa de centróides gerados pelo GAIA .....	101
Figura 49: Características dos grupos identificados no processamento realizado usando as coordenadas dos centróides como dados de entrada .....	102
Figura 50: Mapa temático dos grupos formados pelos valores do IDH-M e das coordenadas dos centróides .....	104
Figura 51: Campi da UNESP com Ciências Biológicas .....	105
Figura 52: Campi da UNESP com Ciências Biológicas, em relação à configuração espacial do IDH-M no Estado de São Paulo identificada com o módulo RNA do GAIA .....	106
Figura 53: Características dos grupos identificados no processamento realizado usando os dados provenientes do SEADE .....	108
Figura 54: Mapa temático dos agrupamentos - dados do SEADE .....	109

## LISTA DE QUADROS E TABELAS

	Página
Quadro 1: Evolução histórica do desenvolvimento teórico e prático dos SIGs .....	29
Tabela 1: Definição química das classes de fertilidade do solo .....	59
Tabela 2: Comparação entre resultados de agrupamentos obtidos através de RNAs e análise fatorial .....	113

## SUMÁRIO

	Página
1. INTRODUÇÃO .....	13
1.1. Computação precisa e repetitiva .....	15
1.2. Crescente disponibilidade de informações geográficas .....	16
1.3. Métodos matemáticos e estatísticos complexos .....	16
1.4. Computação inteligente: uma alternativa .....	17
2. FUNDAMENTAÇÃO TEÓRICA .....	20
2.1. Espaço geográfico e suas representações computacionais .....	20
2.2. Geoprocessamento e Sistemas de Informação Geográfica .....	27
2.3. Computação inteligente .....	37
2.4. <i>Software</i> livre .....	41
2.5. Computação Inteligente e Geoprocessamento: Um panorama das ferramentas disponíveis .....	43
3. GEOPROCESSAMENTO E COMPUTAÇÃO INTELIGENTE .....	50
3.1. Ferramentas utilizadas no desenvolvimento do software GAIA .....	51
3.2. Lógica Nebulosa .....	54
3.2.1. Fundamentação teórica .....	54
3.2.2. Aplicação .....	61
3.3. Redes Neurais Artificiais .....	76
3.3.1. Fundamentação teórica .....	76
3.3.2. Aplicação .....	88
3.4. Aplicabilidade das técnicas apresentadas .....	114
4. CONSIDERAÇÕES FINAIS .....	117
5. BIBLIOGRAFIA .....	120
6. ANEXOS	
Anexo A DOCUMENTAÇÃO TÉCNICA DO GAIA .....	128
A.1. Fluxograma .....	129
A.2. Mensagens .....	137
A.3. Descrição das telas e seus objetos gráficos .....	143
A.4. Passo-a-passo de utilização do GAIA para reprodução dos exemplos apresentados no texto.....	167
Anexo B DESCRIÇÃO DAS VARIÁVEIS DA FUNDAÇÃO SEADE .....	184
Anexo C APRENDIZADO DE UM NEURÔNIO ARTIFICIAL .....	186

## Capítulo 1 INTRODUÇÃO

No âmbito das atividades científicas, as noções de “teoria” e “modelo” estão diretamente relacionadas aos processos construtivos que tornam possível descrever e explicar os fenômenos da realidade (DELATTRE, 1992, p.223).

É impossível para o ser humano a compreensão total e completa dos fenômenos com os quais tem contato. Isto significa que, nas nossas tentativas de compreensão da realidade, estamos sempre construindo modelos simplificados. A partir do estudo do comportamento deste modelo, tentamos inferir aproximadamente o comportamento da própria realidade. Os modelos, portanto, respousam sobre uma analogia, um sistema de relações entre seus termos e as entidades do mundo que se pretende representar.

Neste processo de construção de modelos, temos contato com os fenômenos da realidade das mais diversas formas, através da observação direta ou acessando registros das observações realizadas por outrem. Seja qual for o caso, essas observações são registradas e se nos apresentam na forma de dados e informações. São esses dados, portanto, que se constituem na matéria-prima básica de qualquer esforço científico de compreensão da realidade, permitindo a construção dos modelos.

Sendo o objeto de estudo da Geografia o espaço físico e as relações humanas, econômicas e sociais que se estabelecem nesse espaço, os dados relativos a esse objeto de estudo são as informações geográficas. Entendemos a informação geográfica para além de uma abordagem quantitativa e/ou cartográfica, englobando todo tipo de dado de característica quantitativa ou qualitativa georeferenciável (JULIÃO, 1999, p.99). Ou seja, informação sobre objetos ou fenômenos da realidade que estão associados a uma localização relativa na superfície da Terra. O trabalho do Geógrafo, na busca pelo conhecimento e entendimento do

espaço geográfico, passa pelo estabelecimento de objetivos e hipóteses e, conseqüentemente, pela coleta dos dados mais relevantes para testá-las (GERARDI; SILVA, 1981, p.1).

Trata este trabalho de métodos e técnicas para auxiliar o Geógrafo em sua atividade de produção e análise de informações geográficas. Em um primeiro momento, se insere na corrente do pensamento geográfico denominada de Geografia Quantitativa ou Teorético-Quantitativa, mas não se restringe a ela, como veremos posteriormente (um Sistema de Inferência Nebuloso, por exemplo, consegue trabalhar com noções tais como “pequeno”, “grande”, “alto”, “baixo”, possibilitando uma maior qualificação de dados quantitativos).

A Geografia Quantitativa tem por base a aplicação do método hipotético-dedutivo que, em termos gerais, consiste na proposição de uma teoria e o posterior processo de tentar refutar/validar essa teoria a partir das observações (dados e informações) relativas ao fenômeno sendo estudado:

A lógica subjacente ao método hipotético-dedutivo é a de que existe uma realidade externa à nossa existência, e esta realidade pode ser capturada (ainda que de forma aproximada) utilizando os princípios da lógica e da matemática. Através de estudo e análise, os fenômenos podem ser explicados através de teorias científicas, que devem ser passíveis de experimentação e portanto, de refutação (POPPER, 1975 apud CÂMARA et al, 2003, p.86).

Nesta perspectiva, o espaço geográfico é estudado a partir de modelos construídos de forma teórica e validados (a partir da busca de sua refutação) com dados relativos a esse espaço (informações geográficas), a partir de técnicas matemáticas e/ou estatísticas. A partir do uso de computadores neste processo podemos falar em Geoprocessamento, que, como conceituam Câmara e Davis (2001, p.1), “denota a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica”.

Porém apenas a combinação de métodos matemáticos e estatísticos, executados em ambiente computacional, não é suficiente para dar conta de processar e encontrar soluções em vários tipos de aplicações devido a uma série de fatores, como descreveremos nas seções a seguir.

### 1.1. Computação precisa e repetitiva

Os computadores tiveram e continuam tendo uma grande evolução em suas capacidades (quantidade de memória, velocidade de processamento, entre outras características)<sup>1</sup>.

Toda essa capacidade tem aplicação imediata na automação de tarefas bem definidas, determinísticas e que não exigem inteligência ou criatividade para serem executadas. Os programas de computador (*software*) criados para esse fim são baseados em uma sequência fixa de passos, que será executada em uma alta velocidade para se chegar ao resultado final único e precisamente definido. Por exemplo, a tarefa manual de buscar uma “ficha de dados” em uma gaveta de um armário de aço (“arquivo”, no sentido não-computacional) segue um conjunto fixo de passos:

- olhar uma ficha;
- se é a ficha procurada, retirar da gaveta. Fim do processo;
- se não é a ficha procurada, olhar a próxima ficha;
- reiniciar o processo.

*Mutatis mutandis*, a busca de um registro em um banco de dados computacional com milhões de registros armazenados segue a mesma sequência de passos, apenas executada mais velozmente em uma “gaveta virtual” milhões de vezes maior.

A dificuldade surge, obviamente, quando o problema que queremos estudar não puder ser expresso por uma sequência bem definida de passos, que leve diretamente a uma solução final única e determinística. Por exemplo,

[...] you can use a statistical technique to test an explicitly formulated a priori hypothesis but you cannot easily use the same statistical method to help you to define, or even define for you, which hypothesis you should be testing. **If you do not know or have no hypothesis to test then the best hypothesis-testing technology in the world is useless<sup>2</sup>** (OPENSHAW; OPENSHAW, 1997, p.3, grifo nosso)

1 Uma analogia bastante conhecida no meio dos profissionais de informática diz que se os automóveis tivessem tido a evolução que os computadores tiveram, hoje um Mercedes-Benz custaria apenas algumas dezenas de Reais e teria a capacidade de rodar 1000 Km com apenas 1 litro de gasolina.

2 “ [...] pode-se usar uma técnica estatística para testar uma hipótese formulada a priori, mas não se pode usar facilmente a mesma técnica para ajudar a definir, ou mesmo definir totalmente para você, qual hipótese testar. **Se você não sabe ou não tem uma hipótese para testar, então a melhor tecnologia de teste de hipóteses disponível no mundo é inútil**” (tradução do autor; grifo nosso).

É muito fácil obter, do banco de dados que registra as vendas diárias de um grande supermercado, respostas para perguntas do tipo “qual bebida foi comprada pelas pessoas que compraram macarrão?” (é a mesma sequência de passos que vimos para procurar uma ficha na gaveta de um arquivo). Porém como fazer para que o banco de dados nos mostre, sem uma pergunta prévia, quais as relações escondidas nos dados ?

### 1.2. Crescente disponibilidade de informações geográficas

De forma análoga ao constante crescimento das capacidades de armazenamento e processamento de informações dos sistemas computacionais, também observamos um crescimento (mais ainda, uma aceleração do crescimento) do conjunto de dados disponíveis, em especial de informações geográficas. O que se observa é que a nossa capacidade de coletar, armazenar e gerenciar informações sobre a realidade excede em muito nossa habilidade de processar estes dados. Esta situação já era uma preocupação em 1981:

[...] face ao geralmente grande volume de dados com que o geógrafo se defronta, aparece a necessidade de utilizar meios que tornem a massa de informações mais facilmente manipulável e compreensível, meios estes que são propiciados pela análise quantitativa que, de maneira objetiva, permite a verificação das relações entre os fenômenos estudados e sua distribuição no espaço (GERARDI; SILVA, 1981, p.1).

### 1.3. Métodos matemáticos e estatísticos complexos

Alguns métodos matemáticos e estatísticos exigem, daqueles pesquisadores interessados em seus resultados, um conhecimento profundo da teoria por trás desses métodos, nem sempre disponível, como novamente nos falam Gerardi e Silva (1981, p.1), “[...] livros estatísticos são normalmente de difícil acesso aos geógrafos uma vez que o enfoque deles é bem diferente, além do problema de que, de modo geral, o geógrafo não tem sólida base matemático-estatística”.

Tomemos como exemplo a construção de um modelo para estudar fluxos (de pessoas, dinheiro, veículos, etc). Um exemplo de modelo deste tipo estabelece que o fluxo entre dois locais quaisquer depende dos tamanhos desses locais e da distância (ou custo envolvido no fluxo) entre esses locais (OPENSHAW; OPENSHAW, 1997, p.173):

$$T_{ij} = O_i D_j B_j e^{(-bC_{ij})}$$

Onde:

$T_{ij}$  = fluxo entre os locais i e j

$O_i$  = tamanho da origem (local i)

$D_j$  = tamanho do destino (local j)

$B_j$  = fator de equilíbrio para garantir que as restrições do modelo sejam respeitadas

$e$  = número de Euler (2,718...)

$C_{ij}$  = distância ou custo entre os locais i e j

$b$  = parâmetro a ser estimado

Temos alguns valores conhecidos de  $O_i$  e  $D_j$  e o valor  $T_{ij}$  correspondente (informações geográficas obtidas através da mensuração da realidade). Queremos pois estimar (calcular, descobrir) o valor de  $b$  de modo que seja gerado o menor erro possível quando se utiliza o modelo (a fórmula) com os valores conhecidos de  $O_i$ ,  $D_j$  e  $T_{ij}$ . Quando calcularmos este valor ótimo de  $b$ , podemos admitir que temos um modelo que descreve com uma certa aproximação o que acontece na realidade (isto é, como funciona o fluxo entre quaisquer locais i e j).

Para estimar o valor de  $b$ , podemos usar métodos convencionais (matemáticos/estatísticos). Porém como se trata de um modelo não-linear, este cálculo irá exigir do pesquisador um grande conhecimento desses métodos matemáticos ou estatísticos, tornando assim difícil o uso desta (e de muitas outras) útil ferramenta de análise por um grande número de pesquisadores.

#### 1.4. Computação inteligente: uma alternativa

Como contornar as dificuldades apresentadas nas seções anteriores? Como afirmam Gerardi e Silva (1981, p.2), “o desenvolvimento dos métodos matemáticos e estatísticos na Geografia não está terminado. Eles se aperfeiçoam cada dia mais”. Este trabalho propõe, nesse sentido, a adoção de métodos e técnicas de análise de dados da Computação Inteligente no âmbito dos estudos geográficos.

Computação Inteligente denomina um conjunto de técnicas computacionais cuja construção e/ou forma de funcionamento tenta reproduzir o comportamento humano ou de outros seres vivos da natureza em procedimentos de processamento e análise de dados.

As técnicas de análise de dados e de busca de soluções fornecidas pela Computação Inteligente (busca heurística, sistemas especialistas, redes neurais artificiais, algoritmos genéticos, sistemas de inferência nebulosa, entre outros) tiveram, nos últimos tempos, um grande avanço em seu desenvolvimento.

Essas técnicas têm sido utilizadas com eficácia e eficiência no tratamento de problemas complexos e/ou que possuam uma grande quantidade de dados a serem processados, sendo capazes de encontrar uma solução “satisfatória” para problemas que antes não possuíam nenhuma solução possível. A utilização dessas técnicas pela Geografia, especialmente em procedimentos de produção e análise de informações geográficas é, portanto, muito vantajosa, especialmente com relação à grande quantidade de dados geralmente envolvida nas questões de natureza espacial e que tem sido disponibilizada com o advento das modernas tecnologias de aquisição e transmissão de dados.

Portanto, buscar formas de operacionalizar a integração entre as técnicas de Computação Inteligente e as ferramentas computacionais utilizadas nos procedimentos de produção e análise de informações geográficas (Geoprocessamento) se constitui em um amplo campo de pesquisa.

O objetivo deste trabalho é, portanto, trazer as técnicas e métodos da Computação Inteligente para o âmbito da pesquisa geográfica, em especial para auxiliar na condução de procedimentos de produção e análise de informações geográficas, apresentando:

- comparações entre os resultados de procedimentos de análise da informação geográfica obtidos através de métodos tradicionais e de métodos que utilizem técnicas provenientes da Computação Inteligente. Serão avaliados também a complexidade inerente a cada método, bem como suas desvantagens e limitações;
- o desenvolvimento de novas ferramentas de geoprocessamento que já tragam embutidos e integrados os métodos e técnicas da Computação Inteligente. A idéia principal aqui não é construir “mais uma” ferramenta computacional, mas sim construir uma ferramenta que esteja inserida especificamente no contexto de trabalho dos Geógrafos e de quaisquer outros pesquisadores envolvidos com a temática espacial. O que se busca é uma ferramenta computacional adaptada ao pesquisador que irá utilizá-la, e não exigir o contrário!

Ou seja, a proposta deste trabalho é mais do que a simples disponibilização e/ou adaptação de ferramentas computacionais para utilização no âmbito da pesquisa geográfica. O que se busca principalmente é mostrar as possibilidades de aproximação entre a Geografia e a Computação, a partir de exemplos concretos, estabelecendo assim um paradigma para um trabalho científico multidisciplinar para compreensão dos fenômenos de natureza espacial.

Para atingir o objetivo apresentado, este trabalho se organiza da seguinte forma:

No capítulo 2 serão apresentados os conceitos básicos e a fundamentação teórica necessária para o completo entendimento dos métodos e técnicas aqui expostos: Espaço Geográfico, Computação Inteligente e Processamento de Informações Geográficas. Será também apresentada uma breve discussão sobre como a Computação Inteligente pode contribuir para o processamento de informações geográficas, com base em alguns exemplos reais de pesquisas que utilizam estas ferramentas.

O capítulo se encerra apresentando o conceito de *Software* Livre que guiará todo o desenvolvimento de *software* realizado no âmbito deste trabalho, acompanhado de uma pequena discussão sobre o porque deste autor considerar que esta filosofia de desenvolvimento e disponibilização de *software* é um requisito fundamental em ambientes educacionais e de pesquisa científica.

O capítulo 3 abordará os métodos e técnicas da Computação Inteligente que serão analisados: Lógica Nebulosa e Redes Neurais Artificiais. Para cada técnica, serão apresentados:

- breve fundamentação teórica;
- exemplos de aplicações da técnica em procedimentos de produção e análise da informação geográfica. Neste item serão apresentadas comparações entre o grau de complexidade envolvido com o uso das ferramentas tradicionais (matemáticas/estatísticas) e o uso da Computação Inteligente e entre a qualidade dos resultados obtidos a partir de cada técnica. Também será apresentado o desenvolvimento e os testes de um protótipo de *software* que trabalhe de forma integrada a temática espacial a a técnica de computação inteligente em questão.

Encerra-se este trabalho no capítulo 4 tecendo-se alguns comentários à guisa de considerações finais.

## Capítulo 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1. Espaço geográfico e suas representações computacionais

O espaço é um dos principais, senão o principal, conceito-chave da Geografia. Junto com as noções de paisagem, região, lugar e território, forma a base conceitual sobre a qual esta ciência estuda a sociedade, em especial a ação humana modelando a superfície da Terra (CORRÊA, 1995, p.16). Se vamos utilizar sistemas computacionais para processar e analisar informações que tem o espaço como substrato (informações geográficas), precisamos saber como representar computacionalmente este conceito e também quais são as limitações impostas por esta representação. Mais ainda, temos na Geografia várias abordagens para o conceito de espaço, conforme a corrente do pensamento geográfico adotada. Quais são, portanto, as possibilidades de representação computacional e as limitações advindas dessas representações, relativas a cada abordagem do conceito?

Esta questão é discutida por Câmara, Monteiro e Medeiros (2003). Para estes autores é necessário o estabelecimento de um conjunto de conceitos teóricos para a consolidação do que denominam de “Ciência da Geoinformação”<sup>3</sup>. Nessa linha, os autores consideram que o fundamento básico desta ciência é a construção de representações computacionais do espaço, ou seja, a utilização de computação (*hardware* e principalmente *software*) como ferramentas de representação da realidade.

Apesar da palavra “ferramenta” estar sendo usada aqui, não devemos diminuir a importância de relacionar esta ação de representação da realidade com os conceitos com base

---

<sup>3</sup> Este termo aparece também em artigo de Goodchild (2003), como *Geographic Information Science*, denominação que provocou reações. Apesar disso o termo parece ter sido aceito, já que a principal revista geográfica dos Estados Unidos (*Annals of American Geographers*) usa esse termo para denominar uma de suas quatro áreas editoriais (CARVALHO; SILVA, 2006, p.54).

nos quais estudaremos esta mesma realidade, bem como de identificar as limitações da ferramenta perante este conceito. A Hipótese da Relatividade Linguística “propõe que o pensamento é relativo à linguagem na qual é conduzido” (BERGER, 1999). Da mesma forma, a representação da realidade depende da ferramenta com a qual ela é construída:

Como tal, as estruturas de dados e algoritmos disponíveis num determinado estágio de evolução da tecnologia de Sistemas de Informação Geográfica (SIG) condicionam as formas de expressão computacional dos problemas geográficos. O efeito resultante [...] muitos usuários de SIG acabam tomando as estruturas computacionais pela realidade, sem sequer ter consciência de suas limitações (CÂMARA et al, 2003, p.84)

O texto nos apresenta, para diferentes concepções de espaço geográfico provenientes de três diferentes correntes do pensamento geográfico (Geografia Idiográfica, Geografia Quantitativa e Geografia Crítica), como a tecnologia possibilita (ou não possibilita) a expressão computacional dessas concepções, consequentemente mostrando o que as diferentes escolas podem nos ensinar sobre as limitações do Geoprocessamento como ferramenta de representação da realidade, contribuindo assim para direcionar seu desenvolvimento futuro. Ressaltamos que não faz parte dos objetivos deste trabalho a realização de uma revisão profunda do conceito de espaço tal como definido e trabalhado por cada corrente do pensamento geográfico. O que se pretende aqui é apenas possibilitar uma reflexão inicial sobre a relação entre alguns conceitos de espaço geográfico e sua representação computacional.

Na linha da Geografia Tradicional, a idéia de **localização** das ações humanas não era tida como um conceito chave. Porém, Hartshorne (1939) considerava a noção de espaço como sendo de fundamental importância para a Geografia, de acordo com o que ele acreditava ser a tarefa dos geógrafos de descrever e analisar a interação e integração de fenômenos no espaço.

Para este autor, o espaço seria apenas uma base sobre a qual os fenômenos acontecem. Este espaço não teria uma importância *per se*, mas sim decorrente dos fenômenos contidos nele, conformando, assim, uma visão idiográfica da realidade que prescreve que uma certa área é descrita e definida por uma combinação única de fenômenos naturais e/ou sociais. Estas áreas foram chamadas por Hartshorne de “unidades-área”, e são os elementos básicos de seu método de “estudos de variação de áreas”.

Este método consiste na ação do pesquisador em relacionar as características que individualizam cada unidade-área em relação às demais constituintes do espaço: “Hartshorne

argumenta que o caráter de cada área seria dado pela integração das diferentes variáveis geográficas, tomadas em conjunto” (CÂMARA et al, 2003, p.85).

Pensando em termos computacionais, a representação da “unidade-área” de Hartshorne seria feita através da dupla polígono fechado/atributos, que seria capaz de delimitar e descrever cada região de estudo. Seu método de estudo de variação de áreas poderia ser implementado em um ambiente computacional (SIG - Sistema de Informações Geográficas) através das seguintes etapas:

- cada característica (variável geográfica) teria seu próprio conjunto de polígonos/atributos que a delimitaria e a descreveria no espaço, gerando o que poderíamos chamar de uma “camada” (ou, como mais comumente denominado em Geoprocessamento, um *layer*);
- através de um processo de sobreposição, busca-se intersecções entre as várias camadas. Estas intersecções definem assim as unidades-área;
- o resultado é a criação de uma nova camada, onde as unidades-área definidas na etapa anterior estariam delimitadas e descritas através de seu próprio conjunto de polígonos/atributos.

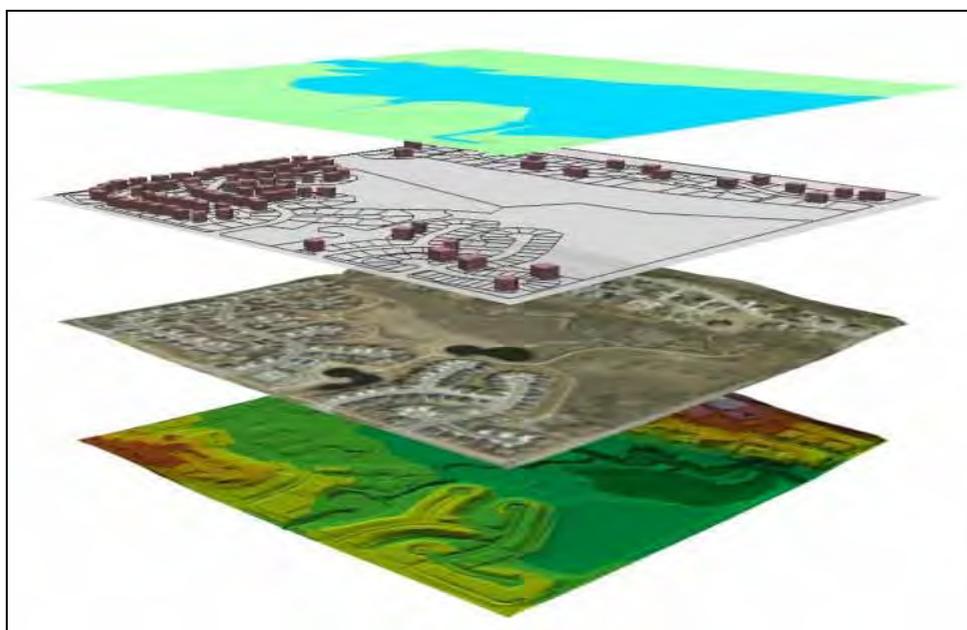


Figura 1: Representação de variáveis geográficas através de camadas.  
Fonte: [www.water-and-earth.com/gis.htm](http://www.water-and-earth.com/gis.htm).

As etapas descritas anteriormente são possíveis de serem executadas pelas capacidades básicas e fundamentais de qualquer Sistema de Informações Geográficas

moderno, o que significa que os conceitos de Hartshorne podem ser representados com esta tecnologia com poucas limitações.

Na corrente denominada de Geografia Quantitativa ocorreu a grande aproximação entre a Geografia e a Computação, já que os estudos geográficos passaram a ser conduzidos segundo a ótica do método hipotético-dedutivo: propõe-se uma teoria, apresentando-a como uma idéia inicialmente não comprovada; com base nesta teoria são construídos modelos matemáticos, muitas vezes de forma análoga aos das ciências naturais (CORRÊA, 1995, p. 20); finalmente, esses modelos são verificados e validados (ou refutados) com dados quantitativos utilizando-se métodos matemáticos e estatísticos.

Nesta corrente do pensamento geográfico, o espaço aparece como conceito-chave da disciplina, já que o foco é o estudo da distribuição e relação espacial dos fenômenos. Conseqüentemente, características tais como vizinhança (autocorrelação espacial como expressão básica da dependência entre observações no espaço em regiões vizinhas) e distância (em um contexto de processo estacionário, que indica uma área de trabalho na qual as relações entre as medidas são função da distância) passam a ser fundamentais nos procedimentos de análise.

A grande forma de representação computacional desse espaço e dos fenômenos nele localizados é a superfície que, de forma geral, engloba todos os outros tipos de representação de fenômenos geográficos:

- eventos pontuais: apenas alguns pontos da superfície são considerados;
- grades retangulares: cada ponto da superfície ou tem um valor próprio de atributo(s) (modelo numérico do terreno), ou pertence a uma categoria de dados (células em uma representação *raster*);
- unidades-área (polígonos): grade retangular onde os limites dos polígonos se “dissolveram”, sendo representados pelos limites entre as células que formam a grade;
- redes (linhas): a superfície armazena os pontos que formam a origem e o destino de cada linha (representando um fluxo) e, paralelamente à superfície, temos uma matriz origem-destino que registra os atributos dos fluxos.

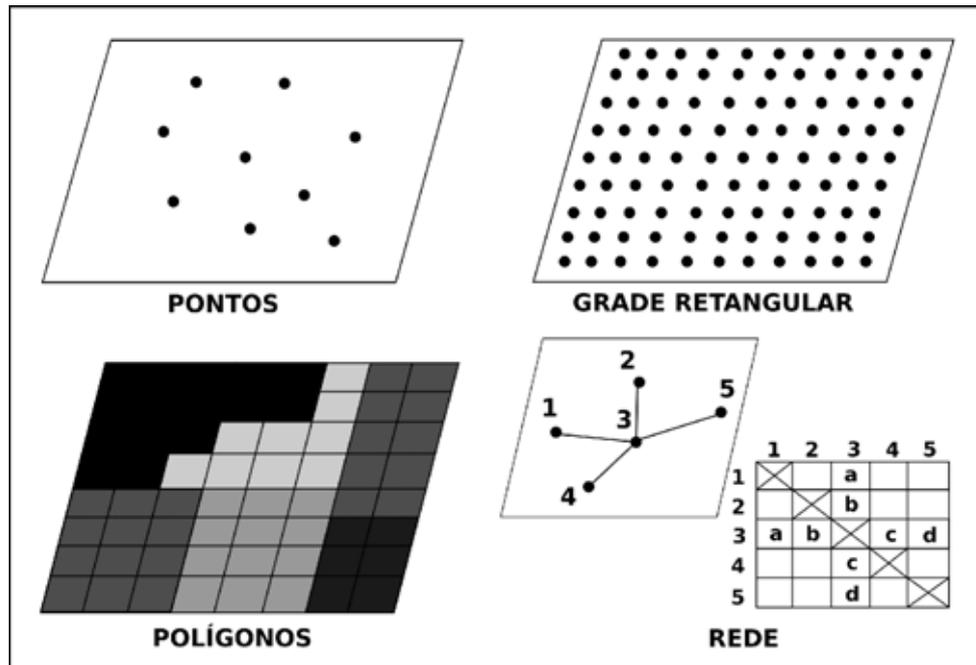


Figura 2: Representações baseadas em superfícies.  
Elaboração: Carlos José de Almeida Pereira.

A principal limitação destas representações aparece quando se necessita trabalhar com fenômenos dinâmicos pois elas, juntamente com a tecnologia que as implementam, enfatizam um caráter estático (processo estacionário, como vimos) dos fenômenos: “Para representar os conceitos de modelos espaço-temporais, apenas a representação de superfícies em grades regulares não é suficiente” (CÂMARA et al, 2003, p.88).

Outro desafio que surge nesta forma de representação é com relação à rigidez que ela impõe no estabelecimento e no desenho dos limites dos fenômenos:

Os limites desenhados em mapas temáticos (como solos, vegetação, ou geologia) raramente são precisos e desenhá-los como linhas finas muitas vezes não representa adequadamente seu caráter (BURROUGH, 1986 *apud* CÂMARA et al, 2003, p.87).

A utilização da lógica nebulosa pode auxiliar na solução deste problema, como veremos mais adiante neste trabalho.

Finalizando esta discussão, o texto de Câmara, Monteiro e Medeiros aborda a Geografia Crítica, que se opõe a Geografia Quantitativa alegando que esta pode até conseguir estudar os padrões espaciais dos fenômenos, porém não consegue explicar os processos sócio-econômicos subjacentes a estes padrões espaciais.

Um dos autores mais importantes desta corrente é o geógrafo Milton Santos, “um dos mais empenhados em apresentar novos conceitos de espaço geográfico” (CÂMARA et al, 2003, p.89). Vamos aqui abordar duas concepções deste autor para este conceito, com o objetivo de compreender as possibilidades e limitações de suas representações computacionais.

A primeira concepção de espaço geográfico em Milton Santos reúne as noções de forma, função, estrutura e processo para descrever as relações que explicam a organização do espaço (CÂMARA et al, 2003, p.89):

A forma é o aspecto visível do objeto, referindo-se, ainda, ao seu arranjo, que passa a constituir um padrão espacial; a função constitui uma tarefa, atividade ou papel a ser desempenhado pelo objeto; a estrutura refere-se à maneira pela qual os objetos estão inter-relacionados entre si, não possui uma exterioridade imediata — ela é invisível, subjacente à forma, uma espécie de matriz na qual a forma é gerada; o processo é uma estrutura em seu movimento de transformação, ou seja, é uma ação que se realiza continuamente visando um resultado qualquer, implicando tempo e mudança.

Encontramos aqui várias limitações da atual tecnologia de Geoprocessamento para representar computacionalmente estes conceitos: é possível representar a forma de um objeto, porém não a sua função; com relação a um grupo de objetos, é possível representar a parte visível da sua estrutura, mas não a rede de relacionamentos subjacente e, por isto, invisível; quanto ao processo, vale aqui a mesma limitação já apresentada anteriormente para a corrente da Geografia Quantitativa que é a dificuldade de representação de processos dinâmicos.

Interessante, para os objetivos deste trabalho, é o comentário de Câmara, Monteiro e Medeiros sobre uma possível solução para estas limitações: “Para remover estes limites, será preciso avançar muito na direção de técnicas de Representação do Conhecimento e Inteligência Artificial” (CÂMARA et al, 2003, p.90).

Outra concepção de espaço da Geografia Crítica que será abordada aqui é a noção de espaço-tempo, ou seja, espaço não mais como um conceito independente, mas tendo sua significação entendida em relação a outros fatores, como por exemplo o tempo. Como vimos na discussão do conceito de espaço no âmbito da Geografia Quantitativa, muito da análise espacial nesta corrente se baseia na noção de proximidade (ou seja, uma função da distância

entre objetos): "Everything is related to everything else, but near things are more related than distant things"<sup>4</sup> (TOBLER, 1970, p.236).

Porém a noção de distância, associada à noção de tempo, sofreu alterações, o que segundo Harvey (1989, p.241) impactou a experiência humana provocando grandes mudanças nos anos recentes. Como exemplo desse fato, ele compara a velocidade das diligências no século XIX ao advento das telecomunicações nos dias atuais, que permite a troca de documentos e a realização de reuniões com pessoas em outros lugares do mundo de forma instantânea:

A compressão do espaço-tempo subverte esta lógica previsível de organização do espaço e estabelece um substancial desafio conceitual para sua representação computacional. [...] implicam que a forma tradicional de expressar as relações espaciais entre entidades geográficas (propriedades como adjacência e distância euclidiana) capturam apenas efeitos locais, e não permitem representar a dinâmica dos fenômenos sociais e econômicos de nosso tempo” (CÂMARA et al, 2003, p.90).

Apesar de serem poderosas em termos de tecnologias de processamento eletrônico de dados, as atuais ferramentas de Geoprocessamento ainda apresentam diversas limitações na tarefa de representar adequadamente o espaço geográfico, etapa fundamental de qualquer tentativa de análise dos fenômenos nesse espaço, ao longo de suas diversas abordagens. Reafirma-se, portanto, a necessidade de novas pesquisas no âmbito da Geografia e da Computação que busquem novas formas de representação e novos procedimentos de análise das informações geográficas, o que dá sentido a este trabalho.

---

4 “Todas as coisas estão relacionadas entre si, mas coisas próximas estão mais relacionadas do que coisas distantes” (tradução do autor).

## 2.2. Geoprocessamento e Sistemas de Informação Geográfica

O termo Geoprocessamento<sup>5</sup>, nas palavras de Câmara e Davis (2001, p.1), “denota a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica”. Rodrigues (1993, p.1) complementa esta definição englobando também a fase de coleta das informações. Por vezes a definição de Geoprocessamento (a disciplina) se confunde com a definição de Sistema de Informação Geográfica (a principal ferramenta computacional da disciplina), como podemos ver nesta definição em uma das mais importantes referências na área<sup>6</sup> (LONGLEY et al, 2001, p.1):

The art, science, engineering, and technology associated with answering geographical questions is called Geographical Information System (GIS). GIS is a generic term denoting the use of computers to create and depict digital representations of the Earth's surface.<sup>7</sup>

A informação geográfica, manipulada através das técnicas de geoprocessamento, e em especial por um SIG, tem como aspecto fundamental a sua natureza dual: é composta por uma localização geográfica (expressa por coordenadas em um mapa), representada de forma gráfica, e por atributos descritivos, representados como elementos textuais em tabelas de dados. Conseqüentemente, este se torna também uma característica fundamental de um SIG, ou seja, o sistema deve ser capaz de manipular essas duas partes fundamentais da informação geográfica de forma integrada (CÂMARA, 1995, p.8) (figura 3).

---

5 Ao se buscar o correspondente termo em inglês, devemos ter cuidado com a natural tradução para *geoprocessing*, que denota uma única operação, geralmente em um ambiente SIG, para manipulação de dados espaciais (ESRI, 2006b). O termo mais adequado é *geocomputation*, “aplicação de tecnologia computacional em estudos espaciais, incluindo coleta, armazenamento, visualização e análise de dados espaciais, além de modelagem de sistemas espaciais dinâmicos” (ESRI, 2006a).

6 Este livro é denominado como “*the big book of GIS*” (o grande livro sobre SIG) por várias fontes. Um comentário acerca desse fato pode ser visto na resenha feita por Nedovic-Budic (2001).

7 “Um Sistema de Informação Geográfica (SIG) é a arte, ciência, engenharia e tecnologia associados as atividades de estudo das questões geográficas. SIG é um termo genérico que denota o uso de computadores para criar e apresentar representações digitais da superfície da Terra” (tradução do autor).

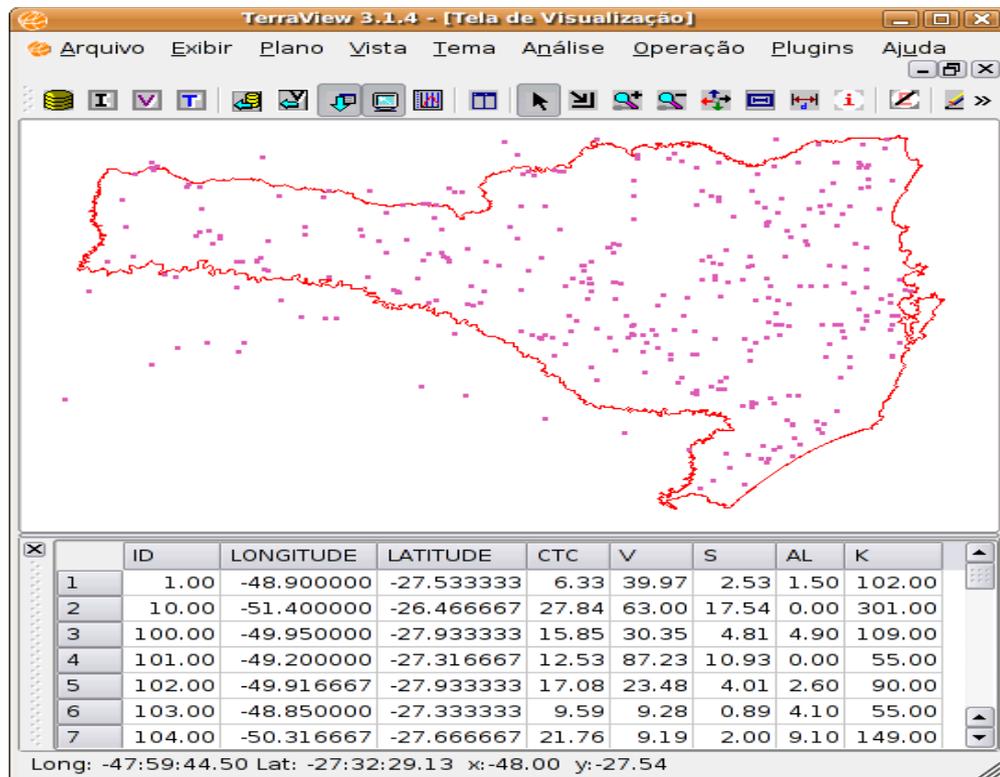


Figura 3: Exemplo de SIG integrando localização e atributos.  
Elaboração: Carlos José de Almeida Pereira.

Podemos relacionar as seguintes motivações iniciais para o desenvolvimento dos SIG (LONGLEY et al, 2001, p.2):

- como ferramenta para análise e visualização de dados: a história dos SIGs como a história do uso de computadores para manipular e analisar dados provenientes de mapas;
- como ferramenta para construção de mapas : benefícios oriundos da automação do processo de produção de mapas;
- como ferramenta para o planejamento ambiental: emergiu, na década de 60, uma visão do planejamento que via o mundo como formado por um conjunto de camadas independentes, cada uma representando algum componente do ambiente, sendo desta importante para estudos ambientais. Apesar de a idéia inicial ser a de um processo manual, logo se buscou um processamento computacional dessas idéias usando um SIG baseado em camadas.

- como ferramenta para estudos demográficos e urbanos: esforços para automatizar os Censos nacionais vêm desde a época de Hollerith nos primórdios da computação. Um Censo é inerentemente geográfico, requerendo a tabulação e publicação de estatísticas sobre um conjunto de unidades geográficas, com relações hierárquicas complexas no espaço;
- como ferramenta proveniente do desenvolvimento da tecnologia de sensoriamento remoto.

O primeiro SIG surgiu com a iniciativa de construção de um sistema de informações geográficas em escala nacional, o Canada Geographic Information System (CGIS). Este sistema tem operado continuamente desde a década de 60. Foi desenvolvido a partir de um projeto para desenvolver capacidade de classificação das terras do país, objetivando compilar um inventário de todas as terras potencialmente produtivas do Canadá. Em adição a essas informações de capacidade de produção agrícola, foram incluídas outras categorias de uso da terra, tais como florestas, recreação e vida selvagem (ARONOFF, 1989, p.4).

Apresentamos no quadro 1 um histórico resumido do desenvolvimento teórico e prático dos SIGs e de outras tecnologias relacionadas ao Geoprocessamento.

Ano	Descrição
1959	Waldo Tobler define um modelo simples chamado MIMO ( <i>map in - map out</i> ) para aplicação de computadores na cartografia. Os princípios do sistema MIMO foram as bases para o desenvolvimento de processos de georeferenciamento, captura de dados, análise de dados e visualização. O sistema já continha todos os elementos básicos encontrados nos SIGs atuais.
1963	Início do desenvolvimento do <i>Canada Geographic Information System</i> (CGIS), liderado pelo Dr. Roger Tomlinson. O sistema foi projetado para analisar o inventário de terras do Canadá, e foi pioneiro em muitos aspectos da tecnologia de SIG.
1963	A URISA ( <i>Urban and Regional Information Systems Association</i> ) foi formada como uma associação de profissionais usuários de tecnologia da informação para a solução de problemas nas áreas de planejamento, setor público, meio-ambiente, serviços de emergência, entre outras. URISA foi a primeira organização voltada para o uso e a integração da tecnologia da informação espacial para melhorar a qualidade de vida nos ambientes urbanos e regionais.
1964	Criado o <i>Harvard Lab for Computer Graphics</i> , importante centro de pesquisa, criador de <i>software</i> pioneiro para manipulação de dados espaciais. Local de estudo de muitos dos indivíduos chave da indústria de SIG, tais como David Sinton (Intergraph), Jack Dangermond (ESRI) e Lawrie Jordan e Bruce Rado (ERDAS).
1965	Desenvolvimento do SYMAP ( <i>Synagraphic Mapping System</i> ), uma aplicação pioneira para mapeamento computacional automatizado, por Howard Fisher no <i>Northwestern Technology Institute</i> e completada no <i>Harvard Lab</i> .

continua

continuação

1967	Estabelecida a unidade de Cartografia Experimental (ECU) no <i>Royal College of Art</i> em Londres.
1968	Desenvolvimento do Sistema de Informações sobre Transportes por Robert Tweedie, do Departamento de Transportes do Estado de Nova York, baseado em manipulação de grades regulares. O sistema incorporou, entre outras características, classificação de uso da terra georeferenciada e características de viagens.
1969	Fundação da ESRI
1969	Fundação da Intergraph
1969	Fundação da Laser-Scan
1969	Publicação do livro <i>Design With Nature</i> , de Ian McHarg, popularizando o desenvolvimento de técnicas de sobreposição de camadas.
1970	O primeiro SIG ( <i>Canada Geographic Information System - CGIS</i> ) se torna totalmente operacional.
1970	Realização do primeiro simpósio sobre Sistemas de Informação Geográfica em Ottawa, Canada.
1972	Lançamento do primeiro satélite da série Landsat.
1972	IBM começa o desenvolvimento do seu sistema de Informação geográfica (GFIS).
1978	Fundação da ERDAS
1978	O sistema de posicionamento global (GPS) entra na sua fase 2, com o lançamento dos quatro primeiros satélites
1981	O sistema de posicionamento global (GPS) se torna operacional.
1982	Fundação da SPOT - primeira empresa comercial para a distribuição, em escala mundial, de informações geográficas derivadas de satélites de observação da Terra
1985	Início do desenvolvimento do sistema GRASS ( <i>Geographic Resources Analysis Support System</i> ) por um laboratório de pesquisa do exército americano.
1987	Início de publicação do <i>International Journal of Geographical Information Systems</i> .
1991	Publicação do “grande livro de GIS”: <i>Geographical Information Systems : Principles and Applications</i> .
1993	Desenvolvimento do primeiro sistema de busca de mapas interativo via web.
1996	Criação do Centro para Análise espacial avançada ( <i>Centre for Advanced Spatial Analysis - CASA</i> ) na UCL ( <i>London's Global University</i> )
1997	Lançamento do sensor orbital LandSat 7, levando a bordo um mapeador temático avançado.
1999	Publicação da 2a. edição do “grande livro de GIS”.
2004	Primeira edição da “Open Source GIS Conference”, que irá se tornar, a partir de 2006, na série de eventos FOSS4G - “Free and Open Source Software for Geoinformatics”
2005	Criação da MapServer Foundation.
2006	Transformação da MapServer Foundation na OSGEO: “Open Source Geospatial Foundation”, criada para apoiar a construção de software de código-aberto de alta qualidade para aplicação na área geo-espacial.

Quadro 1: Evolução histórica do desenvolvimento teórico e prático dos SIGs.

Fonte: Adaptado de CASA (2000).

Complementando este registro histórico, apresentamos também o desenvolvimento da tecnologia no Brasil. Em nosso país, esta área teve seu desenvolvimento iniciado através dos esforços do Prof. Jorge Xavier da Silva (UFRJ) no início dos anos 80. Um fator motivante foi a visita do Dr. Roger Tomlinson, principal responsável pela criação do primeiro SIG (CGIS, Canadá). A partir daí, houve o aparecimento de diversos grupos interessados no desenvolvimento da tecnologia de geoprocessamento e SIG, entre os quais podemos citar: (CÂMARA; DAVIS, 2001, p.3)

- o pioneiro grupo do Laboratório de Geoprocessamento do Departamento de Geografia da UFRJ, coordenado pelo Prof. Jorge Xavier, que desenvolveu o SAGA (Sistema de Análise Geo-Ambiental);
- profissionais oriundos do setor de informática da empresa de aerolevanteamento AeroSul. Este grupo criou, em meados dos anos 80, um sistema para automatização de processos cartográficos (*software* MaxiCAD), constituindo posteriormente a empresa MaxiDATA. Este grupo também desenvolveu o *software* dbMapa, que permitia a junção de bancos de dados convencionais à arquivos gráficos do MaxiCAD, tornando possível assim a manipulação efetiva de informações geográficas, como esta é conceituada;
- o Centro de Pesquisa e Desenvolvimento da TELEBRÁS, com o desenvolvimento do SAGRE (Sistema Automatizado de Gerência da Rede Externa), um exemplo de aplicação do Geoprocessamento no setor de telefonia;
- o INPE, que em 1984 estabeleceu um grupo específico para o desenvolvimento de tecnologia de geoprocessamento e sensoriamento remoto. Esta instituição contribuiu e continua contribuindo muito para o desenvolvimento não só da tecnologia, na forma de *softwares* aplicativos, mas principalmente em termos de material de referência, como dissertações, teses, livros, cursos, sempre disponibilizados de forma gratuita e on-line via Internet. Vale destacar o desenvolvimento das ferramentas SITIM (Sistema de Tratamento de Imagens), o SGI, o SIG Spring, e mais recentemente, o SIG TerraView e a biblioteca para desenvolvimento de *software* em geoprocessamento TerraLib;
- outras iniciativas, de âmbito restrito, também podem ser citadas, como é o caso do GEO-INF, SIG para computadores pessoais de 8 bits (TEIXEIRA, 1987), e seu aperfeiçoamento — GEOINF+MAP (TEIXEIRA, 1990), ambos desenvolvidos na UNESP/Rio Claro por Amândio de Almeida Teixeira.

São objetivos principais de um SIG:

- inserir e integrar, no mesmo banco de dados, informações espaciais provenientes de dados cartográficos, dados censitários, dados de cadastro urbano e rural (gráficos ou textuais), imagens de satélite, redes e modelos numéricos de terreno;
- oferecer mecanismos para combinar os vários tipos de informações, através de algoritmos de manipulação e análise, bem como para consultar, recuperar, visualizar e imprimir o conteúdo do banco de dados geográfico.

A figura 4 retrata a arquitetura básica de um SIG:

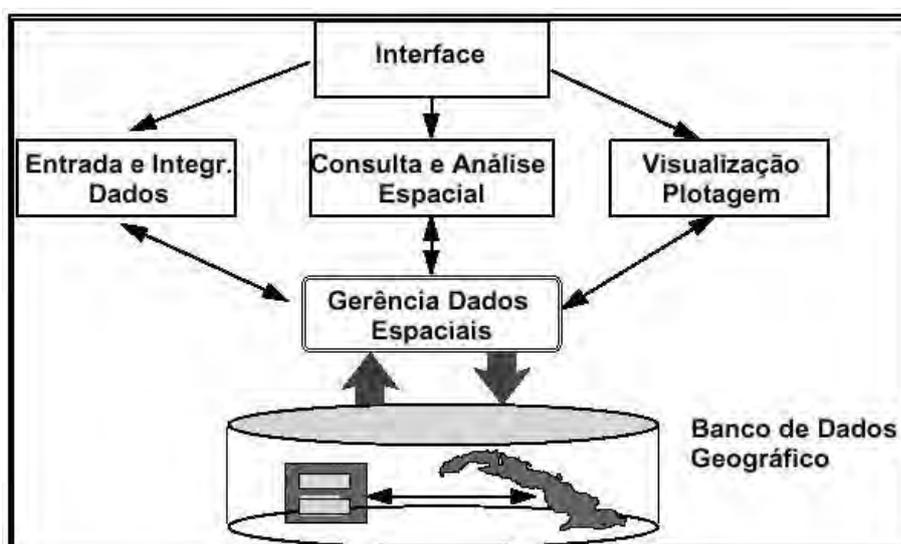


Figura 4: Arquitetura básica de um SIG.  
Fonte: (CÂMARA et al, 1996, p.24).

Na base da arquitetura apresentada na figura 4, vemos o banco de dados geográfico, isto é, um sistema gerenciador de banco de dados capaz de dar conta das necessidades especiais de armazenamento oriundas da dualidade geometria/atributos da informação geográfica. Temos hoje em dia disponíveis alguns sistemas que já trazem embutida esta nova funcionalidade (Oracle Spatial<sup>8</sup>, PostGIS<sup>9</sup>, MySQL Spatial Extensions<sup>10</sup>). O módulo de armazenamento e recuperação funciona como um facilitador de acesso às informações geográficas armazenadas no banco de dados para os demais módulos de um SIG. No módulo

8 <http://www.oracle.com/technology/products/spatial/index.html>

9 <http://postgis.refrations.net/>

10 <http://dev.mysql.com/tech-resources/articles/4.1/gis-with-mysql.html>

“funções de processamento” temos agrupadas todas as funcionalidades que vão efetivamente manipular e analisar as informações geográficas.

Com relação à forma de representação computacional das informações geográficas (e por consequência suas possibilidades de armazenamento), podemos identificar duas formas principais (LONGLEY et al, 2001,p.5):

- modelo de campo: informação geográfica concebida como um conjunto de funções contínuas no espaço, cada uma possuindo um valor em cada ponto desse espaço.
- modelo de objetos: o mundo é preenchido por entidades discretas (elementos únicos), representados por objetos geométricos caracterizados por atributos não espaciais. A localização dos objetos pretende ser exata.

Câmara e Davis (2001, p.2-13) denominam estes tipos de dados, respectivamente, de geo-campos e geo-objetos. Podemos ter ainda algumas especializações desses tipos de dados principais, conforme a utilização desejada. São elas:

- temático: especialização de um geo-campo. O resultado da função, relativo a cada ponto, representa um tema específico ao qual o ponto pertence. Na figura 5 vemos um exemplo deste tipo de dado, onde cada tonalidade da cor vermelha representa o valor que identifica o tema do ponto.



Figura 5: Informação geográfica temática.  
Elaboração: Carlos José de Almeida Pereira.

- numérico: ainda do tipo geo-campo, onde o valor que a função retorna em cada ponto é um número real, representando a medida de uma certa grandeza relacionada àquele ponto. Vemos um exemplo na figura 6, para uma grandeza hipotética. Nesta figura, os valores numéricos foram convertidos em tons de cinza, isto é, quanto mais escura a cor do ponto, maior o valor numérico associado: “Lighter hues normally represent lower quantities while darker hues are for higher quantities”<sup>11</sup> (GARO, 1998).

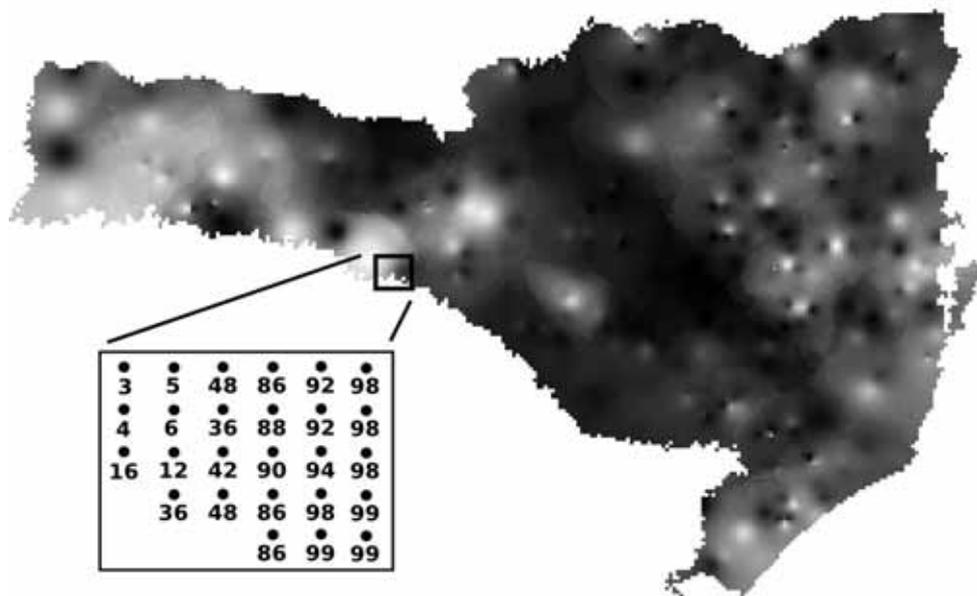


Figura 6: Informação geográfica numérica.  
Elaboração: Carlos José de Almeida Pereira.

- imagem: geo-campo que novamente tem um valor numérico associado a cada ponto. Apesar desta semelhança, não devemos confundir este tipo com o tipo numérico, pois no tipo imagem cada ponto representa uma área (por exemplo, em uma imagem oriunda de um satélite da série Landsat, cada ponto – ou pixel – representa uma área de 90m<sup>2</sup> na superfície da Terra), enquanto que no tipo numérico, teoricamente, cada ponto representa apenas um único ponto dentre a infinidade de pontos que caracteriza um plano. O valor numérico associado a um ponto no tipo imagem representa o nível de reflectância daquela área em termos de energia eletromagnética. Este valor geralmente é um número inteiro, variando de 0 (nenhuma reflectância) até 255 (reflectância máxima). A figura 7 mostra um exemplo deste tipo de informação.

<sup>11</sup> “Matizes mais claras normalmente representam valores baixos, enquanto matizes mais escuras são adequadas para valores altos” (tradução do autor).

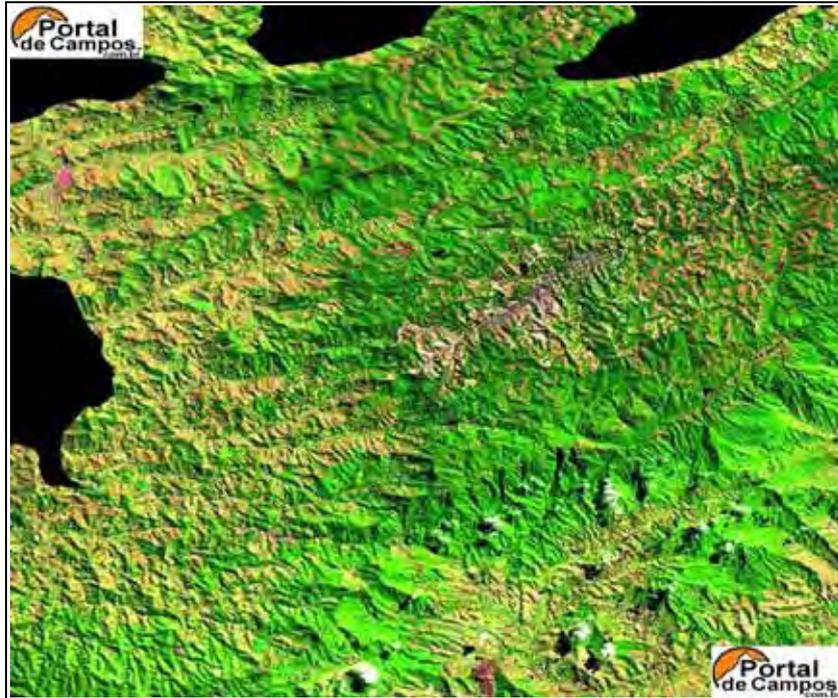


Figura 7: Informação geográfica do tipo imagem.

Fonte: [www2.uol.com.br/portaldecampos/images/satelite2.jpg](http://www2.uol.com.br/portaldecampos/images/satelite2.jpg).

- cadastral: é a implementação do modelo de objetos, sendo composto de um conjunto de geo-objetos para uma área geográfica definida, como pode ser visto na figura 8.

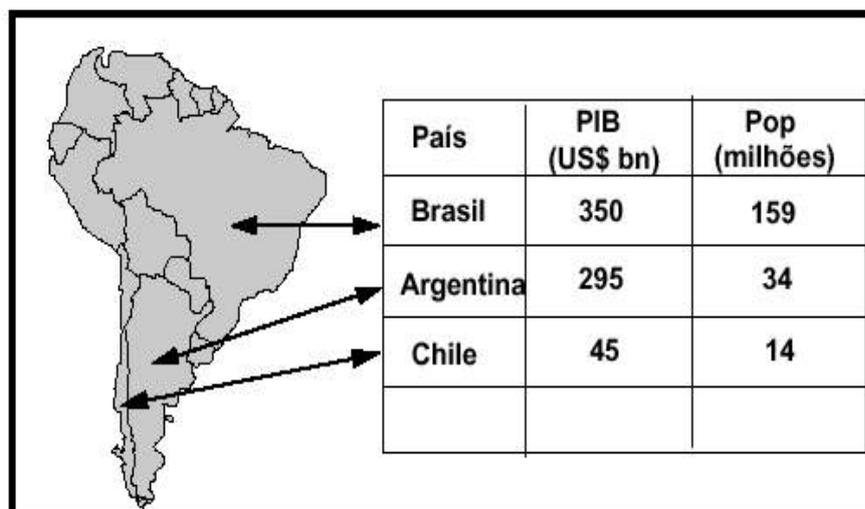


Figura 8: Informação geográfica do tipo cadastral.

Fonte: (CÂMARA; MONTEIRO, 2001, p.2-8).

- redes: especialização do tipo geo-objetos onde estes são representados por pontos e principalmente linhas conectando estes pontos (transmissão de energia elétrica, fluxo de mercadorias, etc). A figura 9 ilustra um exemplo deste tipo de informação geográfica.

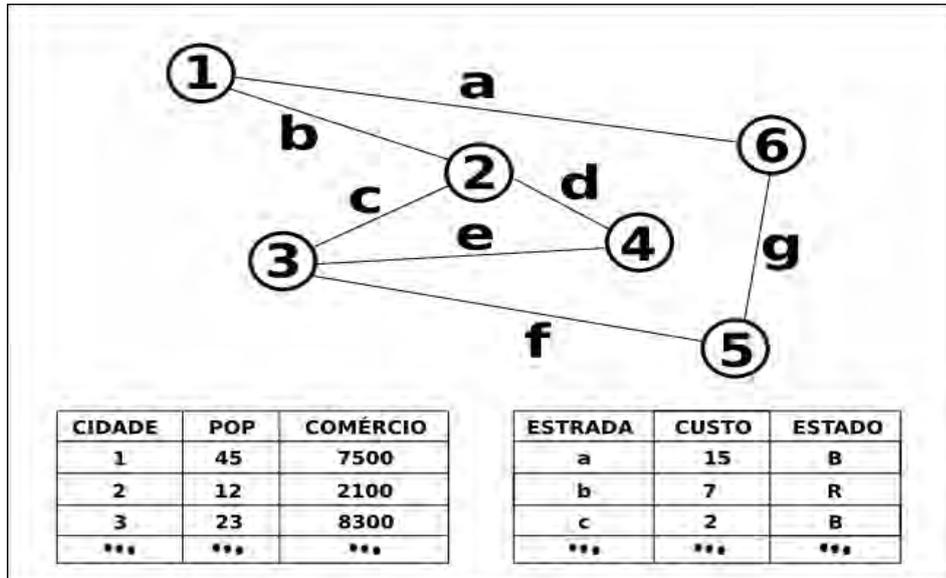


Figura 9: Informação geográfica do tipo rede.  
Elaboração: Carlos José de Almeida Pereira.

O grande objetivo do Geoprocessamento é determinar e esquematizar os mecanismos implícitos e explícitos de inter-relação entre os padrões de ocupação estabelecidos pela distribuição dos fenômenos geográficos sobre a superfície da Terra (CÂMARA; MEDEIROS, 1998, p.1-3). As formas que estes padrões de inter-relação podem assumir são:

- correlação espacial: um fenômeno espacial está relacionado com o entorno de forma tão mais intensa, quanto maior for a proximidade de localização;
- correlação temática: as características de uma região geográfica são moldadas por um conjunto de fatores. Por exemplo, o clima, as formações geológicas, o relevo, o solo, a vegetação formam uma totalidade interrelacionada. Deste modo, pode-se traçar pontos de correspondência entre esses vários fatores;
- correlação temporal: evolução dos fenômenos geográficos no tempo;
- correlação topológica: relações de adjacência, pertinência e intersecção, que permitem estabelecer os relacionamentos entre os objetos geográficos que são invariantes à rotação, à translação e à escala.

### 2.3. Computação Inteligente

Originalmente conhecida por Inteligência Artificial, esta grande área de estudo da Ciência da Computação é também conhecida por diversos outros nomes: Sistemas Inteligentes, Computação Bio-inspirada, *Soft Computing* (em oposição a *hard*, que indicaria uma computação rígida, repetitiva, que busca resultados únicos e precisos), e trata dos sistemas computacionais (*hardware* mas principalmente *software*) cuja forma de construção é inspirada no comportamento humano ou de outros seres vivos da natureza: “Inteligência Artificial significa o desejo de replicar, emular ou simular as características mais importantes da inteligência biológica através de sistemas computacionais para resolver problemas práticos” (OPENSHAW; OPENSHAW, 1997, p.17).

A grande diferença entre a computação convencional (“*hard*”) e os sistemas inteligentes (“*soft*”) é que os primeiros são construídos para realizarem um processamento que tenha uma sequência de passos bem definida e que não permita nenhum tipo de processamento alternativo, enquanto que os sistemas inteligentes são projetados para, em certa medida, se adaptarem a novas situações, descobrirem relações entre fatos (expressos nos dados de entrada) e aprenderem com base em sua experiência. Esta forma de operação pode fornecer, para várias classes de problemas, soluções mais satisfatórias (ou até mesmo soluções aproximadas onde antes não existia nenhuma solução possível!) que as fornecidas pela computação convencional.

Vejamos um exemplo para ilustrar essa diferença entre a computação convencional e a computação inteligente. Imaginemos um programa de computador cuja tarefa seja a de identificar uma letra com base no seu desenho.

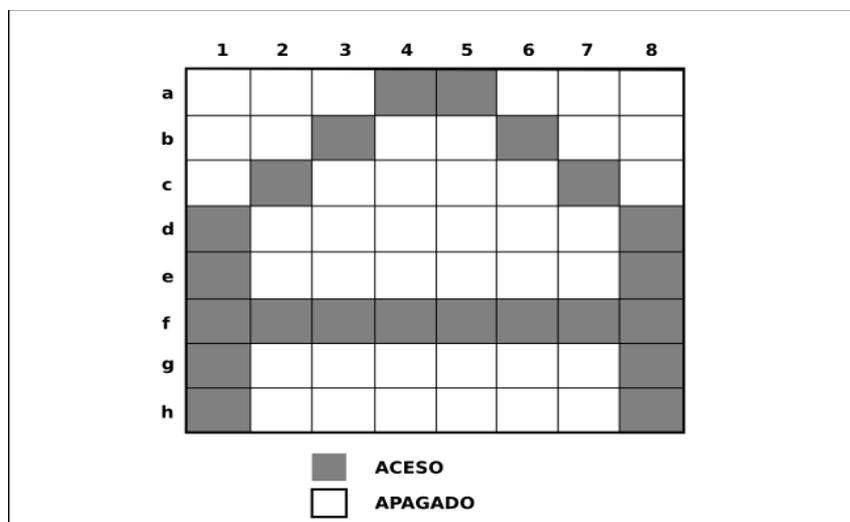


Figura 10: Representação computacional da letra 'A'.  
Elaboração: Carlos José de Almeida Pereira.

Um programa convencional para identificar a letra 'A' a partir do desenho retratado na figura 10, não poderia ser mais simples:

<i>SE</i>	o ponto a1 estiver apagado	<i>E</i>	<i>ENTÃO É A LETRA 'A'</i>
	o ponto a2 estiver apagado	<i>E</i>	
	o ponto a3 estiver apagado	<i>E</i>	
	o ponto a4 estiver aceso	<i>E</i>	
	...	<i>E</i>	
	o ponto h8 estiver aceso	<i>E</i>	

Como descrevemos anteriormente, é uma sequência de passos bem definida e rígida (imutável em sua forma de processamento), que pode ser executada de forma muitíssimo rápida em qualquer microcomputador pessoal disponível atualmente. Porém, se ocorrer a mínima alteração no desenho apresentado (como por exemplo, um único ponto que deveria estar “aceso” aparece como “apagado”), o programa apresentado acima deixa de identificar a letra corretamente.

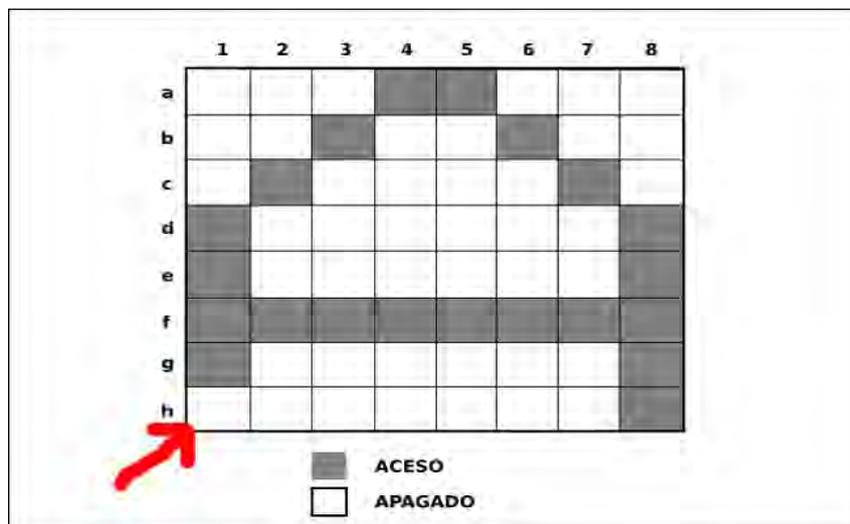


Figura 11: Deixou de ser a letra 'A' ?  
Elaboração: Carlos José de Almeida Pereira.

Um programa com o mesmo objetivo, só que baseado na computação inteligente, como por exemplo uma Rede Neural Artificial, seria “treinado” para identificar uma letra, ou mesmo várias letras diferentes. Após esse treino, o programa é capaz de identificar até mesmo letras que tenham seu desenho alterado (obviamente, dentro de uma certa margem de erro).



Figura 12: Níveis hipotéticos de reconhecimento de uma letra 'A' por uma Rede Neural Artificial.  
Elaboração: Carlos José de Almeida Pereira.

Outro exemplo que contribui para se entender a diferença entre a rigidez da “hard” computação convencional e a “soft” computação inteligente, é o da definição de conjuntos de dados usando, no primeiro caso, a teoria dos conjuntos tradicional e, no segundo caso, a teoria dos conjuntos nebulosos. Pensemos, por exemplo, numa definição possível para a categoria “cidade média” como sendo uma cidade que abrigue de 50.000 a 250.000 habitantes.<sup>12</sup>

Na teoria dos conjuntos tradicional, esses limites são rígidos, de forma que se uma cidade tiver 49.999 habitantes, ela não é considerada uma cidade média. Já uma cidade com 50.001 habitantes (apenas duas pessoas a mais do que na primeira cidade), esta sim, seria com certeza considerada uma cidade média. Ainda neste contexto, se tivermos duas cidades com 52.500 e 249.300 habitantes, respectivamente, as duas serão consideradas cidades médias de forma igual, sem distinção entre elas (no que diz respeito ao conceito e à definição do conceito adotada). Essa rigidez pode ser quebrada utilizando-se a teoria dos conjuntos nebulosos, cujos detalhes veremos mais adiante neste trabalho

<sup>12</sup> <http://www.rc.unesp.br/igce/planejamento/territorioecidadania/Artigos/Braga%207.htm>

Algumas das técnicas da computação inteligente, com sua componente de inspiração biológica (adaptado de FERNANDES, 2005, p.4), são apresentadas a seguir:

- Sistemas baseados em regras: sistemas que implementam comportamentos inteligentes de especialistas humanos;
- Raciocínio baseado em casos: é o campo de estudo da Computação Inteligente que utiliza uma grande biblioteca de casos para consulta e resolução de problemas. Os problemas atuais são resolvidos através de recuperação e consulta de casos já solucionados e da consequente adaptação das soluções encontradas;
- Redes neurais: são consideradas uma classe de modelagem de prognóstico que trabalha por ajuste repetido de parâmetros. Estruturalmente, uma Rede Neural consiste em um número de elementos interconectados (chamados “neurônios”) organizados em camadas que aprendem pela modificação das conexões que conectam essas camadas. Esta forma de funcionamento é baseada no funcionamento real dos neurônios no cérebro humano;
- Algoritmos genéticos: é um modelo para aprendizado de máquina inspirado na idéia de seleção natural do naturalista inglês Charles Darwin, criador da teoria evolucionista, segundo a qual somente os mais aptos sobrevivem;
- Programação genética: é um campo de estudo da Computação Inteligente voltado para a construção de programas que visam imitar o processo natural da genética. Trabalha com métodos de busca aleatória;
- Lógica Nebulosa: também denominada Lógica Difusa ou Lógica Fuzzy (Fuzzy Logic). É uma metodologia que serve para representar, manipular e modelar informações imprecisas, tais como as idéias expressas pela linguagem natural dos seres humanos, quebrando assim a rigidez imposta pelos métodos computacionais tradicionais.

Conforme apontam Openshaw e Openshaw (1997, p.24), as técnicas da computação inteligente têm a potencialidade de se tornarem uma importante “caixa de ferramentas”, cujo uso nos estudos geográficos proporcionará:

- a criação de novos e melhores modelos de sistemas humanos espaciais;
- o desenvolvimento de novos e melhores métodos para análise espacial;
- a criação de novas abordagens para velhos problemas;
- a busca da solução de problemas que antes eram insolúveis;

- uma grande flexibilidade;
- a condução estudos mais realísticos do ponto de vista geográfico;
- a possibilidade de uso da imensa quantidade de informação geográfica que tem sido criada desde o advento da tecnologia dos Sistemas de Informações Geográficas;
- a aplicação da computação aos estudos mais qualitativos (“*soft areas*”) da Geografia.

#### 2.4. *Software* Livre

Todas as ferramentas computacionais que foram utilizadas neste trabalho, bem como as ferramentas que foram construídas, estão inseridas no que é comumente conhecido como a “filosofia” do *software* livre. *Software* livre é uma forma de construção e disponibilização de programas de computador onde o código-fonte<sup>13</sup> do programa é disponibilizado. De posse deste código-fonte, podemos estudar como o programa foi feito, isto é, quais os algoritmos (sequências de passos) que o mesmo possui para resolver determinado problema e, adicionalmente, podemos realizar alterações neste código-fonte para adaptá-lo a alguma necessidade especial de processamento.

Quando surgiram os primeiros computadores, todos os *softwares* utilizados eram livres, ou seja, tinham o seu código-fonte disponibilizado para qualquer um. Naquela época, o foco das empresas estava na construção e comercialização do hardware (os equipamentos propriamente ditos). O *software* era um item secundário, sem valor comercial. Com o tempo, os fabricantes perceberam que o *software* na verdade tinha mais valor que o *hardware* (o mesmo equipamento pode executar tarefas distintas, conforme o *software* utilizado), e passaram então a “fechar o código”, isto é, fornecer o equipamento e os programas prontos para uso, mas sem o código-fonte deste programa. Desta forma, qualquer necessidade de alteração nestes programas teria que ser encomendada e contratada perante a empresa proprietária dos programas.

---

<sup>13</sup> Um programa de computador é criado, basicamente, em duas etapas: na primeira, o programador escreve o código-fonte do programa, que é um “texto” contendo uma sequência de passos necessária para se resolver um determinado problema. Este “texto” é escrito utilizando-se uma determinada linguagem de programação, que é, na maioria dos casos, bem parecida com a língua inglesa. Na segunda etapa, este código-fonte é convertido em um código que o computador entende e pode executar, chamado de código de máquina. Para se alterar um programa (por exemplo, adicionar novas funcionalidades), é preciso ter acesso ao código-fonte que o gerou, pois é praticamente impossível alterar diretamente o seu código de máquina.

Em 1983, um pesquisador do Laboratório de Inteligência Artificial do MIT chamado Richard Stallman, insatisfeito com a recente impossibilidade de ter acesso ao código-fonte dos programas, criou o projeto GNU, que visava a construção de um sistema operacional<sup>14</sup> completo cujo código-fonte estaria disponível para qualquer um. Em 1985, foi criada uma fundação para arrecadar fundos para a manutenção do projeto GNU, a *Free Software Foundation*, surgindo assim o termo *software* livre.

Estando um programa de computador enquadrado como *Software* Livre, significa que qualquer usuário deste programa tem 4 liberdades (MOTA FILHO, 2006, p.52):

- Executar o programa para qualquer propósito;
- Estudar como o programa funciona, para adaptá-lo para as suas necessidades (acesso ao código-fonte é um requisito para esta liberdade);
- Distribuir cópias do programa, para que outros usuários também possam se beneficiar de seus recursos;
- Aperfeiçoar o programa e disponibilizar os seus aperfeiçoamentos, de modo que toda a comunidade se beneficie (acesso ao código-fonte é um requisito para esta liberdade).

O *Software* Livre é, portanto, muito mais do que uma forma de produção e/ou disponibilização de programas de computador. Acreditamos, na verdade, que sua adoção é uma atitude política e um requisito fundamental em ambientes educacionais e científicos.

Em um ambiente educacional a adoção de programas de computador baseados na filosofia do *Software* Livre, em qualquer curso (não apenas no curso de Ciências da Computação), forma profissionais completos e não meros clientes de algumas empresas de *software* específicas. Por exemplo, num curso de Pedagogia, se ensinamos uma disciplina de 'administração escolar' utilizando um *software* proprietário para este fim, estamos formando clientes para a empresa dona deste *software*, pois os alunos saem do curso só sabendo usar aquele *software* específico. O uso de *software* livre permitiria que o foco da disciplina fosse nos objetivos que se busca atingir e não na ferramenta específica para atingir esses objetivos. Também dá a liberdade ao aluno (e por consequência nas empresas e instituições onde ele vai trabalhar depois de formado) de escolher o *software* que deseja utilizar. Finalmente, o *software* livre pode ajudar também na expansão das possibilidades de trabalho deste futuro

---

<sup>14</sup> Programa básico para o funcionamento de qualquer computador, como por exemplo o GNU/Linux, DOS, Windows 98, etc.

profissional, que poderá prestar serviços de implantação do *software*, tendo uma remuneração para isto.

Mas é no ambiente da pesquisa científica que a filosofia do *software* livre mais se mostra como uma necessidade fundamental, pois o fator determinante neste ambiente é a construção do conhecimento e a sua conseqüente disponibilização. Nesse sentido, o *software* livre representa a disponibilização efetiva do conhecimento embutido em ferramentas computacionais, permitindo que outros pesquisadores não só utilizem as ferramentas disponibilizadas, mas também estudem sua construção interna, contribuindo assim para um maior avanço na evolução dessas ferramentas.

Com base nessas idéias, este trabalho baseou todo seu processamento computacional em *software* livre, tanto no uso e adaptação de ferramentas já prontas, como principalmente no desenvolvimento de novas ferramentas. Isto permitirá que outros pesquisadores possam não somente refazer o caminho apresentado aqui mas, principalmente, estudar as ferramentas desenvolvidas, objetivando uma melhor compreensão das idéias aqui apresentadas ou até mesmo expandir essas ferramentas, possibilitando assim o surgimento de novos trabalhos de pesquisa nesta área. A idéia é a de que este trabalho se transforme em um laboratório livre e aberto, tornando-se uma possível base de partida para outros trabalhos nesta temática.

## 2.5. Computação Inteligente e Geoprocessamento: Um panorama das ferramentas disponíveis

A aplicação de técnicas de computação inteligente em estudos e pesquisas de caráter geográfico tem se configurado, ao longo dos últimos anos, numa fértil área de pesquisa, tanto no que diz respeito à busca de formas de aplicação dessas técnicas às especificidades das informações geográficas, como também à criação e disponibilização de ferramentas computacionais que implementem estas técnicas. Neste momento, encontramos uma grande disponibilidade de ferramentas tanto de Geoprocessamento como de Computação Inteligente, porém poucos casos<sup>15</sup> onde é possível o funcionamento integrado dessas ferramentas, isto é, onde seja possível ao pesquisador aplicar as técnicas da computação inteligente em seus dados espaciais DIRETAMENTE “de dentro” de alguma ferramenta de geoprocessamento, em especial um sistema de informações geográficas.

---

<sup>15</sup> A pouca integração entre ferramentas computacionais (entendendo aqui como integração a capacidade das ferramentas de trabalharem em conjunto) exige do pesquisador interessado no seu uso um grande conhecimento da área de computação. Para realizar a transferência de dados entre os dois tipos de programas o pesquisador deverá conhecer, entre outras coisas, o funcionamento interno das ferramentas envolvidas, os formatos (computacionais) dos dados a serem transmitidos, e em alguns casos, como utilizar uma linguagem de programação para criar programas que serão responsáveis pelas conversões e adaptações necessárias nos dados. Um exemplo de trabalho onde este tipo de situação ocorreu é descrito em Pereira (2003).

Descreveremos a seguir algumas dessas ferramentas, com foco principalmente na existência ou não de funcionalidades relativas a técnicas de computação inteligente, especificamente da Lógica Nebulosa e das Redes Neurais Artificiais. Procuramos elaborar uma lista, que não se pretende exaustiva, com os *softwares* mais importantes da área, sendo este critério aplicado a partir da experiência profissional deste autor. O objetivo aqui é apresentar um panorama geral da disponibilidade de ferramentas de computação inteligente integradas às ferramentas de geoprocessamento.

Para cada software listado, serão apresentados os seguintes itens: se é software livre ou proprietário, o(s) sistema(s) operacional(is)<sup>16</sup> em que é possível utilizar o software e a existência ou não de recursos para análise de dados via computação inteligente (lógica nebulosa e redes neurais artificiais).

### **ArcGIS**

- Denomina um conjunto de programas (computadores pessoais, servidores, computação móvel, análise de dados, Internet, entre outros) para a manipulação de dados espaciais;
- Software proprietário. Empresa: ESRI;
- Sistema Operacional: Windows;
- Disponibiliza o uso de lógica nebulosa e redes neurais artificiais através de um programa externo desenvolvido por terceiros, denominado de *Spatial Data Modeler*. Este programa é de domínio público, e seu código-fonte está disponível.

### **MapInfo Professional**

- Software proprietário. Empresa: Pitney Bowes;
- Sistema Operacional: Windows;
- Disponibiliza o uso de lógica nebulosa em algumas ferramentas específicas (georeferenciamento de dados utilizando seu endereço e identificação de clientes e mercados). Não foi encontrada nenhuma referência de que é possível o uso tanto de lógica nebulosa como redes neurais artificiais de uma forma genérica pelo usuário.

---

<sup>16</sup> Os sistemas operacionais Windows (Microsoft) e Mac OS (Apple) são softwares proprietários. O sistema operacional GNU/Linux é software livre. Isto significa que, se um SIG só funciona em um sistema operacional proprietário, o pesquisador interessado em utilizar este software (ou sua instituição) terá que ter adquirido também uma licença de uso deste sistema operacional.

## **IDRISI**

- Sistema de informações geográficas e software para processamento de imagens;
- Software proprietário. Instituição: Clark Labs (Clark University, EUA);
- Sistema Operacional: Windows;
- Disponibiliza recursos de lógica nebulosa e redes neurais artificiais, principalmente para uso em procedimentos de classificação de imagens.

## **ERDAS IMAGINE**

- Conjunto de programas focados principalmente na manipulação de imagens de alta resolução;
- Software proprietário. Empresa: Erdas;
- Sistema Operacional: Windows;
- Disponibiliza duas técnicas provenientes da computação inteligente para uso em procedimentos de classificação de imagens: lógica nebulosa e sistemas especialistas.

## **TNT**

- Conjunto de programas (TNTMips, TNTEdit, TNTView, entre outros) para a manipulação e análise da informação geográfica;
- Software proprietário. Empresa: Microimages;
- Sistemas Operacionais: Windows e Mac OS;
- Possui recursos de lógica nebulosa e redes neurais artificiais apenas para processamento de imagens.

## **GRASS**

- Mais antigo SIG ainda em desenvolvimento e atividade. Iniciou em 1982 como um projeto de uma instituição militar americana. Teve seu desenvolvimento finalizado em 1996 e retomado no ano seguinte pela Universidade Baylor, tornando-se efetivamente um software livre. Encontra-se atualmente na versão 6.2;

- Software Livre, com desenvolvimento gerenciado por uma equipe denominada *GRASS Project Steering Committee*<sup>17</sup>;
- Sistemas Operacionais: GNU/Linux, Windows, Mac OS, entre outros;
- Disponibilizava, até a versão 4 um módulo para uso de lógica nebulosa em procedimentos de análise e combinação de imagens. Na versão atual, disponibiliza um módulo para utilização de uma rede neural artificial em procedimentos de classificação de imagens.

## **QGIS**

- Software com as funções básicas de um sistema de informações geográficas. Pode realizar procedimentos de análise espacial mais avançados através do GRASS, funcionando em paralelo à este *software*;
- Software Livre, também com desenvolvimento gerenciado por um *Project Steering Committee*;
- Sistemas Operacionais: GNU/Linux, Windows, Mac OS, entre outros;
- Não possui nenhum recurso próprio de análise de dados através de lógica nebulosa ou redes neurais artificiais.

## **MapWindow**

- Sistema de informações geográficas programável (extensível) que suporta a manipulação, análise e visualização de dados geográficos e seus atributos, em vários formatos de dados;
- Software Livre, com desenvolvimento gerenciado pelo *Geospatial Software Lab* da *Idaho State University*;
- Sistema Operacional: Windows;
- Não possui nenhum recurso próprio de análise de dados através de lógica nebulosa ou redes neurais artificiais.

---

17 “Comitê de gerenciamento” (tradução do autor).

### **gvSIG**

- Sistema de informações geográficas desenvolvido pelo governo da Comunidade Valenciana (Espanha) e pela Universidade Jaume I;
- Software livre, atualmente em processo de organização para receber colaboração externa;
- Sistemas Operacionais: GNU/Linux, Windows e Mac OS;
- Disponibiliza um módulo para análise de dados através de lógica nebulosa, desenvolvido pelo projeto SEXTANTE (Sistema de informações geográficas do Governo Regional de Extremadura, Espanha, e da Universidade de Extremadura).

### **SAMT**

- Spatial Analysis and Modelling Tool (Ferramenta para modelagem e análise espacial);
- Software Livre, desenvolvido pelo *Leibniz Centre for Agricultural Landscape Research*, Alemanha;
- Sistema Operacional: GNU/Linux, exigindo um grande conhecimento de computação para sua instalação;
- Foi projetado especificamente para uso de lógica nebulosa e redes neurais artificiais em procedimentos de modelagem ambiental, atividade que os autores consideram que tenha como característica principal a imprecisão, tanto nos dados como nas próprias técnicas para sua execução. Segundo eles, os sistemas de informação geográfica tradicionais são especializados em realizar análise espacial, produzir mapas e organizar dados para estes mapas, porém carentes de ferramentas de modelagem capazes de lidar com esta imprecisão (SAMT, 2008).

### **Spring**

- Sistema de processamento de informações georeferenciadas;
- Software acadêmico e gratuito, desenvolvido pelo INPE. Não pode ser considerado Software Livre porque não tem seu código-fonte disponível;
- Sistemas Operacionais: GNU/Linux e Windows;

- Disponibiliza um módulo denominado de AHP (Processo Analítico Hierárquico) que utiliza lógica nebulosa em seu processamento. Porém esta função do Spring gera como saída um programa que deverá ser alterado pelo usuário com as informações específicas sobre os dados nos quais deseja aplicar o procedimento, exigindo assim um conhecimento avançado de computação.

### **TerraView**

- Software com as funções básicas de manipulação de informações geográficas;
- Software Livre, com desenvolvimento feito apenas pelo INPE e seus parceiros. Não há contribuição direta de outros desenvolvedores no código-fonte;
- Sistemas Operacionais: GNU/Linux e Windows;
- Não possui nenhum recurso próprio de análise de dados através de lógica nebulosa ou redes neurais artificiais.

Analisando esta lista, verificamos que:

- Entre os *softwares* que disponibilizam recursos de análise de dados através da lógica nebulosa e/ou redes neurais artificiais, a maioria o faz apenas para procedimentos de tratamento de imagens, não sendo possível a utilização desses recursos para o processamento e análise de outros tipos de dados, como por exemplo dados sócio-econômicos associados a áreas (setores censitários, bairros ou municípios);
- Entre os programas que disponibilizam recursos de computação inteligente, a maioria é constituída por *software* proprietário. Isso faz com que as pesquisas que os utilizam tenham diminuída sua capacidade de geração de conhecimento, pois nem sempre estes softwares estão disponíveis nas instituições de pesquisa, devido ao alto custo de suas licenças, além de serem apenas ferramentas (fechadas) para se atingir algum resultado. Se estes *softwares* fossem livres, teríamos a possibilidade de ampliação da geração de conhecimento: como é uma ferramenta livre, qualquer outro pesquisador interessado em refazer (e avançar) essa pesquisa teria todas as ferramentas utilizadas a sua disposição. Adicionalmente, por serem livres, as próprias ferramentas podem ser objeto de pesquisa, já que se pode estudar seu funcionamento interno e contribuir para seu desenvolvimento<sup>18</sup>;

---

<sup>18</sup> Para uma reflexão adicional sobre este tema, consultar Pereira (2008).

- Existe uma grande carência de ferramentas que disponibilizem as técnicas ligadas as redes neurais artificiais.

Este trabalho vem, portanto, ao encontro destas necessidades, produzindo uma ferramenta computacional totalmente livre<sup>19</sup>, agregando as capacidades de análise de dados da lógica nebulosa e das redes neurais artificiais em um sistema de informações geográficas (TerraView). Adicionalmente, salientamos o caráter didático deste trabalho, apresentando também exemplos completos de utilização destas ferramentas, que poderão servir como guia ou mesmo base para a condução de outros estudos geográficos similares.

---

<sup>19</sup> Todo material referente a este trabalho (*software*, código-fonte, dados e textos) está disponível no link <http://starfightercarlao.blogspot.com/2008/08/doutorado-geoprocessamento-e-computao.html>

### Capítulo 3 GEOPROCESSAMENTO E COMPUTAÇÃO INTELIGENTE

Este capítulo se divide em três seções: na primeira é feita uma descrição das ferramentas computacionais utilizadas no desenvolvimento de um *software* para o processamento de informações geográficas utilizando técnicas da Computação Inteligente, e nas demais apresenta-se a fundamentação teórica de duas técnicas da Computação Inteligente (Lógica Nebulosa e Redes Neurais Artificiais), acompanhada de uma aplicação prática da técnica em um contexto de análise de informações geográficas.

Utilizaremos doravante neste texto o termo “mapa” em seu significado amplo, tal como definido por Dent (1985, p.3): “Maps are graphic representations of the cultural and physical environment. (A thematic map) shows the spatial distribution of some geographical phenomenon”<sup>20</sup>, para identificar as figuras que conterão os resultados obtidos pelos diversos procedimentos de análise de dados que serão realizados. O termo não deve ser entendido em seu significado cartográfico, pois as figuras aqui apresentadas não conterão os elementos fundamentais de uma representação cartográfica formal, tais como a escala e a orientação.

---

20 “Mapas são representações gráficas dos ambientes cultural e físico. (Um mapa temático) mostra a distribuição espacial de algum fenômeno geográfico” (tradução do autor).

### 3.1. Ferramentas utilizadas no desenvolvimento do *software* GAIA

Foi desenvolvida, como um dos objetivos deste trabalho, uma ferramenta computacional para auxiliar em procedimentos de produção e na análise de informações geográficas através da integração de técnicas de Computação Inteligente e ferramentas de Geoprocessamento, em especial um Sistema de Informações Geográficas (SIG). Esta ferramenta recebeu o nome de GAIA<sup>21</sup> — Geoprocessamento Apoiado por Inteligência Artificial.

Para agilizar seu desenvolvimento, o *software* GAIA foi construído como um sistema de apoio que deve ser utilizado em conjunto com o *software* TerraView, um SIG desenvolvido pelo Instituto Nacional de Pesquisas Espaciais e disponibilizado como *Software Livre*, isto é, qualquer pessoa tem acesso livre ao programa e a seu código-fonte, não só para utilizá-lo para qualquer objetivo (educacional, científico ou mesmo comercial) mas também e principalmente para estudar sua construção interna, podendo até realizar alterações em seu funcionamento, contribuindo assim com o seu desenvolvimento. Também o desenvolvimento e a disponibilização do GAIA seguirá esta filosofia<sup>22</sup>.

Tanto o GAIA quanto o TerraView foram desenvolvidos utilizando a biblioteca TerraLib, também desenvolvida pelo INPE e disponibilizada como *Software Livre* (CÂMARA et al, 2000). Uma biblioteca é um recurso computacional que agiliza o desenvolvimento de *software*, pois torna disponível um conjunto de “pequenos programas” (procedimentos e funções) que realizam atividades básicas e fundamentais, dentro da área de ação coberta pela biblioteca, permitindo assim que o programador concentre sua energia e o foco do seu trabalho nos objetivos finais da aplicação que ele quer criar, não tendo que despender tempo (re)criando soluções para estas necessidades básicas. A TerraLib é uma biblioteca que fornece funções para a decodificação de dados geográficos, estruturas de dados espaço-temporais e algoritmos de análise espacial, além de propor um modelo para um banco de dados geográficos (VINHAS; FERREIRA, 2005, p.383). Apresentamos na figura 15 um esquema representativo de como as tecnologias envolvidas serão interligadas para o desenvolvimento e funcionamento do GAIA:

---

21 O nome Gaia, Géia ou Gê, é utilizado como prefixo para designar as diversas ciências relacionadas com o estudo do planeta. Na mitologia grega, Gaia é a personificação da Terra como Deusa: “[...] de acordo com um dos primeiros mitos gregos sobre a criação, no princípio a Mãe Terra (Gaia) emergiu do caos. A seguir, deu nascimento a Urano, o deus celeste, enquanto dormia. Ele era seu filho e seu amante; das montanhas, olhando fixamente para baixo, para ela, fez cair a chuva fértil sobre as secretas fendas de sua mãe e ela produziu grama, flores e árvores e criou os pássaros e as feras” (SHELDRAKE, 1991, p.30).

22 GAIA está disponível no link

<http://starfightercarlaho.blogspot.com/2008/08/doutorado-geoprocessamento-e-computao.html>

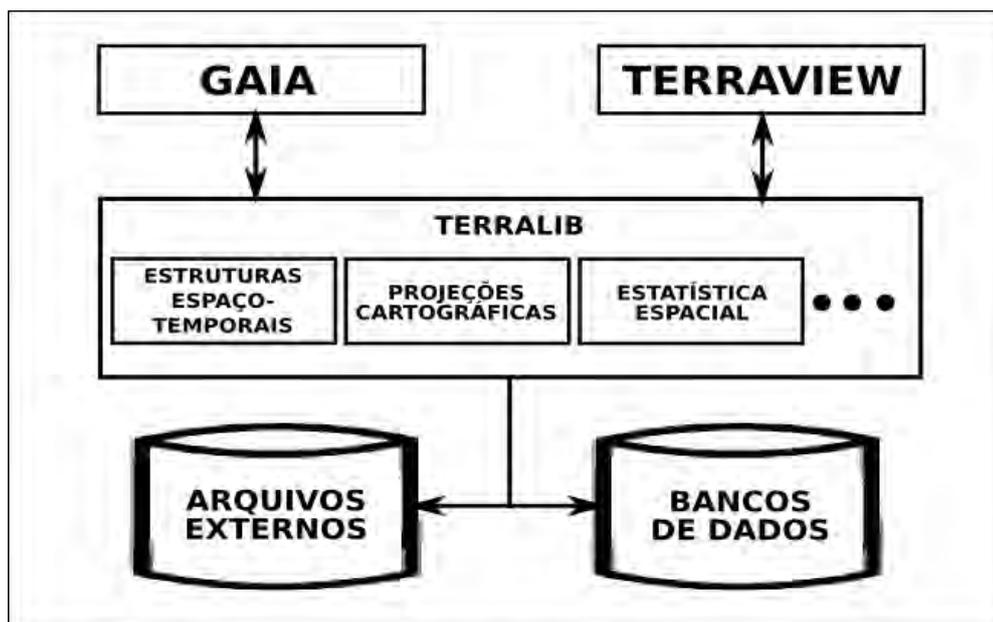


Figura 13: Integração entre o GAIA, o TerraView e a TerraLib.  
Adaptado de (VINHAS; FERREIRA, 2005, p.384).

A operação conjunta do GAIA com o TerraView permitirá que procedimentos básicos para a manipulação de informações geográficas, tais como importação de dados, definição de elipsóides de referência e projeções cartográficas, visualização gráfica de mapas, entre outras, serão realizadas pelo *software* TerraView. Este *software* é bastante poderoso e de utilização bem fácil, porém não traz nenhum recurso de análise de dados utilizando alguma técnica da computação inteligente. O GAIA será responsável, portanto, pela aplicação de técnicas provenientes da computação inteligente a esses dados.

Como podemos notar pela figura 15, o sistema opera sobre um banco de dados único, responsável por armazenar as informações geográficas que serão manipuladas. A TerraLib (e por consequência o TerraView e o GAIA) têm a capacidade de trabalhar com diversos Sistemas Gerenciadores de Bancos de Dados (SGBDs), tais como Oracle, Oracle Spatial, MySQL, PostgreSQL, PostGIS e Access<sup>23</sup>. Estes gerenciadores (com exceção do Access) permitem o funcionamento do GAIA e o TerraView em rede, isto é, os dados geográficos podem estar centralizados em apenas um computador, permitindo que vários pesquisadores utilizem esses dados em seus próprios computadores, através da rede. Optou-se, no âmbito deste trabalho, pela utilização do SGBD MySQL<sup>24</sup>, devido a sua facilidade de instalação e também pelo fato de ser *software* livre.

<sup>23</sup> Este SGBD só está disponível para o sistema operacional proprietário Microsoft Windows.

<sup>24</sup> <http://www.mysql.com>.

No desenvolvimento do GAIA utilizou-se, além da TerraLib, a biblioteca GTK+<sup>25</sup>, para a construção da interface gráfica com o usuário. O software foi desenvolvido nas linguagens de programação C e C++, no sistema operacional livre GNU/Linux (distribuição Ubuntu 7.10), utilizando-se o ambiente integrado de desenvolvimento (IDE) NetBeans. O processamento de dados via lógica nebulosa foi realizado através da biblioteca FISPRO (*Fuzzy Inference System Professional*, disponível em <http://www.inra.fr/internet/Departements/MIA/M/fispro/indexen.html>), desenvolvida pelo *Département de Mathématiques et Informatique Appliquées*, do *Institut national de la recherche agronomique*, França, e também disponibilizada como Software Livre.

Por se tratar de software livre, outros pesquisadores poderão adaptar o GAIA para funcionar em outros sistemas operacionais, tais como o Microsoft Windows ou Apple Mac OS X. A documentação completa do GAIA pode ser encontrada no anexo 1.

---

25 <http://www.gtk.org>.

## 3.2. Lógica Nebulosa

### 3.2.1. Fundamentação Teórica

Vimos, na introdução deste trabalho, que nossas tentativas de compreensão da realidade passam pela construção de modelos simplificados, ou seja, trabalhamos com um “subconjunto” da realidade. Os modelos são construídos visando o estudo de aspectos específicos (problemas específicos de uma área bem definida), e desta forma não explicam a realidade de uma maneira total:

As teorias científicas não estarão nunca aptas a fornecer uma descrição completa e definitiva da realidade. Serão sempre aproximações da verdadeira natureza das coisas. Em termos claros: os cientistas não lidam com a verdade; eles lidam com descrições da realidade limitadas e aproximadas (CAPRA, 1999, p.45).

Precisamos, portanto, discutir a noção de imprecisão e, em especial, buscar uma medida de associação entre a realidade que se deseja representar e o que efetivamente o modelo construído consegue representar. Esta é uma questão importante, pois como vimos tentamos inferir conhecimento acerca da realidade por analogia aos resultados obtidos utilizando o modelo construído. E certamente, a qualidade desses resultados depende diretamente do quanto o modelo consegue se aproximar da realidade.

Note-se que não se trata aqui de tentar **diminuir** ou **eliminar** a imprecisão associada ao modelo (atividade que, dada à complexidade da realidade, é impossível), mas sim, **levar em consideração** esta imprecisão, objetivando uma compreensão melhor do que se está deixando de fora do modelo.

Pode-se associar esta noção de imprecisão a dois aspectos distintos: o primeiro, com relação ao modelo em si e com a forma como ele é construído por meio da nossa linguagem. Apesar da linguagem natural ser a forma mais poderosa de comunicação e troca de informações entre os seres humanos, ela é, por sua própria natureza, vaga e imprecisa (ROSS, 1995). Desta forma, a imprecisão associada à nossa linguagem se reflete no modelo por ela descrito.

Esta imprecisão é, em especial, a dificuldade de atribuir significado preciso a regiões de fronteira, ou “região de sombra”, como nos fala Bertrand Russel (RUSSEL, 1923). Mais ainda, é a dificuldade de dar conta de aspectos “nebulosos” da realidade. Tomemos o exemplo da palavra “vermelho”. Se olharmos uma escala de cores, conseguimos discernir um grupo de

tonalidades ao qual podemos chamar com certeza de “vermelho” e um outro grupo que, de forma similar, podemos chamar de “amarelo”. Mas qual foi o ponto exato da mudança? Em que tonalidade o vermelho passou a ser amarelo? (figura 14)

The fact is that all words are attributable without doubt over a certain area, but become questionable within a penumbra, outside which they are again certainly not attributable. Someone might seek to obtain precision in the use of words by saying that no word is to be applied in the penumbra, but unfortunately the penumbra is itself not accurately definable, and all the vaguenesses which apply to the primary use of words apply also when we try to fix a limit to their indubitable applicability<sup>26</sup> (RUSSEL, 1923).

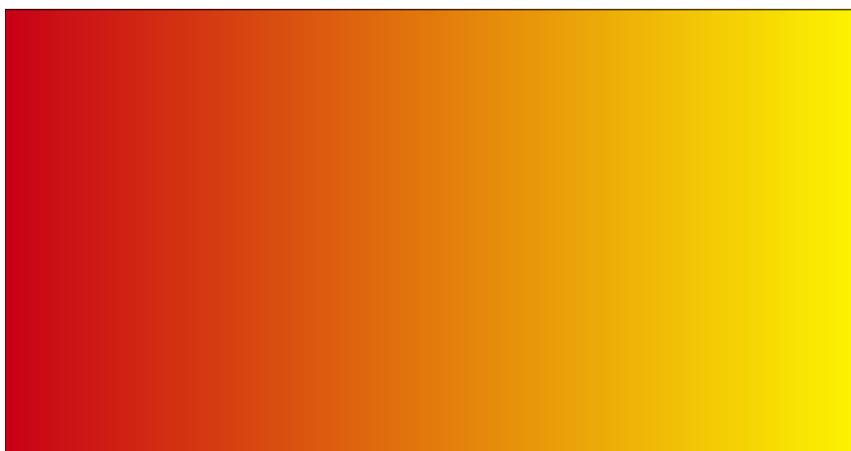


Figura 14: Onde termina o vermelho? Onde começa o amarelo?  
Fonte: Adaptado de Pereira (2005, p.29).

O segundo aspecto sobre a noção de imprecisão diz respeito à maneira como o ser humano raciocina acerca de um problema, de um objeto de estudo. Os seres humanos, em especial os pesquisadores empenhados no desenvolvimento de modelos da realidade, não possuem a informação completa para a solução dos problemas. Algumas das informações de que se dispõe são subjetivas, julgamentos pessoais por parte do pesquisador e não informação quantitativa precisa (ROSS, 1995). Ou seja, nem sempre tomamos uma decisão a partir de dados precisos, combinados com uma regra também precisa, que nos diz que decisão tomar em qualquer ocasião. Muitas vezes, nossas decisões são tomadas com base em julgamentos subjetivos e intuições.

---

26 “O fato é que qualquer palavra pode ser atribuída, com precisão, em uma certa área, mas seu uso se torna questionável dentro de uma região de sombra, após a qual a palavra se torna, com certeza, não-atribuível. Alguém poderia buscar a precisão no uso das palavras alegando que realmente não se pode atribuir nenhuma palavra na região de sombra, porém infelizmente esta própria sombra não pode ter seus limites precisamente definidos, e toda imprecisão que se aplica no uso primário das palavras também se aplica quando tentamos fixar um limite para sua indubitável aplicabilidade” (tradução do autor).

É nesse ponto que a lógica nebulosa (também chamada de lógica difusa), que se apóia na teoria dos conjuntos nebulosos, surge como ferramenta capaz de dar conta desta tarefa de construção de um modelo da realidade que leve em consideração o fator imprecisão. Entre os objetivos da lógica nebulosa, encontramos o de permitir um melhor tratamento matemático (e por consequência, computacional) de imprecisões, especialmente as encontradas como característica fundamental do raciocínio humano.

O conceito básico que sustenta a lógica nebulosa é o de uma variável linguística, isto é, uma variável cujos valores são palavras ao invés de números. Desta forma a lógica nebulosa pode ser vista como uma metodologia para computação com palavras ao invés de números. As palavras são inerentemente menos precisas que os números, porém seu uso é mais próximo da intuição humana (ZADEH, 2000). Enquanto os procedimentos computacionais tradicionais impõem uma precisão artificial em dados, processamentos e nos resultados finais desses processamentos, a utilização da lógica nebulosa, por sua vez, permite que essas imprecisões façam parte de todo o processo, seja nos dados inseridos no processamento, na própria definição do processamento a ser realizado, ou na apresentação dos resultados.

Para se entender o principal conceito por trás da lógica nebulosa, que é o de conjunto nebuloso, precisamos revisitar a teoria clássica dos conjuntos. A idéia principal a ser lembrada relativamente a essa teoria é a de pertinência de um elemento a um conjunto: um determinado elemento ou **pertence** a um conjunto, ou **não pertence** a este conjunto. Por exemplo, no conjunto “números pares menores que 10”, o elemento “2” pertence ao conjunto, enquanto que o elemento “3” não pertence ao conjunto. Utilizando a linguagem matemática, podemos utilizar a notação  $\chi_A(x)$  para indicar “pertinência do elemento x ao conjunto A”, e pelo que vimos, esse valor de pertinência só pode ser ou 1 (indicando que x pertence a A) ou 0 (indicando que x não pertence a A) (ROSS, 1995, p.11).

Notem-se os problemas que surgem quando esse conceito rígido é aplicado à forma de pensamento humano: caso se queira definir o conjunto “pessoas altas”, é preciso definir a medida a partir da qual a pessoa pode ser considerada alta, por exemplo, 1,80m. Desta forma, as pessoas que tivessem altura igual ou superior a 1,80m seriam consideradas “altas”, isto é, pertenceriam ao conjunto “pessoas altas”. Já as pessoas que tivessem altura inferior a 1,80m estariam fora desse conjunto. Ou seja, mesmo que a pessoa tivesse 1,7999m, ela não poderia ser considerada “alta”.

Como exemplo adicional podemos imaginar a necessidade de se selecionar, em uma determinada região, uma área para o estabelecimento de algum tipo de agricultura, e que tivéssemos as seguintes regras para definir a adequação dessa área:

- inclinação menor que  $30^\circ$ ;
- e
- fertilidade do solo igual ou maior que 60 (estabelecendo uma escala de 0 a 100, onde quanto maior o valor, maior a fertilidade do solo).

Encontramos, na região, três áreas possíveis, cada uma possuindo as seguintes características:

- Área 1:  
Inclinação:  $0^\circ$   
Fertilidade: 59
- Área 2:  
Inclinação:  $30,3^\circ$   
Fertilidade: 99
- Área 3:  
Inclinação:  $29,7^\circ$   
Fertilidade: 61

Segundo as regras estabelecidas e utilizando a teoria clássica dos conjuntos, a Área 3 seria a escolhida (já que é a única que efetivamente respeita as regras estabelecidas), enquanto que as outras duas áreas seriam descartadas. Mas claro está que a Área 3 é a pior de todas as três áreas apresentadas, pois:

- tem os seus dois parâmetros com valores muito perto do limite máximo permitido, enquanto que as outras áreas têm apenas um dos parâmetros nesta situação;
- os valores (válidos) apresentados pelos seus parâmetros são muito próximos dos valores (inválidos) dos parâmetros das outras áreas;
- o valor além do limite máximo apresentado por um dos parâmetros (no caso das duas primeiras áreas) faz com que o valor ótimo apresentado pelo outro parâmetro seja totalmente desconsiderado.

A teoria dos conjuntos nebulosos tenta diminuir esse problema, acabando com a rigidez da pertinência de um elemento a um conjunto. Em termos matemáticos, o valor da pertinência, em um conjunto nebuloso, **varia entre** 0 (não pertence com certeza) e 1 (pertence

com certeza), podendo assumir qualquer valor entre esses extremos. Se indicarmos a função de pertinência de um conjunto nebuloso por  $\mu_A(x)$ , ou seja, “pertinência do elemento  $x$  ao conjunto nebuloso  $A$ ” (ROSS, 1995, p.12), teremos:

$$\mu_A(x) = \alpha, \quad \alpha \in [0,1]$$

ou seja, o valor que estamos chamando de  $\alpha$  pode ser qualquer valor no intervalo entre 0 e 1.

No exemplo já visto de um conjunto “pessoas altas”, pode-se definir que, acima de 1m80cm a pessoa pode certamente ser considerada alta, e abaixo de 1m60cm a pessoa pode certamente ser considerada baixa (ou pelo menos, não alta). A partir de 1m60cm “vai se considerando” a pessoa alta. A diferença entre as duas abordagens fica mais clara na figura 14.

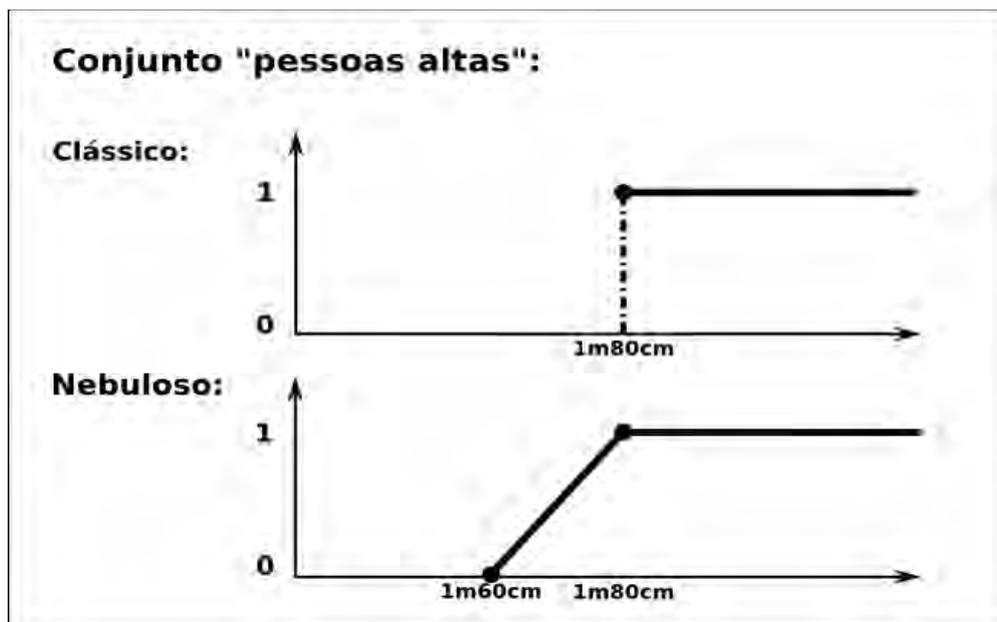


Figura 15: Comparação entre as teorias de conjuntos: clássica e nebulosa.  
Elaboração: Carlos José de Almeida Pereira.

Desta forma, uma pessoa com altura de 1m75cm teria pertinência no conjunto “pessoas altas” igual a 0,75. Outra pessoa, com altura igual a 1m64cm, teria pertinência no mesmo conjunto igual a 0,4. Ambos não pertenceriam “totalmente” ao conjunto “pessoas altas”, já que nenhum dos dois possui pertinência igual a 1. Porém, claramente se nota que a primeira pessoa “pertence mais” ao conjunto que a segunda pessoa (que “pertence pouco”).

Outro exemplo pode ser visto na tentativa de se estudar o grau de fertilidade do solo. Este grau pode ser estabelecido a partir de algumas características químicas, tais como “capacidade de troca de cátions” e “saturação por bases”. Na tabela 1, vemos como definir os níveis de fertilidade a partir dos valores dessas características químicas (BÖNISCH, 2001, p. 86).

Classes de Fertilidade	Capacidade de troca de cátions (cmolc/kg)	Saturação por bases (%)	Soma de bases (cmolc/kg)	Alumínio trocável (cmolc/kg)	Potássio (mg/kg)
Alta	$\geq 8$	$\geq 50$	$\geq 4$	$< 0,3$	$\geq 80$
Média	$\geq 6 \text{ e } < 8$	$\geq 35 \text{ e } < 50$	$\geq 2 \text{ e } < 4$	$\geq 0,4 \text{ e } < 1$	$\geq 45 \text{ e } < 80$
Baixa	$\geq 4 \text{ e } < 6$	$\geq 10 \text{ e } < 35$	$< 2$	$\geq 1 \text{ e } < 4$	$< 45$
Muito baixa	$< 4$	$< 10$	$< 2$	$\geq 4$	$< 45$

Tabela 1: Definição química das classes de fertilidade do solo.

Fonte: (BÖNISCH, 2001, p.86).

Vemos na tabela que o valor de “capacidade de troca de cátions” para que o solo seja considerado com alta fertilidade é maior ou igual a 8. Pela lógica tradicional, isso significa que se o valor dessa característica química for igual a 7,99999, o solo tem apenas um nível médio de fertilidade, não importando o quanto esse valor é próximo de 8. Ainda segundo a tabela, não importa se o valor é igual a 6,0 ou 7,9999, pois os dois valores pertencem da mesma forma à classe de fertilidade “média”.

A utilização da teoria dos conjuntos tradicional, aplicada conforme as definições apresentadas na tabela 1 impõe uma rigidez e precisão artificial a esses dados, além de perder muito do conhecimento subjetivo de um especialista sobre o tema. Como já vimos, a lógica nebulosa “quebra” essas barreiras rígidas, proporcionando uma transição mais suave (e também mais realista) entre as faixas de valores. Mais ainda, seria possível incorporar no processamento um conhecimento “subjetivo” de um especialista da área de solos, conhecimento esse que poderia ser expresso por frases tais como “o valor x é muito alto”, ou “a característica y é mais importante que a característica z”.

O objetivo final da aplicação desta técnica é a construção de um sistema de inferência nebulosa (fuzzy inference system, ou FIS) para manipulação de informações geográficas, composto de:

- conjuntos nebulosos para os diversos valores das diversas variáveis de entrada, bem como para os valores da variável de saída (resultado do processamento);
- regras, no formato “se...então” relacionando os valores das diversas variáveis de entrada (utilizando operadores lógicos E e OU) aos valores da variável de saída.

As regras são as responsáveis por relacionar as variáveis de entrada, isto é, os conjuntos nebulosos que descrevem os dados sobre os quais busca-se um processamento, às variáveis de saída (o resultado do processamento). Como já apresentado, a escolha das regras tem como ponto de partida, além da análise do próprio processo em si, a experiência dos especialistas que com ele trabalham (GALVÃO; VALENÇA, 1999, p.181).

O conhecimento subjetivo do especialista definindo o sistema é representado não só na elaboração dos conjuntos nebulosos (“o que é um valor alto?”, “que valor deixa dúvidas entre alto e médio?”) mas também na fase de elaboração das regras. Por exemplo, se o valor da característica química “capacidade de troca de cátions” for mais importante que a “saturação por bases”, a regra pode refletir esse conhecimento, dando uma maior importância ao valor da primeira variável do que ao valor da segunda variável.

Uma característica dos sistemas de raciocínio nebuloso que cabe destacar é o fato de que todas as regras contribuem ao mesmo tempo para se chegar ao resultado final do processamento, diferente de outros tipos de sistemas e modelos onde existe uma aplicação serial de regras (isto é, as regras são aplicadas uma após a outra). Esta é uma característica de similaridade com o raciocínio humano, onde vários fatores (pensamentos, informações, experiências, intuições) contribuem, ao mesmo tempo, para que uma pessoa chegue a uma decisão final, a uma conclusão sobre um determinado assunto.

De forma resumida, um sistema de inferência nebulosa funciona da seguinte forma:

- recebe os valores das entradas;
- calcula o valor de pertinência das entradas com base na definição de seus conjuntos nebulosos (esta etapa é chamada de “difusificação”<sup>27</sup> das entradas);

---

27 Processo de tornar difuso. Apesar dos termos “fuzificação” e “defuzificação” serem muito utilizados na literatura acerca da lógica nebulosa, correspondendo aos termos em inglês *fuzzyfying* e *defuzzyfying*, optou-se nesse trabalho pela utilização de expressões derivadas na língua portuguesa, respectivamente, “difusificação” e “desdifusificação”. Estes termos denominam, respectivamente, o processo de transformação de um valor numérico em um grau de pertinência relativo a um certo conjunto nebuloso (valor entre 0 e 1) e o processo contrário de transformação deste grau de pertinência em um valor numérico qualquer que vai representar o resultado gerado pelo sistema de inferência nebulosa.

- combina os valores de pertinência relativos as entradas na forma especificada por cada regra (por exemplo, “SE entrada1 é baixa E entrada2 é alta...”), gerando um novo valor de pertinência geral para as entradas de cada regra;
- utiliza este valor de pertinência único gerado para cada regra para definir um subconjunto do conjunto nebuloso de saída, conforme definido pela regra em questão (continuando o exemplo anterior, “SE ... ENTÃO saída é média”);
- combina todos os subconjuntos gerados pelas regras em um único conjunto nebuloso de saída;
- calcula um valor numérico único representativo deste conjunto nebuloso de saída (esta etapa é chamada de “desdifusão” da saída).<sup>28</sup>

### 3.2.2. Aplicação

A primeira funcionalidade implementada no *software* GAIA foi um sistema de inferência nebuloso espacial, isto é, utilização da lógica nebulosa para a análise de informações espaciais. Esta funcionalidade foi testada usando-se o exemplo de estudo do grau de fertilidade do solo visto anteriormente (BÖNISCH, 2001), onde a autora apresenta um conjunto de locais (pontos) no estado de Santa Catarina junto com as propriedades químicas de cada local (valores de capacidade de troca de cátions [CTC] em cmolc/kg, saturação por bases [V] em %, soma de bases [S] em cmolc/kg, alumínio trocável [AL] em cmolc/kg e potássio [K] em mg/kg). Adicionalmente, a autora apresenta uma tabela (BÖNISCH, 2001, p. 86) que define como as faixas de valores dessas propriedades químicas se combinam para definir os níveis de fertilidade do solo (tabela 1). Como o objetivo principal aqui é observar as diferenças entre o uso de técnicas tradicionais e técnicas provenientes da computação inteligente, optamos pela redução do número de características (propriedades químicas) que serão abordadas, visando uma simplificação do sistema de inferência nebuloso resultante. Desta forma, utilizaremos apenas as características “saturação por bases”, “soma de bases” e “alumínio trocável”.

A partir dos dados disponíveis, foi preparado um arquivo com as coordenadas e as propriedades químicas de cada ponto. Inserimos este arquivo em um banco de dados geográficos criado pelo TerraView, juntamente com um mapa com os limites do estado de Santa Catarina, conforme pode-se ver na figura 16:

---

<sup>28</sup> Para detalhes de cálculos, incluindo algoritmo para implementação computacional, ver Cox (1994).

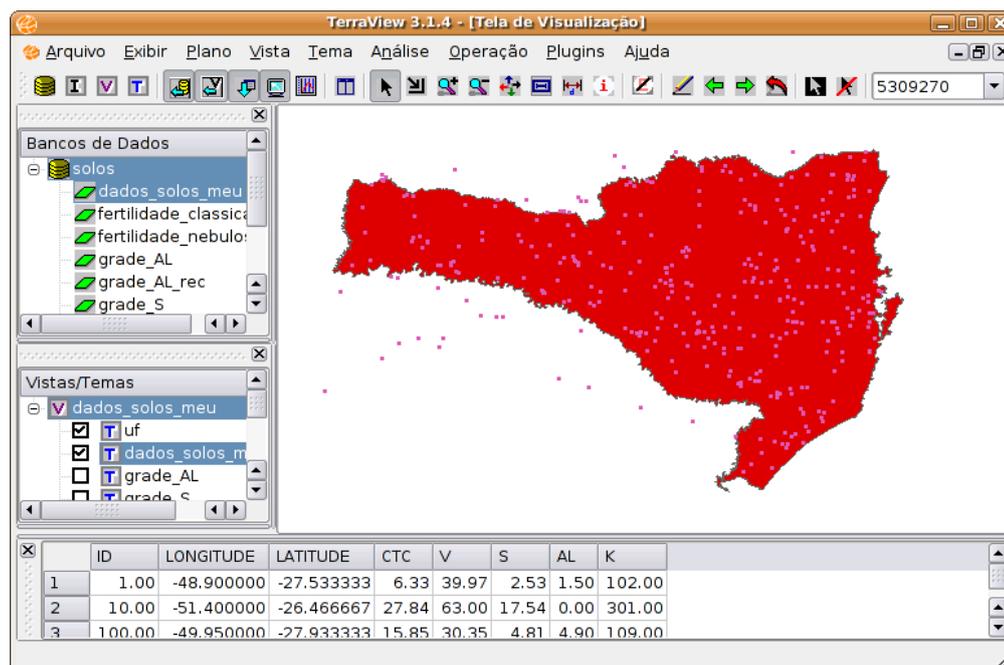


Figura 16: Pontos, propriedades químicas e limites do estado de Santa Catarina.  
Elaboração: Carlos José de Almeida Pereira.

Precisamos dos valores dessas propriedades químicas não apenas para alguns pontos específicos, mas sim para todos os pontos da área em estudo. Isto é conseguido através da geração de um Modelo Numérico de Terreno (MNT), que é a representação de uma grandeza que varia continuamente no espaço. Esta grandeza é comumente associada à altimetria, mas os MNT também podem ser utilizados para modelar unidades geológicas, como teor de minerais ou propriedades do solo ou subsolo (CÂMARA et al, 1996, p.43).

Pode-se representar um MNT de duas formas: através de grades regulares ou grades triangulares. Uma grade regular é uma matriz de elementos com espaçamento fixo, onde a cada elemento é associado o valor estimado da grandeza na posição geográfica relativa a este elemento. Esta é a forma adotada pelo TerraView para a representação de modelos numéricos de terreno. Porém o TerraView não fornece uma funcionalidade para geração desta grade regular a partir de dados associados a pontos (interpolação). Desta forma, optamos por desenvolver e suprir esta funcionalidade a partir do GAIA<sup>29</sup>. A figura 17 apresenta o resultado do uso desta funcionalidade para a propriedade química alumínio:

<sup>29</sup> Para uma descrição do funcionamento de alguns métodos de interpolação disponíveis no sistema de informações geográficas SPRING, também desenvolvido pelo INPE, consultar <http://www.dpi.inpe.br/spring/portugues/tutorial/modelagem.html>. O método de interpolação utilizado no GAIA foi o denominado de “média ponderada”.

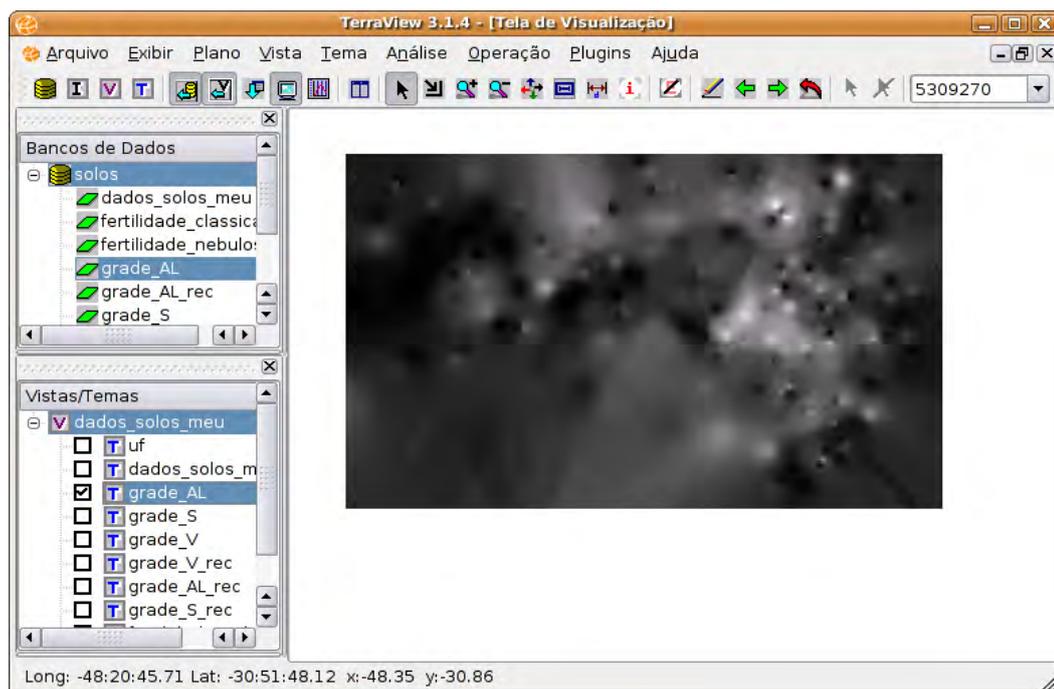


Figura 17: Grade regular gerada pelo GAIA para a propriedade química alumínio.  
Elaboração: Carlos José de Almeida Pereira.

Na visualização de grades regulares, o TerraView representa o maior valor com a cor branca, o menor valor com a cor preta, e os valores intermediários em tons de cinza. Esta não é a forma mais adequada, conforme atestam Dent (1985, p.360) e Garo (1998), como pudemos ver anteriormente na descrição conceitual do tipo de dado numérico (p.34). A forma mais adequada para esta representação seria a cor branca para o menor valor e cor preta para o maior valor. Como a única forma a nosso alcance para remediar isso seria a geração de uma grade de valores invertida (o que impossibilitaria as análises posteriores) teremos que aceitar essa limitação do software neste momento, mas ressaltando a necessidade de uma discussão sobre questões de comunicação da informação geográfica nas ferramentas de geoprocessamento disponíveis, pois como nos fala Dent (1984, p.3): “Map making must always be viewed in the context of communication”<sup>30</sup>.

Outra funcionalidade importante, não disponibilizada pelo TerraView, é a que permite recortar uma grade numérica a partir de um outro mapa, como por exemplo, os limites de um Estado. Como os pontos que geram a grade regular se encontram, em sua grande maioria, no interior do Estado de Santa Catarina, os valores dessa grade fora dos limites deste Estado não representam valores confiáveis para serem usados na confecção do mapa final de fertilidade do solo. Desta forma, optou-se pela implementação no GAIA de mais esta funcionalidade. O resultado de sua utilização é apresentado na figura 18:

30 “A construção de mapas deve sempre estar inserida no contexto da comunicação” (tradução do autor).

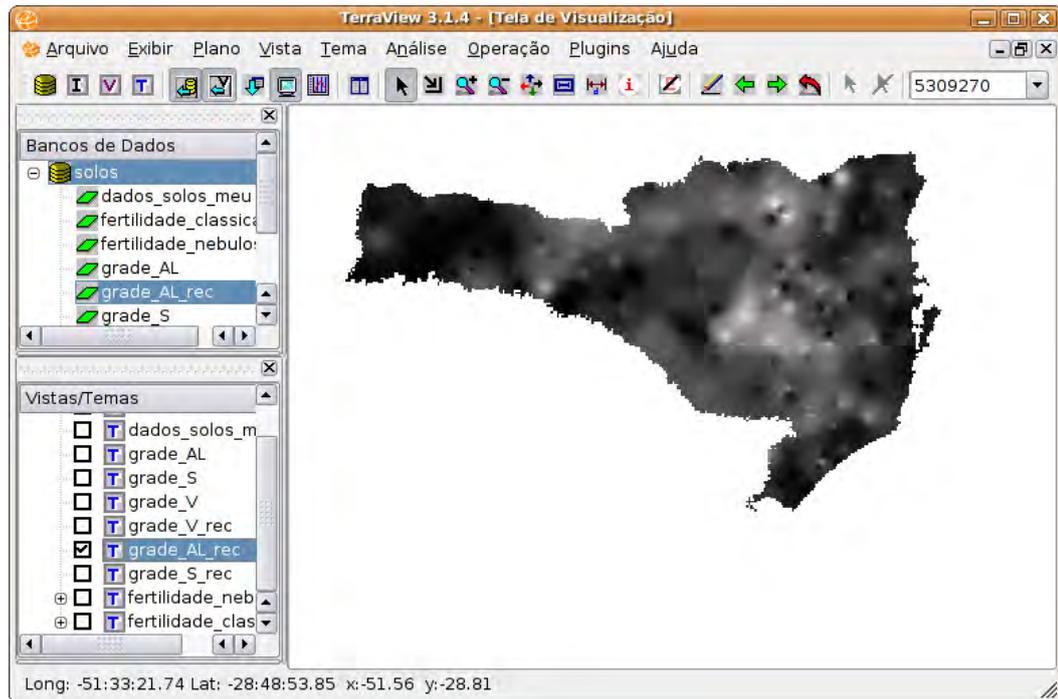


Figura 18: Grade regular recortada usando os limites do Estado.  
Elaboração: Carlos José de Almeida Pereira.

Após essas atividades preliminares, podemos enfim buscar nosso objetivo principal, que é o de gerar um mapa temático com as classes de fertilidade, conforme os dados apresentados na tabela 1 (página 59). Geraremos este mapa em duas versões, uma baseada na teoria dos conjuntos clássica e outra, utilizando a teoria dos conjuntos nebulosos e um sistema de inferência nebuloso.

Como visto na tabela 1, cada classe de fertilidade do solo é o resultado de uma combinação de classes que representam faixas de valores das propriedades químicas. Por exemplo, a classe de fertilidade “alta” é resultado da combinação de um valor “alto” da propriedade “saturação por bases” (classe de valores iguais ou maiores que 50) com um valor também “alto” da propriedade “soma de bases” (valores iguais ou maiores que 4) e finalmente com um valor “muito baixo” da propriedade “alumínio trocável” (valores abaixo de 0,3). Precisamos pois, antes de produzir o mapa final de classes de fertilidade do solo, definir e visualizar essas classes de valores para cada propriedade química sendo abordada.

A classificação de cada propriedade química conforme as faixas de valores definidas na tabela 1 é uma funcionalidade trivial de qualquer SIG, não sendo o TerraView uma exceção. Observamos na figura 19 um mapa temático criado a partir do MNT “alumínio”:

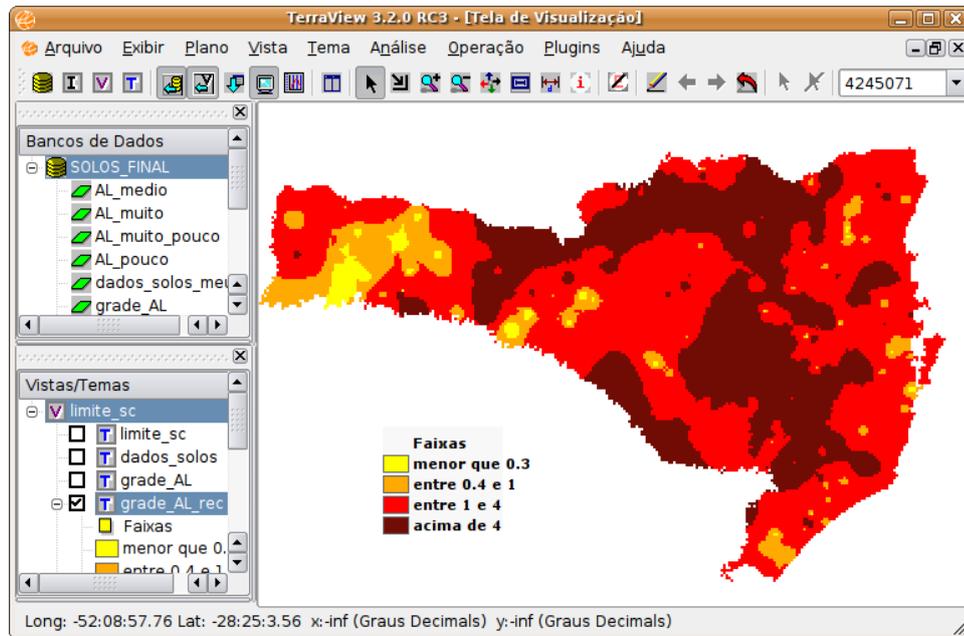


Figura 19: Classes para a propriedade química “Alumínio trocável”.  
Elaboração: Carlos José de Almeida Pereira.

Podemos notar na figura 19 a imposição de limites rígidos aos dados, conforme discutimos na fundamentação teórica. Por exemplo, a classe representada pela cor vermelha agrega os pontos com valores entre 1 e 4. Pela teoria dos conjuntos tradicional, valores tais como 0,99999 e 4,00001 estão fora dessa classe. Da mesma forma, valores tais como 1,00001 e 3,99999 são considerados pertencentes a esta classe de forma igual, mesmo estando o primeiro tão perto do limite inferior e o segundo tão perto do limite superior

Como vimos anteriormente, a teoria dos conjuntos nebulosos tenta quebrar esta rigidez, permitindo a definição de uma “faixa de transição” como limites entre os conjuntos. Assim, um exemplo de definição “nebulosa” das classes relativas a propriedade química “alumínio” poderia ser como apresentada na figura 20:

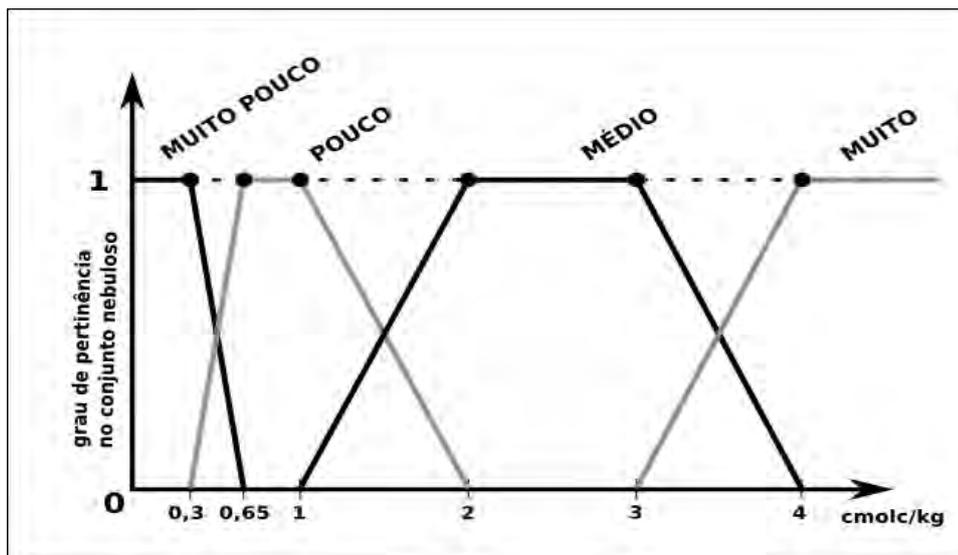


Figura 20: Conjuntos nebulosos hipotéticos para a propriedade química “Alumínio trocável”.

Elaboração: Carlos José de Almeida Pereira.

O conjunto “muito pouco”, pela teoria dos conjuntos tradicional, engloba todos os valores menores ou iguais a 0,3. Pela teoria dos conjuntos nebulosos, e com base na definição acima, os valores tem variados graus de pertinência ao conjunto, não apenas “pertencem” ou “não pertencem”. Assim, valores menores que 0,3 pertencem totalmente ao conjunto (isto é, seu valor de pertinência é igual a 1). A partir de 0,3, a pertinência dos valores vai caindo, até chegar a 0 para o valor 0,65, indicando que este valor não pertence ao conjunto. Não coincidentemente, conforme a pertinência dos valores vai caindo com relação ao conjunto “muito pouco”, esta mesma pertinência vai subindo com relação ao conjunto “pouco” (ou seja, os valores vão “pertencendo menos” ao conjunto “muito pouco” e “pertencendo mais” ao conjunto “pouco”).

É importante relembrar e ressaltar aqui que não é objetivo deste trabalho fazer um estudo profundo das classes de fertilidade do solo, nem das classes das propriedades químicas que são importantes para este estudo. Também não é de domínio deste autor a teoria por trás do estabelecimento dos limites dessas classes. Desta forma, os valores aqui apresentados foram definidos com o objetivo principal de mostrar a diferença entre o estabelecimento de limites conforme a teoria dos conjuntos clássica e conforme a teoria dos conjuntos nebulosos.

O *software* GAIA permite a criação de novas grades regulares (MNT) cujos valores são graus de pertinência, calculados com base em uma definição de um conjunto nebuloso. Esta definição é feita a partir de quatro valores que representam, respectivamente: a) o valor em que a pertinência deixa de ser zero; b) o valor em que a pertinência se torna 1; c) o valor em que a pertinência deixa de ser 1 e d) o valor em que a pertinência torna a ser zero

novamente. Se o conjunto inicia ou termina com pertinência igual a 1, basta repetir os valores dos dois primeiros ou dois últimos parâmetros. A figura 21 mostra os diversos tipos de conjuntos nebulosos que podem ser criados a partir desses quatro parâmetros:

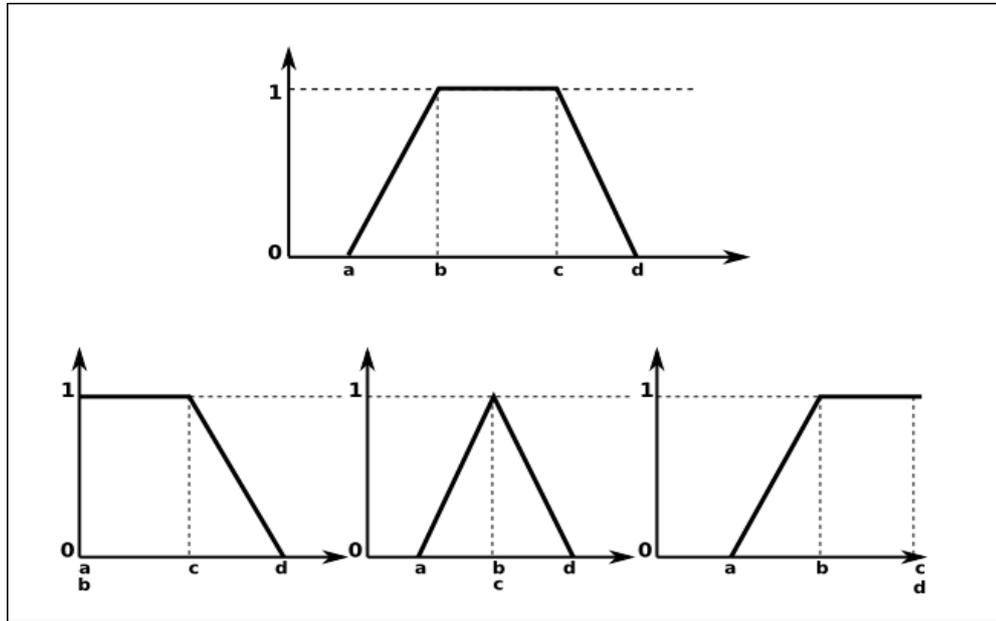


Figura 21: Vários tipos de conjuntos definidos a partir de quatro parâmetros.  
Elaboração: Carlos José de Almeida Pereira.

Dessa forma, os parâmetros para definir os quatro conjuntos nebulosos relativos à propriedade química “alumínio” são:

- “muito pouco”
  - a = “menor” (significa o menor valor da grade original)
  - b = “menor”
  - c = 0,3
  - d = 0,65
- “pouco”
  - a = 0,3      b = 0,65      c = 1      d = 2
- “médio”
  - a = 1      b = 2      c = 3      d = 4
- “muito”
  - a = 3
  - b = 4
  - c = “maior” (significa o maior valor da grade original)
  - d = “maior”

A partir dos parâmetros definidos acima foram criadas quatro grades, denominadas “AL\_muito\_pouco”, “AL\_pouco”, “AL\_medio” e “AL\_muito” respectivamente. Podemos visualizar essas grades da mesma forma que visualizamos a grade original com os valores da propriedade química “alumínio”, não esquecendo que agora os valores da grade são valores de pertinência, ou seja, valores **entre** 0 e 1. O TerraView vai automaticamente exibir valores 0 como preto, valores 1 como branco, e valores intermediários como tons de cinza. Apresentamos os conjuntos acima descritos nas figuras 22, 23, 24 e 25:

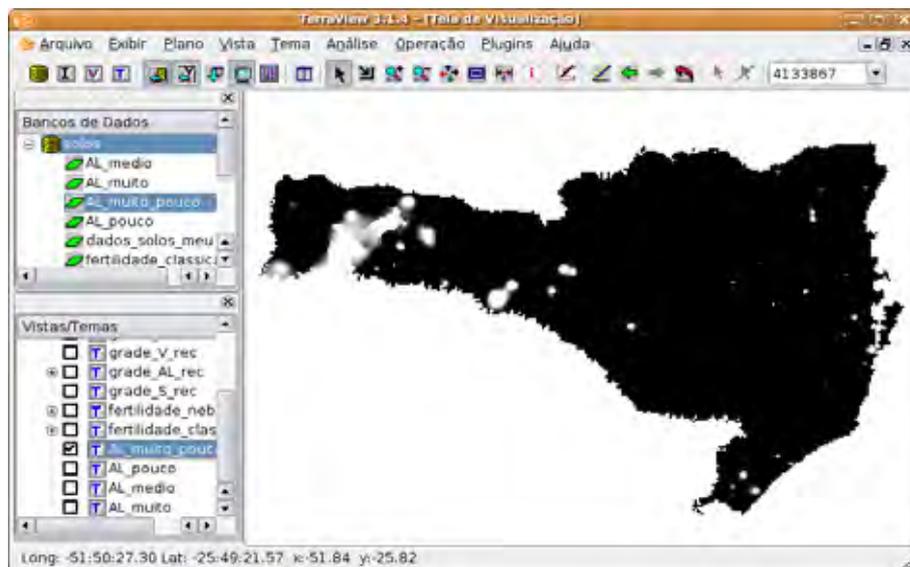


Figura 22: Conjunto nebuloso AL\_muito\_pouco.  
Elaboração: Carlos José de Almeida Pereira.

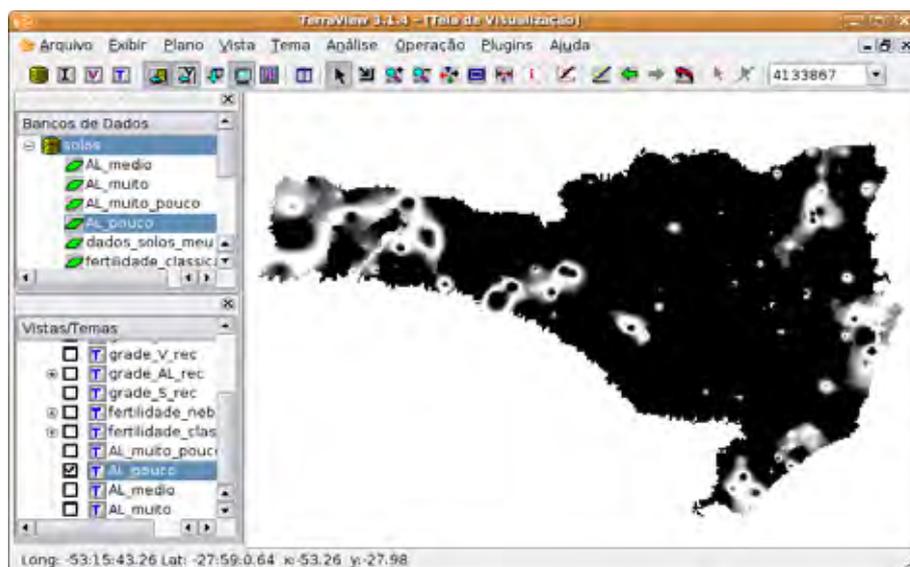


Figura 23: Conjunto nebuloso AL\_pouco.  
Elaboração: Carlos José de Almeida Pereira.

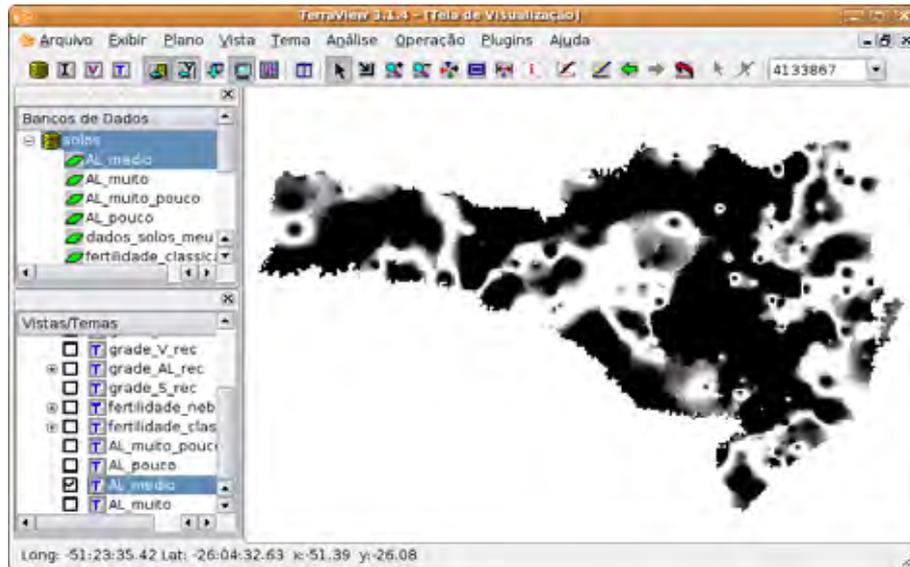


Figura 24: Conjunto nebuloso AL\_medio.  
Elaboração: Carlos José de Almeida Pereira.

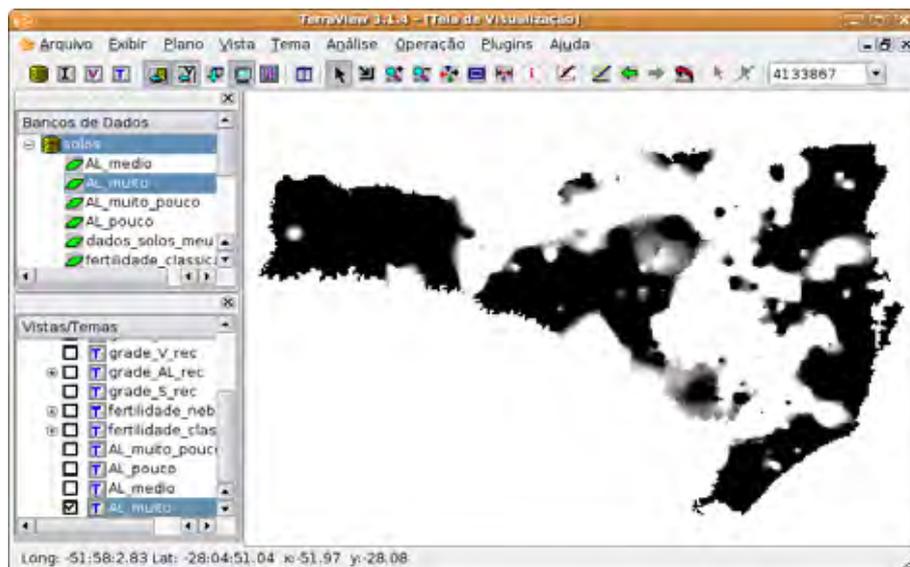


Figura 25: Conjunto nebuloso AL\_muito.  
Elaboração: Carlos José de Almeida Pereira.

Já podemos notar um ganho de informação através da utilização da lógica nebulosa como alternativa a métodos tradicionais. Nos mapas gerados através da lógica nebulosa, não existem os limites rígidos entre as classes, como no caso mostrado anteriormente na figura 19.

Repete-se todo o procedimento de criação de conjuntos nebulosos descrito para as propriedades químicas “saturação por bases” (V) e “soma de bases” (S).

O passo final é a produção do mapa temático de fertilidade do solo. O método baseado na lógica tradicional (teoria clássica dos conjuntos) consiste em verificar o valor da propriedade química em cada grade de entrada, e conforme a classe que se situa cada valor,

define-se a classe de fertilidade do solo resultante. Por exemplo, se determinado ponto tiver os seguintes valores de propriedades químicas:  $V = 62$ ,  $S = 6,5$  e  $AL = 0,12$ , então este ponto pertence a classe de fertilidade do solo “alta”.

Mesmo sendo esta uma forma tradicional de realizar esta classificação, o TerraView não tem esta funcionalidade. O *software* SPRING é capaz de realizar esta tarefa, porém é preciso que o próprio usuário escreva um programa para este fim, utilizando a linguagem de programação fornecida pelo próprio *software* (linguagem LEGAL) (BARBOSA, 1997). Resolvemos então dotar o *software* GAIA desta funcionalidade. O resultado dessa classificação é apresentado na figura 26.

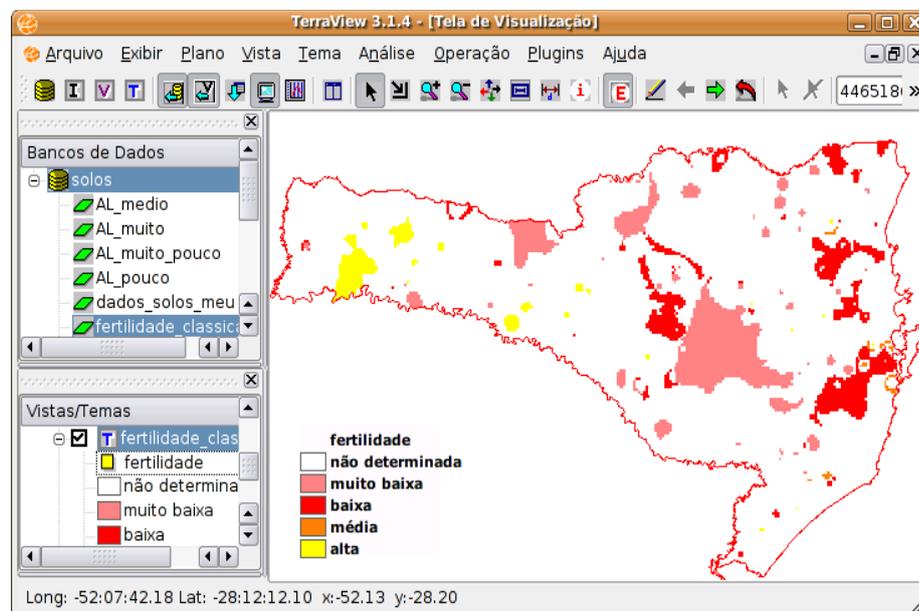


Figura 26: Classes de fertilidade através do método convencional.  
Elaboração: Carlos José de Almeida Pereira.

Na figura 26, vale ressaltar uma característica importante: na cor branca, estão representados os pontos PARA OS QUAIS NÃO FOI POSSÍVEL DEFINIR UMA CLASSE DE FERTILIDADE, isto é, um ponto cujas propriedades químicas não se encaixaram em nenhuma das quatro regras possíveis. Outro detalhe que devemos observar é novamente a existência de limites rígidos para as classes geradas.

No sistema de inferência nebuloso, também temos as regras que relacionam as várias classes de valores das propriedades químicas com as classes de fertilidade do solo, porém com duas diferenças: primeira, precisamos criar conjuntos nebulosos que irão representar a saída

do sistema, pois essa saída também respeita a idéia de não rigidez que usamos na entrada, ou seja, o sistema não vai responder de forma precisa que a fertilidade é “alta” ou “média”, mas sim gerar um valor numérico que vai indicar o grau de pertencimento daquele ponto em uma classe específica (por exemplo, os valores 8,2 e 9,5 podem estar ambos dentro da classe “fertilidade alta”, porém o ponto que recebeu o valor 9,5 tem uma maior fertilidade do que a do ponto que recebeu o valor 8,2).

Os conjuntos nebulosos utilizados neste exemplo são os mostrados na figura 27:

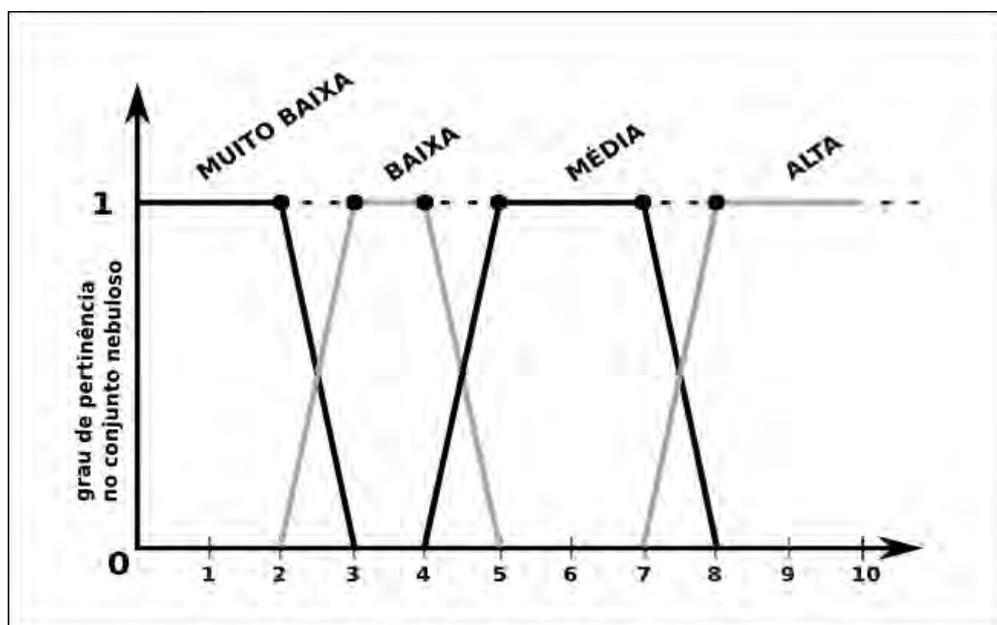


Figura 27: Conjuntos nebulosos para as classes de fertilidade do solo.  
Elaboração: Carlos José de Almeida Pereira.

Ressaltamos que a definição dos conjuntos apresentados acima deve ser entendida como meramente ilustrativa do processo de criação de um sistema de inferência nebulosa, pois somente um especialista da área de solos poderia definir satisfatoriamente esses conjuntos, a partir de seu conhecimento específico. Por exemplo, pode ser que um solo com alto grau de fertilidade seja muito difícil de se encontrar; isto faria com que o conjunto nebuloso denominado “alta” tivesse uma amplitude bem menor, iniciando no valor 9.

A segunda diferença está na definição das regras, que podem expressar várias combinações de conjuntos de entrada e conjunto(s) de saída, permitindo assim um registro melhor das relações existentes entre os dados (neste caso, entre as várias classes de valores das propriedades químicas do solo). Um exemplo para ilustrar: vamos imaginar que a propriedade “soma de bases” tem uma influência menor que a propriedade “saturação por

bases” na definição do grau de fertilidade. Um conjunto de regras possível para expressar esse fato poderia ser:

- se “saturação” é **muita** e “soma” é **muita**, então a fertilidade é “**alta**”
- se “saturação” é **muita** e “soma” é **média**, então a fertilidade é “**alta**”

Ou seja, uma mudança de classe da propriedade “soma” não foi suficiente para diminuir o grau de fertilidade do solo.

O *software* GAIA permite a definição das regras de combinação dos conjuntos nebulosos já criados, além de realizar o processamento do sistema de inferência nebuloso assim criado. O conjunto de regras criado para este exemplo é o que segue:

(V: saturação por bases; S: soma de bases; AL: alumínio trocável; F: fertilidade)

- Se V é “muita” -E- S é “muita” -E- AL é “muito pouco”, então F é “alta”
- Se V é “média” -E- S é “muita” -E- AL é “muito pouco”, então F é “alta”
- Se V é “muita” -E- S é “muita” -E- AL é “pouco”, então F é “alta”
- Se V é “média” -E- S é “muita” -E- AL é “pouco”, então F é “média”
- Se V é “muita” -E- S é “média” -E- AL é “muito pouco”, então F é “alta”
- Se V é “muita” -E- S é “média” -E- AL é “pouco”, então F é “média”
- Se V é “média” -E- S é “média” -E- AL é “muito pouco”, então F é “média”
- Se V é “média” -E- S é “média” -E- AL é “pouco”, então F é “média”
- Se V é “pouca” -E- S é “média” -E- AL é “pouco”, então F é “média”
- Se V é “média” -E- S é “média” -E- AL é “média”, então F é “média”
- Se V é “pouca” -E- S é “média” -E- AL é “média”, então F é “baixa”
- Se V é “média” -E- S é “pouca” -E- AL é “pouco”, então F é “média”
- Se V é “média” -E- S é “pouca” -E- AL é “média”, então F é “baixa”
- Se V é “pouca” -E- S é “pouca” -E- AL é “pouco”, então F é “baixa”
- Se V é “pouca” -E- S é “pouca” -E- AL é “média”, então F é “baixa”
- Se V é “pouca” -E- S é “pouca” -E- AL é “muito”, então F é “muito baixa”
- Se V é “muito pouca” -E- S é “pouca” -E- AL é “muito”, então F é “muito baixa”
- Se V é “muito pouca” -E- S é “pouca” -E- AL é “médio”, então F é “muito baixa”

O resultado final do processamento do sistema de inferência nebulosa é apresentado na figura 28:

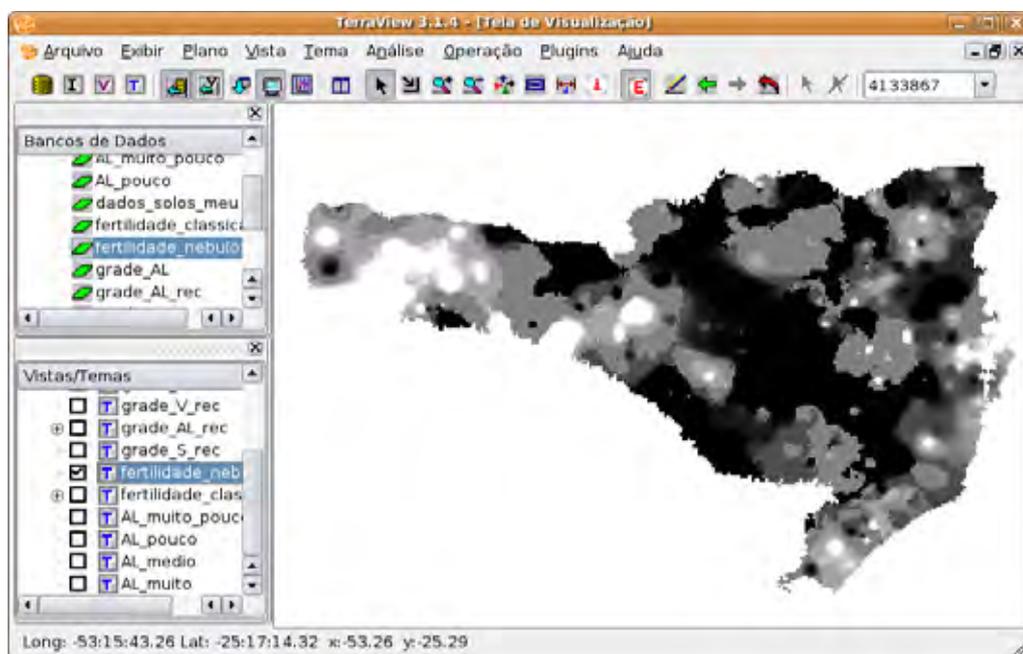


Figura 28: Classes de fertilidade do solo processadas através da lógica nebulosa.  
Elaboração: Carlos José de Almeida Pereira.

O que está sendo representado neste mapa é a grade regular gerada pelo processamento do sistema de inferência nebuloso, ou seja, é uma grade composta pelos valores definidos para os conjuntos nebulosos de saída do sistema (neste exemplo, valores de 0 até 10. Quanto maior o valor, maior o grau de fertilidade do solo). Novamente, o TerraView representa o menor valor da grade com a cor preta, e o maior valor com a cor branca, usando tons de cinza para os valores intermediários.

Podemos inclusive utilizar esta grade gerada para gerar classes (não nebulosas) de valores de fertilidade do solo, utilizando os recursos nativos do TerraView. Ainda assim, como mostra a figura 29, teremos uma quantidade muito maior de informação do que a obtida através do método tradicional (fig. 26).

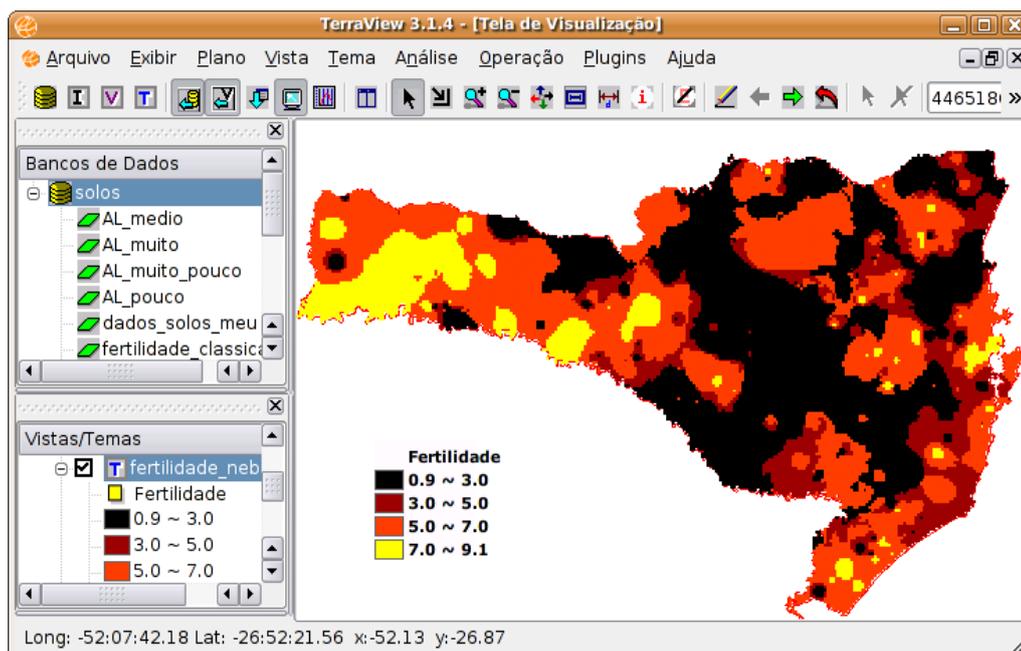


Figura 29: Mapeamento temático da grade resultante do sistema de inferência nebuloso.  
Elaboração: Carlos José de Almeida Pereira.

Podemos concluir, através da comparação visual entre os mapas temáticos gerados pelo método baseado na lógica tradicional e pelo sistema de inferência nebulosa (figuras 26 e 28 respectivamente), que existe uma vantagem na utilização do segundo perante o primeiro (maior quantidade de informações resultantes do processamento e não-rigidez dos limites das classes de fertilidade).

Adicionalmente, para uma validação mais formal das vantagens do método “nebuloso” perante o método “tradicional”, podemos nos remeter a outros trabalhos que utilizaram o primeiro método como uma alternativa para a classificação temática e seu consequente mapeamento (WANG; SUBARYONO, 1990; CHANG; BURROUGH, 1987; BURROUGH, 1989). Outros dois trabalhos tiveram, entre seus objetivos, o de realizar uma comparação entre esses métodos.

Oliveira (1994, *apud* MEIRELLES, 1997) comparou a utilização dos dois métodos no estudo de áreas com umidade. O autor observou que muitas áreas consideradas como possuindo uma umidade deficiente no mapa gerado pela lógica tradicional, seriam consideradas aproveitáveis através da utilização da lógica nebulosa, ou seja, algumas áreas que seriam rejeitadas para o uso agrícola, por exemplo, não o seriam com a utilização dos critérios de classificação provenientes da lógica nebulosa e processados através de um sistema de inferência nebulosa.

Meirelles (1997) atesta a grande utilização da teoria dos conjuntos nebulosos em estudos na área de solos. Para esta autora, na estruturação de sistemas de informação sobre solos, a classificação contínua possibilita o armazenamento de dados imprecisos e a recuperação de informações através de uma linguagem natural. Neste trabalho, a autora descreve os problemas e erros que podem ser causados e acumulados pela utilização da lógica tradicional, como no exemplo de um estudo de aptidão agrícola onde se realiza a combinação de um mapa de fertilidade (que já descarta áreas que poderiam ser consideradas aceitáveis) com os mapas de outros parâmetros envolvidos (drenagem do solo, erodibilidade, etc.) e que contenham também este mesmo tipo de limitação. O resultado final, após a acumulação dos erros provenientes de cada parâmetro, acabará por indicar como aptas à produção agrícola áreas muito restritas, o que pode não refletir a realidade.

A autora conclui pela melhoria que a lógica nebulosa traz na representação dos fenômenos da realidade:

A lógica *fuzzy* pode não ser o instrumento perfeito para a representação da realidade e do ambiente em que se vive, uma vez que um modelo sempre representará a realidade de forma simplificada. No entanto, o uso da classificação *fuzzy* pode, indubitavelmente, contribuir para a melhoria desta representação (MEIRELLES, 1997, cap.7, p.6).

### 3.3. Redes Neurais Artificiais

#### 3.3.1. Fundamentação Teórica

Se estamos falando de inteligência, então nada mais natural do que nos inspirarmos na forma de funcionamento do principal elemento gerador de inteligência, que é o cérebro de um ser vivo, em especial o cérebro humano.

Este órgão é formado por aproximadamente 10 bilhões de células (chamadas neurônios) que são interligadas, formando uma rede que é capaz de processar milhões de informações através da realização de aproximadamente 60 trilhões de conexões possíveis. O cérebro é um complexo sistema de processamento de informações que tem a capacidade de organizar e reorganizar as ligações entre os neurônios, conforme a necessidade de processamento. É um sistema biológico de processamento de informações altamente complexo, com funcionamento paralelo, isto é, várias informações são processadas ao mesmo tempo (GALVÃO e VALENÇA, 1999, p.19).

Um neurônio biológico é composto por três partes: dendritos, corpo celular (núcleo) e axônios. Os dendritos são os responsáveis pelo recebimento de sinais (impulsos elétricos) que são emitidos por outros neurônios através de processos químicos. O corpo celular recebe esses sinais e realiza seu processamento; finalmente o axônio é o responsável por levar um sinal emitido por este neurônio para outros neurônios (FAUSETT, 1994, p.5).

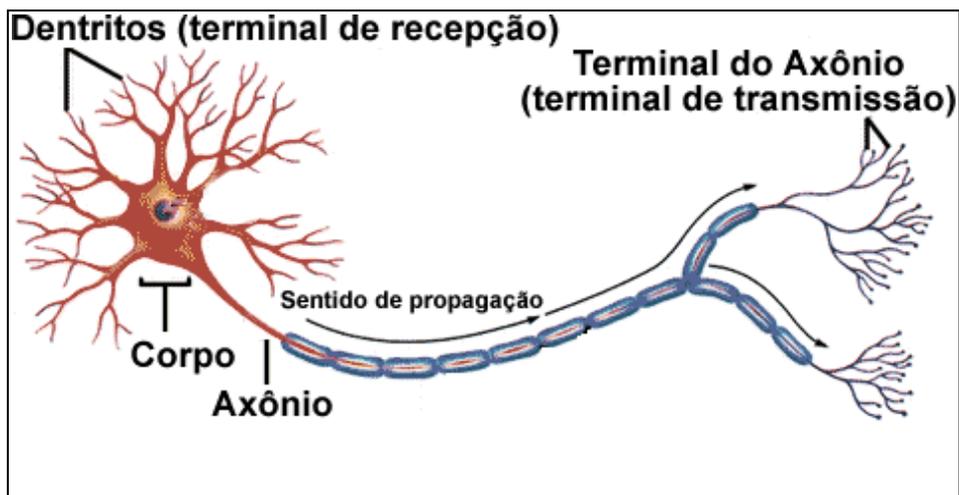


Figura 30: Um neurônio biológico.

Fonte: Adaptado de [www.lncc.br/~labinfo/tutorialRN/imagens/esquemaNeuronio.gif](http://www.lncc.br/~labinfo/tutorialRN/imagens/esquemaNeuronio.gif)

O funcionamento da rede formada pelos neurônios e suas ligações se dá da seguinte forma: ao receber impulsos elétricos através de seus dendritos, o corpo celular de um neurônio realiza o processamento destes impulsos (uma analogia para melhor compreensão: se os impulsos fossem valores numéricos, este processamento seria a soma destes valores); caso o resultado dessa “soma” seja maior que um patamar mínimo definido para cada neurônio particular, o corpo celular retransmite esse impulso resultante através de seu axônio para outros neurônios, reiniciando assim o processo já descrito. Importante citar que esse processo se dá de forma paralela, isto é, todos os neurônios estão realizando esse processo ao mesmo tempo (FREEMAN; SKAPURA, 1991, p.9). Neste contexto, podemos pensar no processo de aprendizagem como sendo o ajuste, ao longo do tempo, deste valor de patamar mínimo, conforme o resultado obtido com a transmissão (ou não) desses impulsos<sup>31</sup>. Também faz parte deste processo a criação de novas conexões entre neurônios (aprendizado de novos conteúdos), ou mesmo a extinção de conexões existentes (esquecimento).



Figura 31: Uma rede de neurônios.

Fonte: <http://www.bitspin.net/images/neuron.jpg>.

Uma rede neural artificial (RNA) é, portanto, um programa de computador que imita este funcionamento para realizar procedimentos de análise de dados. Neste tipo de programa, um neurônio artificial é representado por uma fórmula matemática, que é responsável pelo processamento dos “impulsos” recebidos (dados de entrada). Os vários neurônios artificiais são interligados, isto é, entre eles é definido um meio de transferência de dados. Assim,

<sup>31</sup> Exemplo prático - apesar de extremamente simplificado - deste tipo de aprendizagem: uma criança olha uma tomada elétrica, e esta visão gera sinais em seu cérebro. Como não há experiência anterior, os neurônios retransmitem o sinal para outros neurônios, causando na criança a ação de brincar com a tomada. O recebimento de um choque elétrico configura um resultado indesejável da ação, o que acarreta a mudança dos valores do patamar mínimo dos neurônios, de forma a não mais retransmitir os estímulos que geraram este resultado e tentando evitar sua repetição no futuro.

conforme o estado desse neurônio artificial e também o estado de suas conexões (de e para outros neurônios) ele pode (ou não) retransmitir o resultado da fórmula para os outros neurônios (fórmulas) da rede, repetindo-se assim o processo, até se atingir o objetivo desejado (FAUSETT, 1994, p.6).

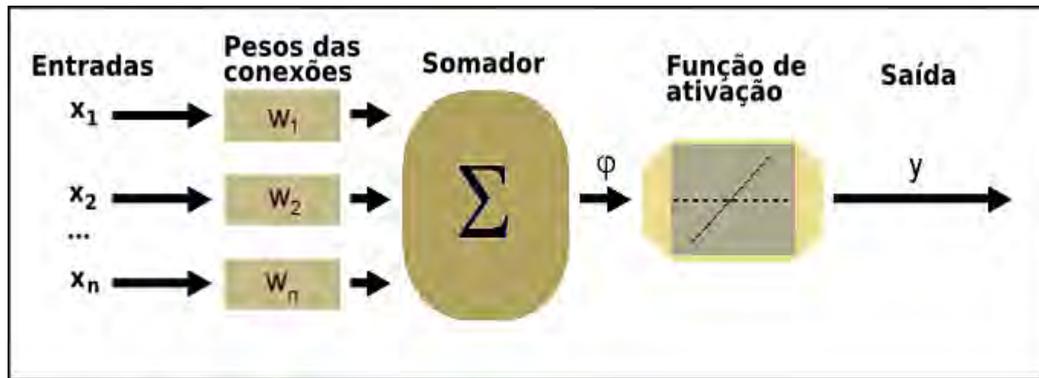


Figura 32: Um neurônio artificial.

Fonte: Adaptado de <http://home.agh.edu.pl/~vlsi/AI/intro/>.

A figura 32 ilustra um neurônio artificial. Este neurônio tem  $m$  entradas (representadas pelos valores  $x_1, x_2, \dots, x_m$ ). As conexões entre as entradas e o neurônio artificial recebem cada uma um valor específico, denominado **peso** da conexão (valores  $w_{k1}, w_{k2}, \dots, w_{km}$ ). O neurônio então realiza uma soma ponderada pelos pesos dessas entradas (“somador”), e conforme a definição de sua função de ativação ele pode transmitir ou não o resultado desta soma para a saída, ou seja, para os outros neurônios aos quais este neurônio estiver conectado.

A quantidade de neurônios e a forma como eles são dispostos e conectados entre si definem a **arquitetura** (ou **topologia**) de uma RNA, que está diretamente relacionada ao tipo de análise de dados que se deseja realizar. De forma geral, os neurônios são dispostos em camadas, onde cada neurônio de uma camada é ligado a todos os neurônios da camada subsequente. A primeira camada é denominada de camada de entrada — é a camada utilizada para se inserir os valores que serão processados pela rede neural —, e a última é denominada camada de saída — utilizada para devolver ao usuário o(s) valor(es) do(s) resultado(s) processado(s) pela rede neural. Todas as outras camadas são denominadas camadas ocultas. Apresentamos na figura 33 uma RNA hipotética com quatro neurônios na camada de entrada, dois neurônios na camada de saída e duas camadas ocultas.

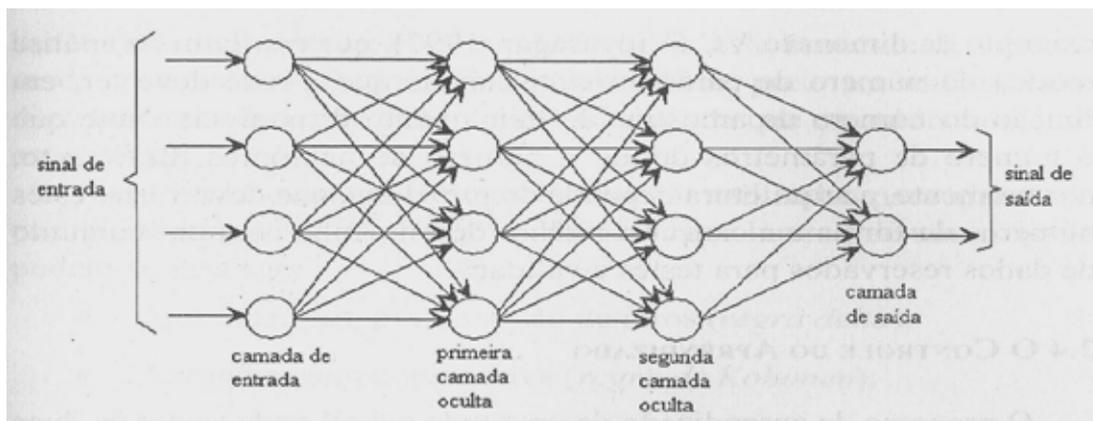


Figura 33: Uma RNA com quatro camadas.  
 Fonte: (LUDWIG Jr.; MONTGOMERY, 2007, p.15)

A característica principal do funcionamento de uma RNA - e que é também a sua grande diferença em relação a outros programas de computador - é a sua capacidade de aprendizagem, que se dá através da modificação dos valores dos **pesos** associados às várias conexões entre os neurônios, de forma a captar e identificar relações existentes porém escondidas nos dados de entrada. Este aprendizado pode se dar de duas formas: supervisionado e não-supervisionado.

No aprendizado supervisionado, a RNA aprende através do uso de um conjunto de dados de entrada para os quais já se conhece a saída resultante correta. Caso o valor de saída calculado pela rede seja diferente do valor de saída correto, o algoritmo de aprendizado realiza alterações nos valores dos pesos das conexões entre os elementos de processamento (neurônios artificiais), repetindo esse procedimento até que o erro gerado nos padrões de saída alcancem um valor mínimo satisfatório (MEDEIROS, 1999, p.73). Este procedimento é detalhado<sup>32</sup> pelos passos abaixo:

- geram-se valores iniciais aleatórios para os pesos de todas as conexões entre cada neurônio artificial da RNA;
- inserem-se os dados de um conjunto de dados de aprendizado (valores das entradas mais o valor da saída correspondente);
- cada neurônio faz seu processamento individual, isto é, realiza a soma ponderada das entradas, e retransmite (ou não) esse resultado para os outros neurônios das camadas posteriores, conforme a definição da função de ativação;
- após o processamento de todos os neurônios da RNA é gerado um (ou vários, dependendo da arquitetura utilizada) valor(es) de saída;

<sup>32</sup> A sequência de passos (algoritmo) é apresentada aqui de forma simplificada e resumida. Para os leitores interessados em implementar uma RNA em um programa de computador sugere-se a consulta a Ludwig Jr e Montgomery (2007), Rogers (1997) e Masters (1993).

- este valor gerado é comparado com o valor previamente conhecido da saída correspondente ao conjunto de dados de entrada utilizado. Caso os valores sejam diferentes, realizam-se alterações nos pesos dos neurônios, objetivando resultar o valor correto;
- repete-se o procedimento a partir do passo 2, para cada conjunto de dados de aprendizado;
- quando todos os conjuntos de dados de treino forem apresentados à RNA, tem-se completada uma **ÉPOCA** de treinamento. Neste momento, pode-se calcular uma medida de erro para se decidir se se continua ou finaliza o treinamento;
- repetem-se as épocas de treinamento (um processamento típico pode chegar até a 1000 ou 2000 épocas de treinamento) até que a condição de parada seja satisfeita. Esta condição de parada pode ser: número determinado de épocas, erro médio menor que um certo valor ou a inexistência de erro em uma época específica.

Apresentamos no anexo 3, a título de ilustração, o processamento completo do aprendizado de uma rede neural simplificada.

Um exemplo de aplicação de uma RNA com aprendizado supervisionado em um estudo geográfico pode ser o processamento do modelo para estudos de fluxo apresentado na introdução deste trabalho (p.16). Para a efetiva utilização do modelo, é preciso estimar o valor do parâmetro  $b$  a partir de valores conhecidos de  $O_i$ ,  $D_j$  e  $T_{ij}$ . Uma alternativa à utilização desse modelo pode ser a utilização de uma RNA. Em primeiro lugar, fornece-se ao programa os dados conhecidos de entrada e os dados (também já conhecidos) da respectiva saída esperada. A RNA utiliza esses dados para “aprender” (ou melhor dizendo, descobrir) as relações implícitas nesses dados. Depois dessa fase de aprendizado, podemos utilizar a RNA treinada como se utilizaria o modelo original: fornecemos as entradas e o programa devolve o valor do fluxo associado, calculado com base no que ela aprendeu com os dados de treino.

Em testes realizados com este exemplo (OPENSHAW; OPENSHAW, 1997, p.174), chegou-se à estimativa do parâmetro  $b$  utilizando 2 métodos convencionais (maximização de entropia, com restrição única e com dupla restrição) e também através de 7 configurações diferentes de RNA (variando o número de neurônios e a quantidade de ligações entre eles). Nos testes realizados, todas as redes neurais geraram resultados melhores que o método matemático de restrição única, e metade delas geraram resultados melhores que o método com dupla restrição).

Já no aprendizado não-supervisionado, não existe um valor de saída correto. O objetivo deste tipo de treinamento não é associar as entradas a uma certa saída específica, mas sim analisar os conjuntos de dados de entrada em busca de regularidades e correlações, objetivando agrupá-los em classes, identificando assim algumas de suas propriedades. As propriedades que a rede vai aprender sobre os dados variam conforme o tipo de arquitetura utilizada (MEDEIROS, 1999, p.74). As RNAs que utilizam este tipo de aprendizado são denominadas de redes neurais auto-organizáveis e atuam agrupando dados de entrada similares sem o uso de dados de treino que especifiquem como um membro típico de cada agrupamento deve ser, ou a que grupo cada conjunto de dados de entrada pertence (FAUSETT, 1994, p.16).

Uma das RNAs auto-organizáveis com aprendizado não-supervisionado é o Mapa<sup>33</sup> Auto-Organizável, desenvolvido por Kohonen (2001, p.106):

The Self-Organizing Map (SOM) is a new, effective software tool for the visualization of high-dimensional data. In its basic form it produces a similarity graph of input data. It converts the nonlinear statistical relationships between high dimensional data into simple geometric relationships of their image points on a low-dimensional display, usually a regular two-dimensional grid of nodes. As the SOM thereby compresses information while preserving the most important topological and/or metric relationships of the primary data elements on the display, it may also be thought to produce some kind of abstractions<sup>34</sup>.

Esta RNA possui apenas duas camadas: a camada de entrada e a camada de saída, esta última especialmente denominada de camada Kohonen (Kohonen layer). Esta camada possui um conjunto de neurônios artificiais, geralmente dispostos em uma grade em duas dimensões. A figura 34 mostra uma RNA do tipo SOM típica.

---

33 O termo “mapa” no nome desta rede neural artificial não tem nenhuma ligação direta com qualquer tipo de representação cartográfica ou geográfica.

34 “O Mapa Auto-Organizável é uma ferramenta de *software* nova e eficaz para a visualização de dados multi-dimensionais. Na sua forma básica, ela produz um gráfico das similaridades dos dados de entrada. Ela converte as relações estatísticas não-lineares entre dados multi-dimensionais em simples relações geométricas entre pontos numa visualização de poucas dimensões, normalmente uma grade regular bi-dimensional de pontos. Além de se poder usar o SOM para comprimir informação enquanto preserva as relações topológicas e/ou métricas mais importantes, podemos também pensar nesta ferramenta como produtora de alguns tipos de abstrações.”

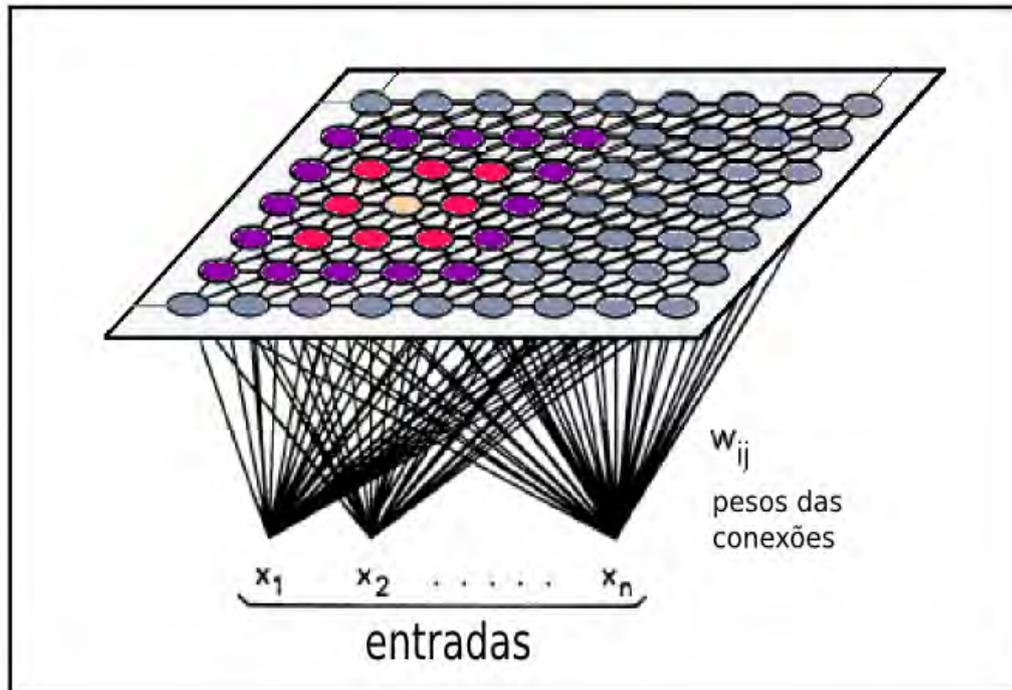


Figura 34: Um mapa auto-organizável de Kohonen.  
 Fonte: Adaptado de [http://www.lohninger.com/helpsuite/kohonen\\_network\\_-\\_background\\_information.htm](http://www.lohninger.com/helpsuite/kohonen_network_-_background_information.htm)

Nesta RNA, cada neurônio da camada de entrada é ligado a todos os neurônios da camada Kohonen, e cada conexão tem seu valor de peso, conforme visto anteriormente. O funcionamento deste tipo de RNA é um pouco diferente do modo descrito no início desta seção. Nesta rede, os neurônios não tem a função de transformar o sinal de entrada, mas sim associar um certo conjunto de dados de entrada a um neurônio específico da camada Kohonen. Desta forma, conjuntos de dados de entrada que forem similares (independente do número de componentes destes conjuntos, por isso se fala em dados multi-dimensionais) ativarão o mesmo neurônio na camada de saída, ou neurônios próximos. Apresentamos a seguir um detalhamento do funcionamento do aprendizado não-supervisionado desta RNA:

- geram-se valores iniciais aleatórios para os pesos de todas as conexões entre os neurônios da camada de entrada e os neurônios da camada Kohonen;
- insere-se na camada de entrada os valores de um conjunto de dados de treinamento da rede;

- comparamos os valores da entrada com os valores dos pesos de todas as conexões; diz-se que o neurônio cujas conexões tiverem seus valores de peso mais similares aos valores dos dados de entrada é o neurônio vencedor<sup>35</sup>. Um exemplo de neurônio vencedor pode ser visto na figura 34, representado com a cor rosa;
- alteram-se os valores dos pesos deste neurônio vencedor, de forma a que se tornem ainda mais similares aos valores dos dados de entrada;
- também alteram-se os valores dos pesos dos neurônios vizinhos ao neurônio vencedor (neurônios vermelhos e roxos na figura 34), de forma a que se tornem mais similares aos valores dos dados de entrada. A intensidade de alteração nos valores dos pesos é diretamente proporcional à proximidade entre o neurônio e o neurônio vencedor;
- repete-se o procedimento a partir do passo 2, para cada conjunto de dados de aprendizado;
- quando todos os conjuntos de dados de treino forem apresentados à RNA, temos completada uma **ÉPOCA** de treinamento;
- repetem-se as épocas de treinamento (um processamento típico pode chegar até a 1000 ou 2000 épocas de treinamento) até que a condição de parada seja satisfeita. Esta condição de parada pode ser: número determinado de épocas, alteração de pesos menor que um certo valor ou a inexistência de alterações de valores de pesos em uma época específica.

Encontramos no procedimento de aprendizado deste tipo de RNA mais uma analogia com o cérebro humano: a ativação de neurônios próximos ao neurônio vencedor, funcionamento que se verifica também no cortex cerebral humano (figura 35):

In comparison with a biological neural network, the Kohonen layer is analogous to the cerebral cortex in the human brain. [...] Although the mechanics and processes of the cerebral cortex are not well understood, anatomical and physiological evidence does suggest that a lateral interaction exists between its neurons. In other words, if one neuron in the cerebral cortex is excited by some stimulus, neurons in the surrounding area are also excited. Furthermore, as the distance between neighboring neurons and the

---

<sup>35</sup> Esta forma de aprendizado também é chamada de aprendizado competitivo: “Na maioria dos outros modelos de redes neurais, todos os neurônios ajustam seus pesos em resposta ao treinamento. No aprendizado competitivo, os neurônios competem pelo privilégio do aprendizado” (MASTERS, 1993, p.328).

stimulated neuron increases, the degree of excitation decreases [...]. The Kohonen layer is a two-dimensional simplification of the cerebral cortex and models the lateral interaction characteristic between its nodes<sup>36</sup> (ROGERS, 1997, p.133).

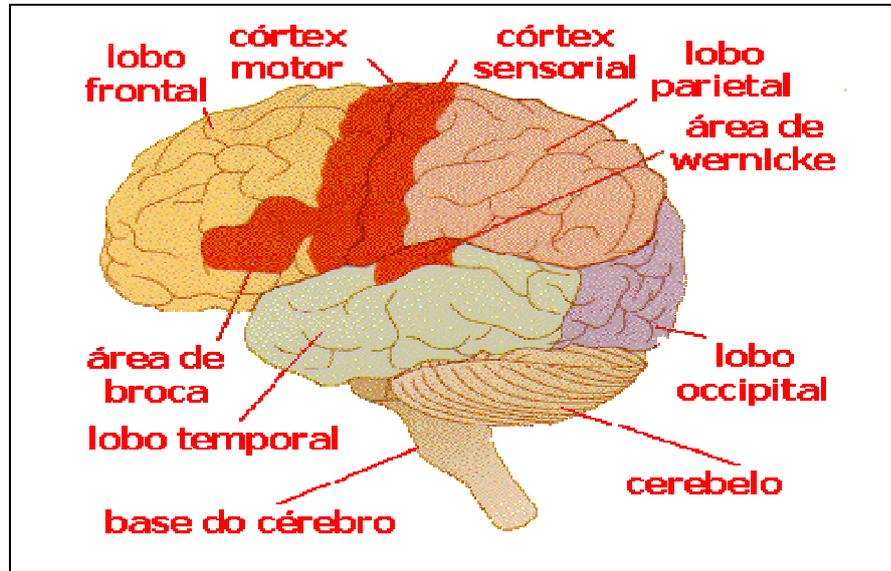


Figura 35: Localização do córtex cerebral.

Fonte: [http://www.encyclopedia.com.pt/readarticle.php?article\\_id=730](http://www.encyclopedia.com.pt/readarticle.php?article_id=730)

Este tipo de RNA pode ser utilizada, após treinada, de duas formas distintas:

- inserem-se novamente os dados de treino, registrando o neurônio da camada Kohonen ativado por cada conjunto de dados de entrada. Os conjuntos similares ativarão os mesmos neurônios, ou neurônios próximos, sendo possível desta forma identificar um agrupamento destes dados;
- inserem-se novos conjuntos de dados (que não estavam presentes nos dados de treino), e registram-se os neurônios ativados por estes novos dados. Desta forma pode-se identificar a qual dos grupos identificados anteriormente os novos dados pertencem.

Apresentamos na figura 36 um exemplo de aplicação de uma RNA do tipo SOM no agrupamento de dados multidimensionais (KASKI; KOHONEN, 1996). O objetivo deste

<sup>36</sup> “Em comparação com uma rede neural biológica, a camada Kohonen é análoga ao cortex cerebral humano. [...] Apesar de não se entender completamente a mecânica e os processos do cortex cerebral, evidências anatômicas e fisiológicas sugerem que existe uma interação lateral entre seus neurônios. Em outras palavras, se um neurônio do cortex cerebral é estimulado, os neurônios vizinhos também são estimulados. Adicionalmente, o grau de estímulo decresce conforme os neurônios vão se afastando do neurônio estimulado [...]. A camada Kohonen é uma simplificação em duas dimensões do cortex cerebral e modela a característica de interação lateral entre seus neurônios artificiais” (tradução do autor).

trabalho foi estudar o nível do padrão de vida em diversos países, a partir de 39 indicadores<sup>37</sup> escolhidos para descrever fatores tais como saúde, educação, consumo e serviços públicos. Segundo um dos autores do trabalho (KASKI, 1997a, p.2), “encontrar estruturas em conjuntos de dados vastos e multi-dimensionais, é uma tarefa difícil e lenta. Relações interessantes e desconhecidas podem estar escondidas nos dados”.

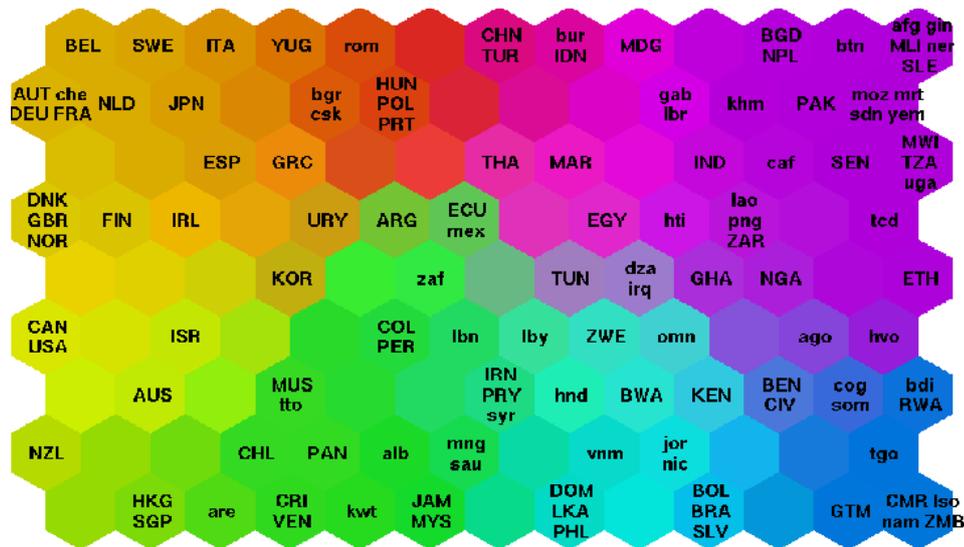


Figura 36: Uma RNA SOM treinada.

Fonte: <http://www.cis.hut.fi/research/som-research/worldmap.html>

A figura 36 apresenta o resultado final da camada Kohonen da RNA do tipo SOM já treinada com os dados descritos acima. Foi exibida a sigla do país junto com o respectivo neurônio ativado pelos seus dados. As cores foram utilizadas para ilustrar as similaridades encontradas pela RNA. Por exemplo, podemos notar no canto superior esquerdo da figura (representado por tons amarelos) a proximidade entre a Bélgica (BEL), Suécia (SWE), Áustria (AUT), Alemanha (DEU), França (FRA), entre outros países. Esta proximidade no resultado final da RNA significa que os valores dos 39 indicadores sócio-econômicos relativos à estes países são similares, formando assim um agrupamento. Ressaltamos que o que deve ser interpretado na figura é a proximidade entre países, e não sua posição absoluta, isto é, o fato da Bélgica (BEL) estar posicionada exatamente no canto superior esquerdo não significa que seus valores são melhores ou piores que os dos outros países do agrupamento. Também o posicionamento deste agrupamento no canto superior esquerdo não significa que este grupo é melhor ou pior que outros grupos. É necessária a análise complementar do pesquisador para identificar as características dos grupos encontrados pela RNA.

37 WORLD BANK. World Development Report 1992. New York: Oxford University Press, 1992.

Kaski (1997a, p.22) apresenta algumas características vantajosas do funcionamento das RNAs do tipo SOM:

- visualização ordenada: Os itens são mapeados para os neurônios cujos pesos são os mais parecidos com os dados, desta forma, neurônios próximos terão dados similares mapeados para eles. Este tipo de visualização ordenada dos dados facilita o entendimento das suas estruturas internas;
- visualização de agrupamentos: a mesma visualização ordenada pode ser usada para se ilustrar a densidade dos agrupamentos, em diferentes regiões de neurônios da camada Kohonen. A densidade dos pesos dos neurônios vai refletir a densidade dos dados de entrada. Em áreas que representam agrupamentos os pesos dos neurônios serão muito parecidos entre si, enquanto que em áreas vazias entre os agrupamentos suas diferenças serão maiores. Desta forma, a estrutura de agrupamentos existentes nos dados poderá ser visualizada através das distâncias (diferenças) entre os pesos de neurônios vizinhos. A figura 37 mostra uma forma diferente de representar a camada Kohonen apresentada na figura 36. Áreas claras representam neurônios cujos valores de pesos são bem próximos, enquanto que as áreas escuras representam maiores diferenças nos valores dos pesos, marcando assim a separação entre os grupos encontrados. Por exemplo, a área escura entre o grupo identificado como “1” (canto superior esquerdo) e o grupo “3” (região central-inferior) indica que os valores dos neurônios do primeiro grupo são bem diferentes dos valores encontrados nos neurônios do segundo grupo. Novamente, o fato de um grupo estar “acima” e outro “abaixo” não significa uma relação hierárquica entre os grupos; é preciso o trabalho do pesquisador analisando os dados dos grupos encontrados pela RNA para se identificar corretamente qual é a configuração desses grupos (se tem valores altos, ou baixo, ou altos/baixos para grupos específicos de indicadores);

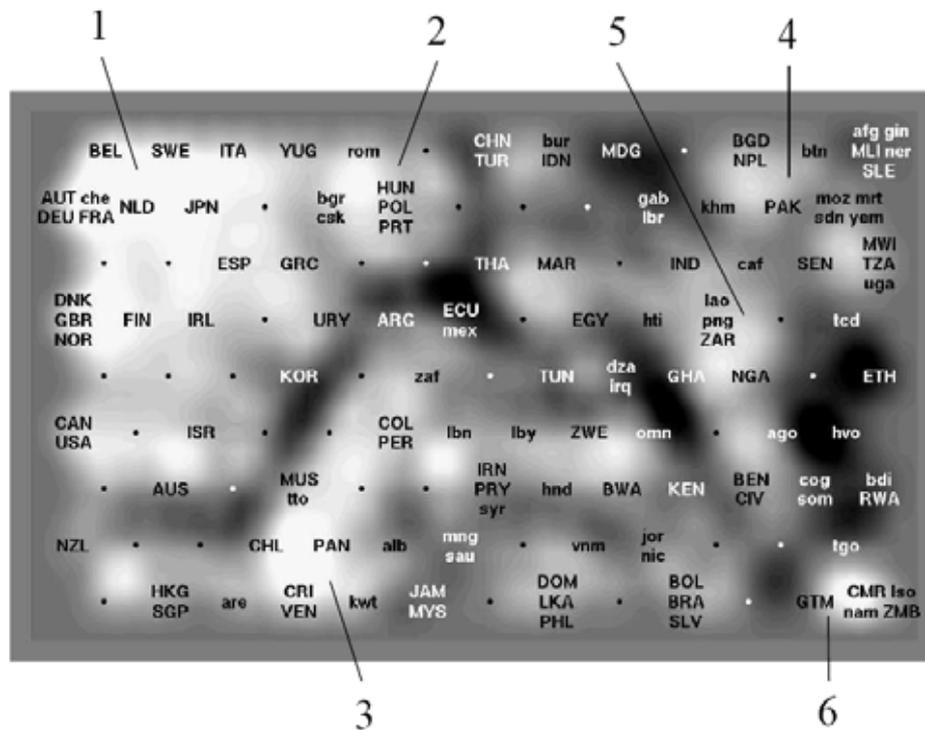


Figura 37: Visualização das distâncias (diferenças) entre os pesos dos neurônios de uma RNA SOM já treinada.

Fonte: (KASKI; KOHONEN, 1996)

- sem suposições a priori: o diagrama de agrupamentos resultante é genérico no sentido de que nada precisa ser tomado como requisito acerca do formato dos agrupamentos (circulares, retangulares, lineares, etc.). A grande maioria dos outros métodos para agrupamento assumem um certo formato para os *clusters* resultantes, isto é, antes de usar o método o pesquisador precisa ter uma idéia de como são esses agrupamentos;
- melhor tratamento de *outliers*: os *outliers* são dados que tem comportamento muito diferente dos demais<sup>38</sup>. No mapa gerado pela RNA SOM, cada outlier ativa apenas um único neurônio e sua vizinhança. Desta forma, o resto dos neurônios pode ainda ser utilizado para análise do comportamento do restante dos dados em análise.

<sup>38</sup> Um exemplo claro para se entender o significado de *outlier* pode ser visto analisando os dados da população residente dos municípios do estado do Rio de Janeiro (Censo Demográfico 2000, [ftp://ftp.ibge.gov.br/Censos/Censo\\_Demografico\\_2000/Dados\\_do\\_Universo/Municipios/PopMun\\_33\\_31.zip](ftp://ftp.ibge.gov.br/Censos/Censo_Demografico_2000/Dados_do_Universo/Municipios/PopMun_33_31.zip)). A população do município do Rio de Janeiro (5.857.904 pessoas) é um *outlier* neste conjunto de dados, pois é um valor muito diferente do apresentado por todos os outros municípios (mínimo 4.886 pessoas, máximo 920.599 pessoas, média 94.815 pessoas). Uma explicação mais técnica pode ser encontrada em <http://mathworld.wolfram.com/Outlier.html>.

Segundo Silva (2004, p.7), “os mapas auto-organizáveis têm sido aplicados, com sucesso, em variados problemas de análise exploratória de dados multivariados, todavia, poucos são os trabalhos voltados para a análise de dados coletados para unidades espaciais [...]”. Contribuir para a disseminação desta ferramenta no uso em procedimentos de produção e análise da informação geográfica é, portanto, o objetivo da aplicação apresentada na próxima seção.

### 3.3.2. Aplicação

Dando continuidade à implementação de funcionalidades de análise de informações geográficas por meio de técnicas de computação inteligente no GAIA, foi desenvolvido um módulo para a identificação de agrupamentos de dados (clusters) utilizando uma rede neural artificial de aprendizado não-supervisionado, mais especificamente um mapa auto-organizável tal como proposto por Kohonen (2001) e descrito na seção anterior.

Esta funcionalidade foi testada e validada repetindo-se uma parte do estudo realizado por este autor em sua dissertação de mestrado (PEREIRA, 2003). Naquele trabalho, buscou-se estudar a relação de influência que o grau de urbanização das cidades e regiões exerce sobre o perfil de capital cultural dos candidatos a diversos cursos da UNESP, instituição de ensino superior que possui cursos em diversos campi espalhados pelo interior do Estado de São Paulo.

O conceito de capital cultural foi cunhado pelo sociólogo francês Pierre Bourdieu (1998 e 1998a), e denota um conjunto de capacidades intelectuais e conhecimentos mas, mais do que isso, um conjunto de potencialidades que formam a constituição intelectual de uma pessoa, obtidas a partir de diversas fontes, materiais ou não. Tal como aponta Whitaker (1981, p.60),

É possível, portanto, pensar em capital cultural como um conjunto lógico e funcional de conhecimentos ligados à literatura, teatro ou música — artes de modo geral — além da compreensão dos acontecimentos políticos (nacionais e internacionais), o que alarga extraordinariamente as possibilidades de se aprender História e Geografia, por exemplo. Integrada a esse conjunto de conhecimentos, transmitidos informalmente pelos adultos, a existência de livros, jornais e revistas ganha funcionalidade, na medida em que aquilo que o estudante lê tem muito a ver com aquilo sobre o que se conversa, o que

leva à ampliação do vocabulário e à assimilação de uma sintaxe que ajuda a criar as estruturas mentais adequadas aos conteúdos da escola, principalmente aqueles que são transmitidos em linguagem científica específica, em nível universitário.

Optou-se, no âmbito daquele trabalho, pela utilização do IDH-M (Índice Municipal de Desenvolvimento Humano) como indicador do grau de urbanização das cidades e regiões. O IDH-M é construído pelo IPEA (Instituto de Pesquisa Econômica Aplicada) e pela Fundação João Pinheiro a partir do IDH (Índice de Desenvolvimento Humano) desenvolvido para o PNUD (Programa das Nações Unidas para o Desenvolvimento) em 1990, com o objetivo de medir a qualidade de vida e o progresso humano em âmbito mundial. A criação do IDH original teve como motivação a preocupação de se usar um único tipo de dado como representação de características mais complexas. Há muito tempo estabeleceu-se a prática de avaliar o bem estar de uma população, e conseqüentemente de classificar os países ou regiões, pelo tamanho de seu PIB per capita. Entretanto, o progresso humano e a evolução das condições de vida das pessoas não podem ser medidos apenas por sua dimensão econômica. Desta forma buscou-se, com a criação do IDH no início da década de 90, uma medida sócio-econômica mais abrangente, que incluísse também outras dimensões fundamentais da vida e da condição humana.

A parte daquele estudo que estamos retomando neste trabalho é a identificação, através de ferramentas de geoprocessamento e de técnicas de análise exploratória espacial, da configuração espacial do IDH-M dos municípios do Estado de São Paulo, isto é, evidenciar a existência de grupos bem definidos de municípios onde este indicador tem valores “altos” (entendidos como valores acima da média geral do indicador para todo o estado de São Paulo) ou valores “baixos” (valores abaixo da média geral). Naquele trabalho, foi utilizada apenas uma única variável, que foi o valor do IDH-M para cada município paulista. O IDH-M é um valor único, calculado a partir de outras três variáveis: IDHM-renda, IDHM-longevidade e IDHM-educação. A aplicação aqui apresentada utiliza essas três variáveis, ou seja, busca identificar grupos de municípios onde essas três variáveis, **ao mesmo tempo**, tenham valores similares, e em especial, acima ou abaixo da média geral. O objetivo com esta repetição do estudo é, não apenas ter uma base de comparação para poder aferir a qualidade dos resultados obtidos com a aplicação desta nova ferramenta, mas também verificar se ela consegue produzir informação adicional, que traga uma qualidade maior para o estudo em questão.

Naquele trabalho identificou-se a existência de dois grupos de municípios (figura 38): um grupo cujos valores de IDH-M estavam, **em conjunto**<sup>39</sup>, acima da média geral do estado (representado pela cor azul-escuro), e um segundo grupo, localizado no sul do Estado, com valores abaixo da média geral do Estado (representado pela cor vermelha). Na legenda da figura 38, a primeira palavra (“alto” ou “baixo”) de cada classe indica se o município representado com aquela cor tem seu valor de IDH-M acima ou abaixo da média geral do Estado. A segunda palavra (também “alto” ou “baixo”) indica se os valores do IDH-M dos vizinhos do município em questão estão (em média) acima ou abaixo da média geral do Estado. Por exemplo, a legenda “alto-alto” (cor azul-escuro) indica que os municípios representados por esta cor têm seu valor de IDH-M acima da média do Estado, e seus vizinhos também têm seus valores de IDH-M (em média) acima da média do Estado.

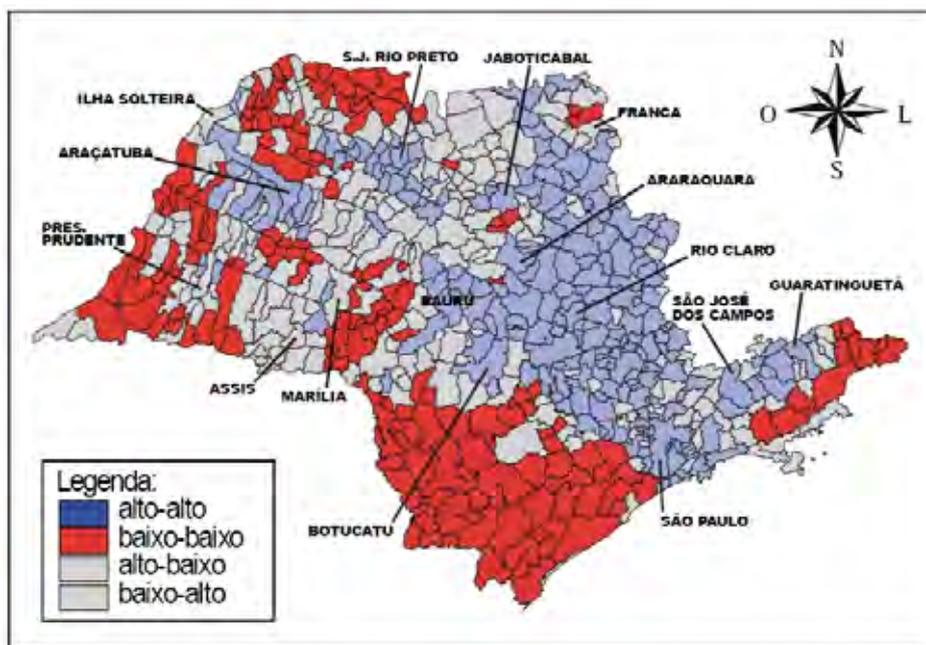


Figura 38: Configuração espacial do IDH-M no Estado de São Paulo  
Fonte: (PEREIRA, 2003, p.68)

<sup>39</sup> As ferramentas utilizadas (mapeamento do gráfico de espalhamento de Moran e mapa de Moran, entre outras) levam em consideração o valor do IDH-M para um município e a média dos valores deste indicador nos municípios vizinhos. Estas ferramentas buscam evidenciar, especificamente, a existência de dois grupos: um composto por objetos cujos valores do atributo sendo estudado estejam acima da média geral, e outro com valores abaixo da média geral. Importante ressaltar que estas ferramentas não buscam identificar municípios específicos que tenham valores acima ou abaixo da média, mas sim **conjuntos** de municípios que tenham este comportamento **em grupo**. Para maiores detalhes sobre o funcionamento das ferramentas utilizadas, consultar a seção “2.3.2. Técnicas de análise exploratória espacial” em (PEREIRA, 2003), disponível em <http://starfightercarloa.blogspot.com/2008/06/dissertao-de-mestrado.html>.

Complementando a análise realizada, apresentou-se um segundo mapa (figura 39), gerado através do cálculo do índice local de associação espacial<sup>40</sup>. Este novo mapa repete a informação apresentada no mapa anterior, porém representando apenas municípios para os quais o cálculo do índice apresentou significância estatística, ou seja, cuja probabilidade do resultado ter sido fruto de mero acaso é de 5% ou menor. Note que o mapa apresentado na figura 39, além de confirmar a existência dos dois grupos de municípios descritos pelo mapa anterior, faz uma definição mais precisa dos municípios constantes desses grupos.

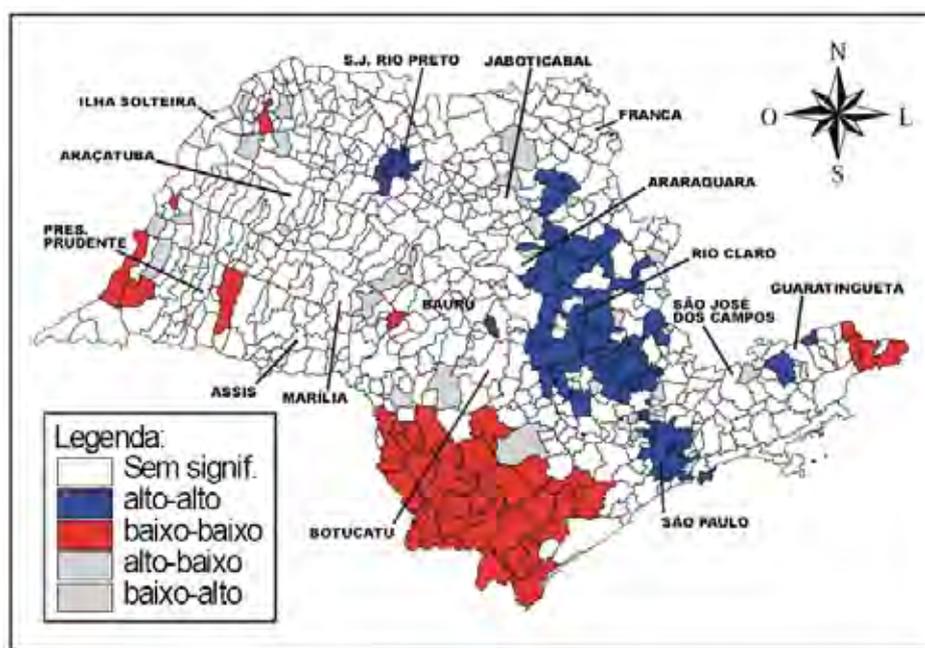


Figura 39: Configuração espacial do IDH-M, com significância estatística.  
Fonte: (PEREIRA, 2003, p.70)

Retomamos este tema neste trabalho, refazendo esta análise de agrupamentos do IDH-M em São Paulo utilizando uma RNA do tipo mapa auto-organizável, para não só repetir (e desta forma validar) os resultados obtidos, mas principalmente para se avaliar possíveis vantagens da utilização desta técnica sobre as técnicas descritas em Pereira (2003).

Iniciou-se a execução da análise pela montagem, no TerraView, de um banco de dados com os municípios do estado de São Paulo, a partir da malha municipal brasileira disponibilizada pelo IBGE na internet.

<sup>40</sup> (PEREIRA, 2003, p.68).

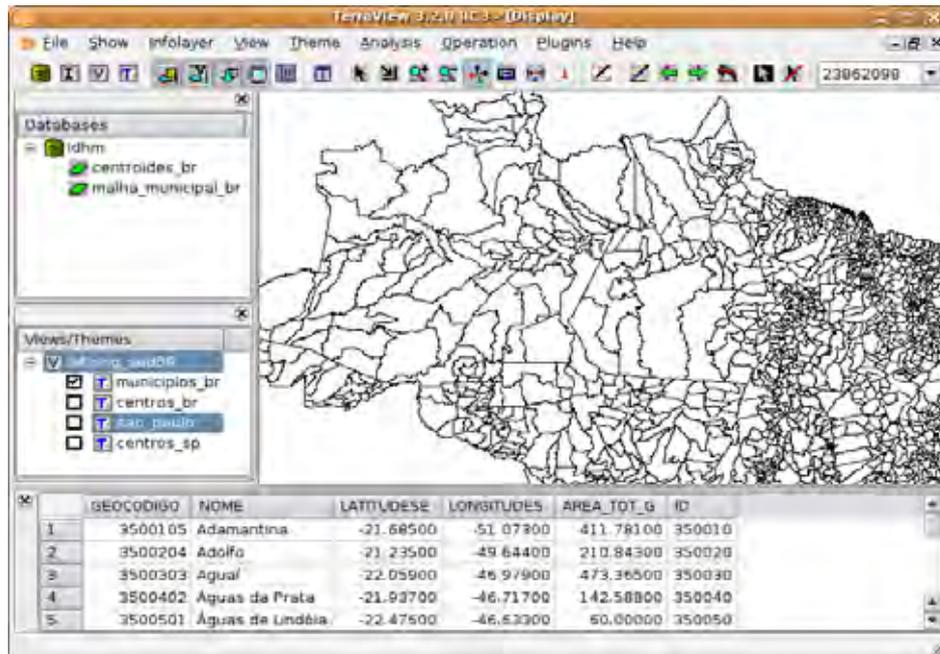


Figura 40: Malha municipal brasileira, inserida no TerraView.  
Elaboração: Carlos José de Almeida Pereira.

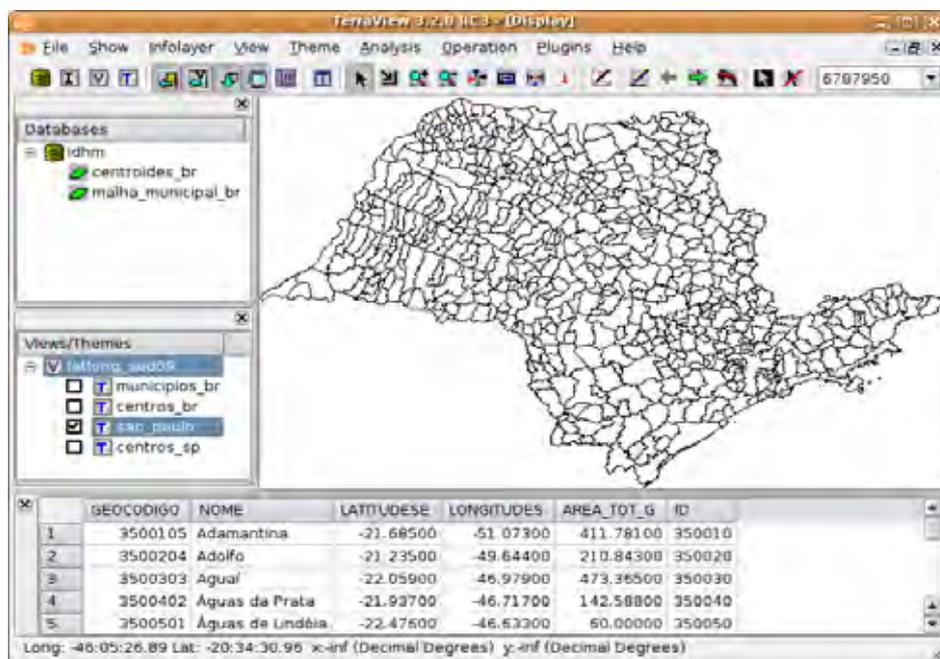


Figura 41: Malha municipal do Estado de São Paulo.  
Elaboração: Carlos José de Almeida Pereira.

O passo seguinte foi a inserção dos valores componentes do IDH-M (renda, longevidade e educação) no banco de dados dos municípios de São Paulo. A planilha completa de valores, para todos os municípios brasileiros, encontra-se disponível no site do PNUD<sup>41</sup>. A ligação entre os dados desta planilha e os objetos gráficos (limites dos municípios) provenientes da malha municipal fornecida pelo IBGE é possibilitada pela existência de um código único que identifica cada município, presente tanto na planilha do PNUD (coluna “CÓDIGO”) como na malha municipal do IBGE (campo “ID”), e denominado geocódigo. O procedimento de inserção desses dados é básico em qualquer Sistema de Informação Geográfica, não sendo o TerraView uma exceção. O resultado deste procedimento encontra-se representado pela figura 42.

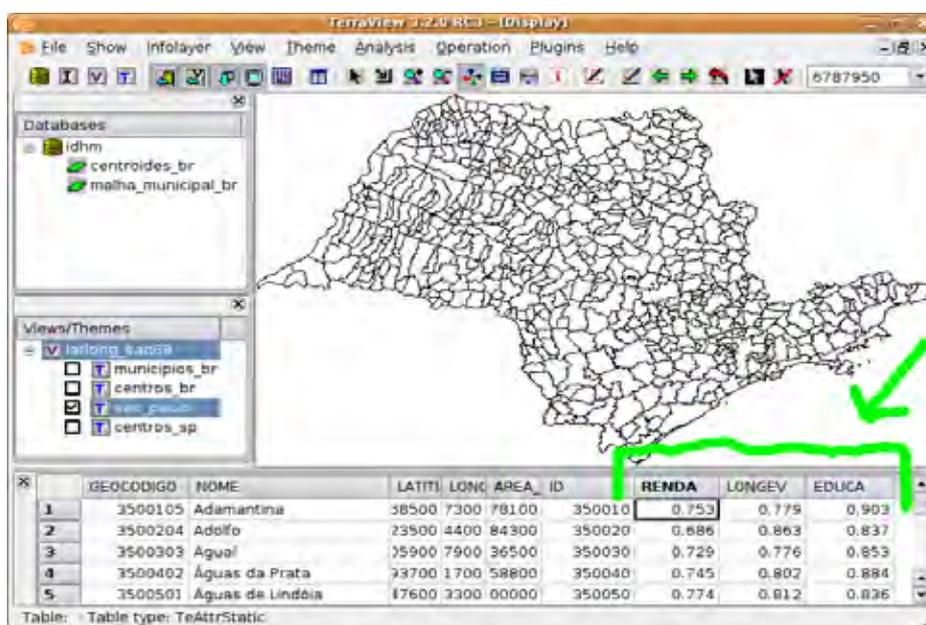


Figura 42: Malha municipal do Estado de São Paulo, já com os valores componentes do IDH-M inseridos.  
Elaboração: Carlos José de Almeida Pereira.

Partiu-se então em seguida para o teste do módulo do GAIA que realiza agrupamento de dados através de uma rede neural. Em sua forma padrão, o módulo irá criar uma rede de 100 neurônios (uma matriz de 10 por 10). Ao final do aprendizado, os neurônios da rede treinada serão submetidos a um procedimento padrão de agrupamento (WARD, 1963; DUTRA et al, 2004; SALVADOR et al, 2004) para uma definição precisa dos grupos encontrados nos dados.

Como já apresentado anteriormente neste trabalho, o GAIA trabalha diretamente com o banco de dados utilizado pelo TerraView, tanto para acesso aos dados que serão utilizados

41 <http://www.pnud.org.br/atlas/tabelas/index.php>.

no processamento, como também para visualização dos resultados diretamente neste SIG, através de mapas temáticos. Na figura 43 é apresentada a tela de configuração da rede neural auto-organizável do GAIA. Nesta tela pode-se escolher o tema do TerraView onde estão os dados a serem analisados, as variáveis que serão tratadas pelo módulo (cujos nomes foram retirados diretamente do banco de dados), e também definir alguns parâmetros de configuração da rede neural. O programa já apresenta valores que possibilitarão uma execução do processo e geração de resultados preliminares, para permitir uma análise exploratória inicial dos dados (valores *default*). Todas as análises realizadas neste trabalho serão efetuadas utilizando-se esses parâmetros *default*. Pretende-se com isso demonstrar que qualquer pesquisador, mesmo sem conhecimento mais profundo sobre redes neurais, poderá utilizar esta ferramenta e conseguir resultados preliminares válidos.

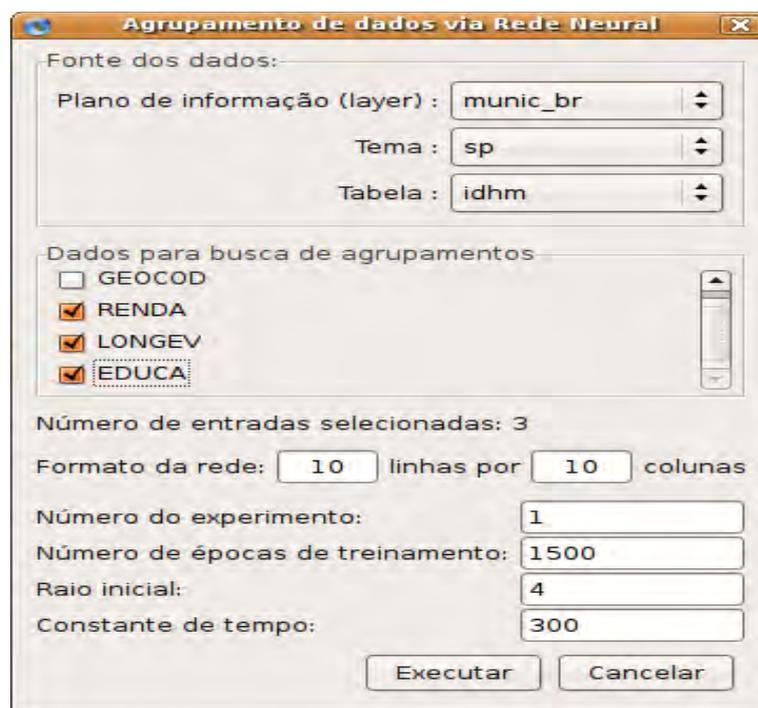


Figura 43: Tela de configuração do módulo RNA do GAIA.  
Elaboração: Carlos José de Almeida Pereira.

Segue uma descrição dos parâmetros relativos ao funcionamento deste tipo de rede neural artificial:

- linhas e colunas: define a arquitetura da camada Kohonen, ou seja, quantos neurônios teremos nesta camada, dispostos em duas dimensões (linhas e colunas). Não há uma definição ou regra precisa sobre a quantidade ideal de neurônios a estabelecer. Uma estratégia para esta escolha seria a de fixar tantos neurônios quantos grupos se espera encontrar nos dados: “[...] projetar a camada

Kohonen de forma a que o número de neurônios nesta camada esteja de acordo com o número de agrupamentos desejado. Por exemplo, uma rede 2x2 tem quatro neurônios, logo tem a capacidade de formar quatro agrupamentos” (KIANG, 2001, p.2). Outra estratégia, e mais citada na literatura, é a de executar vários testes utilizando várias arquiteturas diferentes<sup>42</sup> para a camada Kohonen: “[...] toda a parametrização do SOM dependerá do tipo de aplicação. [...] cada tarefa exige que uma análise posterior seja conduzida até que se chegue à configuração ideal de RNA” (SILVA, 2004, p.42).

- épocas de treinamento: número de vezes que os dados de entrada serão apresentados para treinamento da rede.
- raio inicial: como descrito na seção anterior, a analogia biológica deste tipo de RNA é que a ativação de um neurônio causa a ativação dos neurônios vizinhos, e consequentemente a alteração dos pesos destes neurônios durante o processo de aprendizado. Este parâmetro indica o raio inicial da circunferência que delimitará os neurônios que terão seus pesos alterados. Este valor vai diminuindo ao longo do treinamento de forma que, nas épocas finais do treinamento, apenas os pesos do neurônio ativado serão alterados (a analogia aqui é dar mais importância ao aprendizado já consolidado, isto é, a “experiência” obtida com os dados);
- constante de tempo: regula a velocidade com que o raio de influência é diminuído ao longo das épocas de treinamento. Se definido como 20% do número de épocas, faz com que o raio de influência vá diminuindo numa velocidade que o tornará igual a 0 (isto é, não influenciará nenhum vizinho, só causará a mudança de pesos do próprio neurônio que foi ativado) apenas no final das épocas de treinamento. Se o valor for definido como sendo menor que 20% do número de épocas, aumentará a velocidade com que o raio se tornará 0 (desta forma diminuindo o efeito da influência nos neurônios vizinhos) e vice-versa, caso o valor seja maior que 20%.

A possibilidade de alteração dos parâmetros de configuração da RNA criada pelo módulo permite que o pesquisador realize uma série de testes com os dados, alterando os parâmetros na busca de melhores resultados. Adicionalmente, pesquisadores mais curiosos que se aventurarem a estudar com mais profundidade a teoria por trás das redes neurais

---

<sup>42</sup> Ressalta-se aqui a importância de um programa como o GAIA, que facilita a execução de diversos experimentos com os dados.

artificiais têm a possibilidade de realizar um ajuste mais preciso dos parâmetros com base nos dados que se tem disponível para trabalhar. De qualquer modo, os valores padrão para os parâmetros permitirão que qualquer pesquisador realize uma análise exploratória preliminar dos dados e visualize os resultados.

Em linhas gerais, o módulo realiza as seguintes etapas de processamento:

- montagem, na memória do computador, da rede neural artificial especificada (número de linhas e número de colunas);
- acesso ao banco de dados do TerraView para coleta dos dados que serão utilizados como entrada da rede neural;
- processamento do aprendizado não-supervisionado dos dados, pelo número de épocas definido pelo usuário;
- identificação, nos valores dos pesos dos neurônios calculados pelo aprendizado, de grupos de dados similares;
- devolução, para o TerraView, dos dados dos grupos encontrados, ligados aos objetos gráficos originais (por exemplo, municípios), para mapeamento temático e visualização gráfica (cartografica) desses grupos.

Ao final do processamento, são geradas no TerraView duas novas colunas de dados, “neurônioXX”<sup>43</sup> e “grupoXX”, sendo o “XX” substituído por um número sequencial que identifica uma execução feita pelo módulo (por exemplo, neurônio01, grupo01, neurônio02, grupo02, etc). Assim, um pesquisador pode experimentar com várias configurações de redes neurais e os resultados vão sendo armazenados no banco de dados do TerraView para mapeamento e comparação posterior. De interesse para nós neste momento é a coluna “grupo”, que armazena um número sequencial representativo do grupo identificado pela rede neural. É este número que possibilitará a visualização deste agrupamento no mapa. As colunas geradas pelo módulo podem ser visualizadas na figura 44:

---

43 A coluna “neurônioXX” representa o número de identificação do neurônio que foi ativado, ao final do aprendizado, pelos dados daquele objeto em particular (um município, por exemplo). Este valor não será utilizado neste trabalho, mas já é fornecido visando futuras expansões das aplicações do módulo.

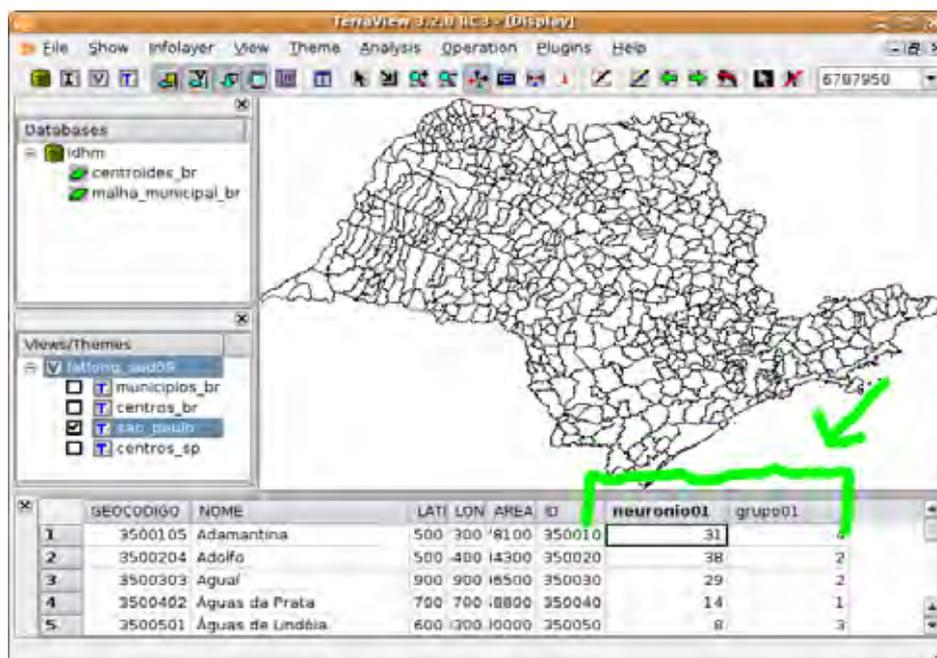


Figura 44: Colunas geradas pelo módulo RNA do GAIA.  
Elaboração: Carlos José de Almeida Pereira.

O passo seguinte é o mapeamento temático da coluna “grupo”, de forma a visualizar os municípios que fazem parte dos grupos identificados pela RNA. Seria possível implementar no GAIA um procedimento para realizar o mapeamento automático desta variável, porém isto não foi feito porque o resultado não seria satisfatório, por dois motivos: o primeiro, seriam exibidos TODOS os grupos identificados pela RNA, incluindo aqueles que não apresentam nenhuma relevância para os interesses do pesquisador, “poluindo” assim o mapa resultante; e segundo, este mapa gerado de forma automática só poderia ter uma única cor (e suas tonalidades), desta forma não dando o devido destaque aos grupos que realmente interessam ao pesquisador e que estão diretamente ligados aos seus objetivos de pesquisa. A figura 45 mostra como seria o resultado de um mapeamento automático da coluna “grupo01”. Podemos observar que a legenda do mapa retratado nesta figura traz apenas os valores existentes na coluna “grupo01” (valores de 0 a 7), pois não seria possível para o GAIA definir as legendas com textos mais significativos (como por exemplo “valores acima da média do estado”, ou “municípios com valores próximos a média do estado”).

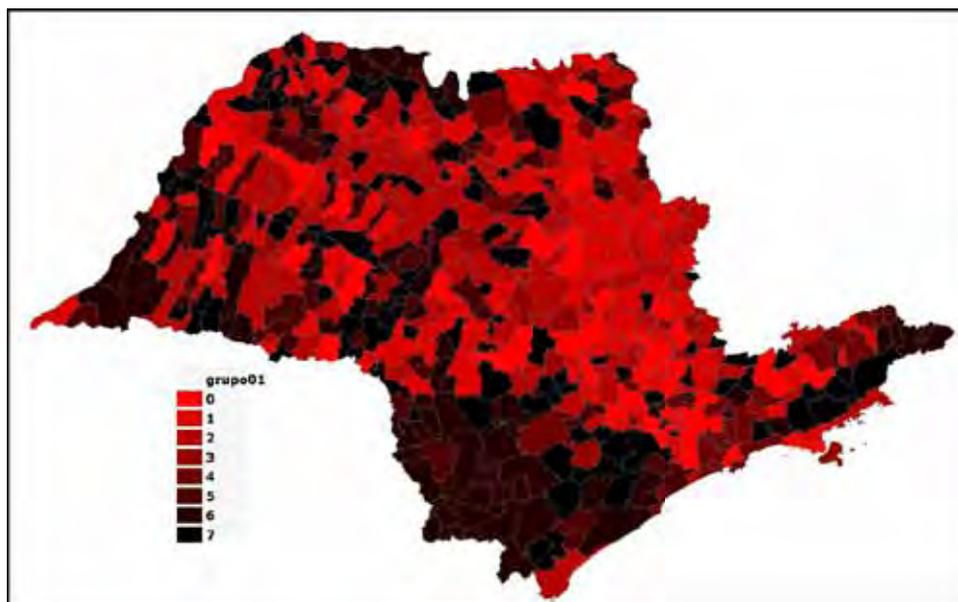


Figura 45: Mapeamento automático da coluna “grupo01”.  
Elaboração: Carlos José de Almeida Pereira.

É preciso, portanto, que o pesquisador realize um mapeamento manual dessa coluna, identificando os grupos relevantes para sua pesquisa, escolhendo as cores com as quais estes grupos serão mapeados e definindo textos significativos para as legendas relativas a estes grupos. Para possibilitar esta tarefa, o GAIA gera um relatório<sup>44</sup> das médias das variáveis utilizadas como entrada, tanto média geral para todo o conjunto de dados, como para cada grupo identificado nos dados. Adicionalmente, o relatório indica em cada grupo a relação entre a média daquela variável no grupo e a média geral da variável. Esta indicação é feita através de um número positivo ou negativo, conforme o valor esteja acima ou abaixo da média, respectivamente. O número em si indica a distância entre a média do grupo e a média geral medida em desvios-padrão.

O GAIA apresenta automaticamente este relatório no final do processamento, e também o salva em um arquivo de nome “resultadogaiaXX.txt” (novamente o “XX” indicando o número sequencial da execução do módulo) para consulta posterior. A figura 46 mostra o relatório gerado para o nosso exemplo com dados do IDH-M:

<sup>44</sup> O leitor mais cuidadoso poderá notar que os valores constantes da tabela, por exemplo, as médias gerais de cada variável, não refletem os valores originais dos dados. Isto acontece porque o módulo RNA realiza um pré-processamento dos dados antes de apresentá-los para processamento pela rede neural, realizando procedimentos de escalonamento (intervalo -1,1) e normalização (MASTERS, 1993, p.330). Isto não afeta os resultados finais, pois as relações entre os dados são preservadas.

	RENDA	LONGEV	EDUCA
Media geral:	-0.332604	0.458419	-0.119845
Desv padrao:	0.442662	0.465352	0.502303
Grupo 0	0.585349 (+2.1)	0.445814 (-0.0)	0.576047 (+1.4)
Grupo 1	0.032545 (+0.8)	0.834273 (+0.8)	0.401182 (+1.0)
Grupo 2	-0.294899 (+0.1)	0.886242 (+0.9)	-0.204899 (-0.2)
Grupo 3	0.193529 (+1.2)	0.657647 (+0.4)	-0.591765 (-0.9)
Grupo 4	0.049062 (+0.9)	0.081875 (-0.8)	0.887812 (+2.0)
Grupo 5	-0.851572 (-1.2)	0.343714 (-0.2)	-0.052714 (+0.1)
Grupo 6	-0.692258 (-0.8)	-0.363978 (-1.8)	-0.503656 (-0.8)
Grupo 7	-0.612290 (-0.6)	0.371603 (-0.2)	-0.637328 (-1.0)

Figura 46: Características dos grupos identificados no processamento.  
Elaboração: Carlos José de Almeida Pereira.

O que este relatório nos diz?

- O grupo 1 possui todas as médias acima das médias gerais;
- O grupo 0 possui, para renda e educação, médias bem acima da média geral. A variável longevidade está abaixo da média geral, mas bem próxima a ela (o valor da diferença, expresso em desvios-padrão, não conseguiu ser diferente de zero);
- Os grupos 6 e 7 tem todas as médias abaixo das médias gerais.

Com base nesta análise, optou-se por criar um mapa temático onde os grupos 0 e 1 sejam representados pela cor azul (grupos de valores acima da média - ou igual a ela, no caso da variável longevidade no grupo 0) e os grupos 6 e 7 representados pela cor vermelha. O resultado deste mapeamento temático encontra-se na figura 47:

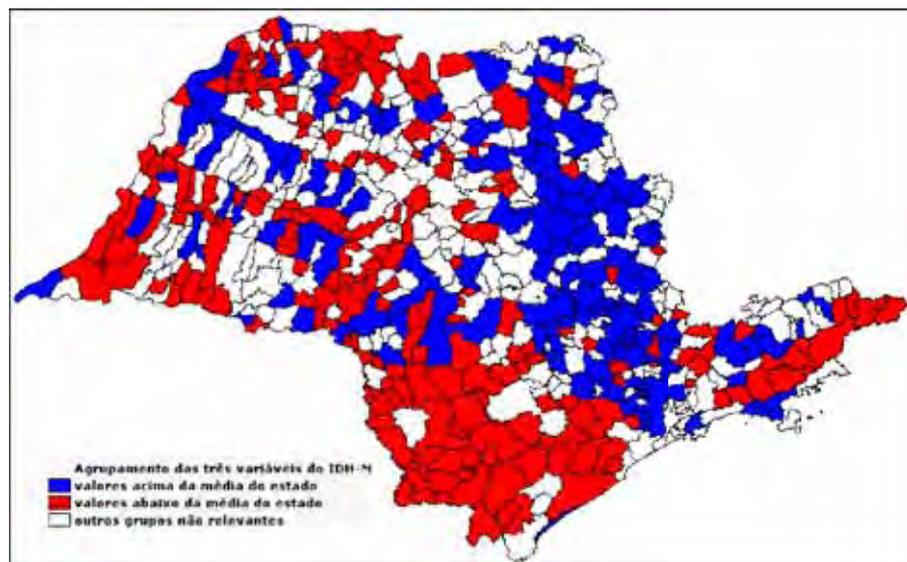


Figura 47: Mapa temático dos grupos de IDH-M.  
Elaboração: Carlos José de Almeida Pereira.

Podemos notar a compatibilidade entre o resultado obtidos no mapa da figura 47 e os mapas das figuras 38 e 39. Estes mapas foram gerados através de um procedimento de várias etapas, que exige um determinado grau de conhecimento por parte do pesquisador, e utilizando apenas uma única variável (o IDH-M consolidado), que já foi produzida com o intuito de resumir e integrar o valor das outras três componentes (renda, longevidade e educação). Mas, e se não tivermos esta variável resumo? E se quisermos testar uma teoria baseada em 10 ou 20 variáveis (disponíveis através de um censo, ou mesmo de uma pesquisa própria)? O procedimento apresentado neste primeiro teste foi capaz de trabalhar com três variáveis, não exigindo nenhum conhecimento prévio do pesquisador acerca dos métodos utilizados (a não ser conhecimentos básicos para operação de um Sistema de Informações Geográficas).

O teste realizado levou em consideração apenas as variáveis de entrada, isto é, a rede neural construiu grupos tomando por base apenas os valores dessas variáveis e a subsequente representação gráfica destes agrupamentos nos mostrou que eles realmente formam “regiões”, isto é, grupos de municípios contíguos.

O próximo teste irá embutir nos dados uma forma da rede neural trabalhar também com a noção espacial, ou seja, agrupar os dados (como fez no exemplo anterior), mas levando em consideração também o fator proximidade entre municípios na formação destes grupos. Para atingir este objetivo, basta inserirmos como variáveis de entrada as coordenadas geográficas dos objetos. Como neste caso os objetos são polígonos (áreas), as coordenadas utilizadas serão as dos centróides (ponto central) destes polígonos. Identificar valores

similares, portanto, no que tange as coordenadas geográficas, significará identificar os municípios que são próximos.

O TerraView não possui a funcionalidade de geração de centróides, portanto resolvemos dotar o GAIA desta funcionalidade. Será preciso também transportar os dados das coordenadas dos centróides para junto dos outros dados que serão analisados. A figura 48 apresenta o resultado desta geração de centróides:

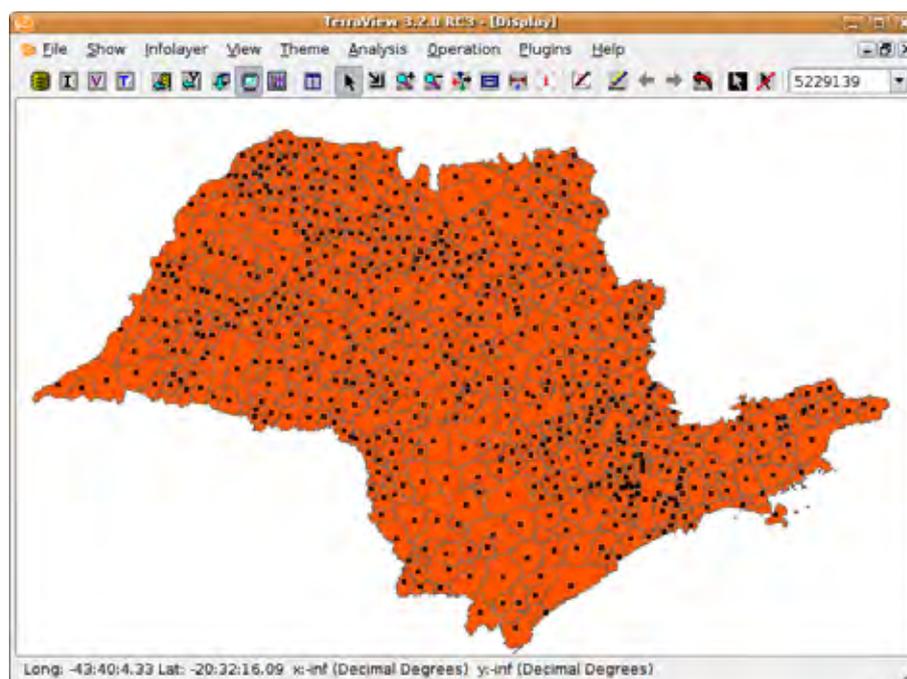


Figura 48: Mapa de centróides gerados pelo GAIA.  
Elaboração: Carlos José de Almeida Pereira.

Uma nova execução do módulo RNA do GAIA, desta vez utilizando as coordenadas dos centróides como dados de entrada, juntamente com as componentes do IDH-M (perfazendo um total de 5 variáveis de entrada), levou à identificação de 9 agrupamentos cujas características são apresentadas na figura 49:

	RENDA	LONGEV	EDUCA	LLONG	LLAT
<b>Media geral:</b>	-0.208450	0.317333	-0.090837	0.004946	0.134636
<b>Desv padrao:</b>	0.303746	0.340923	0.337459	0.485449	0.521039
<b>Grupo 0</b>	0.245584 (+1.5)	0.532468 (+0.6)	0.333636 (+1.3)	0.323117 (+0.7)	-0.293766 (-0.8)
<b>Grupo 1</b>	-0.448058 (-0.8)	0.249320 (-0.2)	-0.309903 (-0.6)	-0.598835 (-1.2)	0.108932 (-0.0)
<b>Grupo 2</b>	-0.478060 (-0.9)	-0.083433 (-1.2)	-0.413134 (-1.0)	0.055075 (+0.1)	-0.574925 (-1.4)
<b>Grupo 3</b>	-0.085833 (+0.4)	0.589762 (+0.8)	-0.025119 (+0.2)	-0.336786 (-0.7)	0.570595 (+0.8)
<b>Grupo 4</b>	-0.343188 (-0.4)	0.159275 (-0.5)	-0.219275 (-0.4)	-0.466522 (-1.0)	0.698841 (+1.1)
<b>Grupo 5</b>	-0.136842 (+0.2)	0.652895 (+1.0)	-0.308421 (-0.6)	0.461579 (+0.9)	0.020000 (-0.2)
<b>Grupo 6</b>	-0.207978 (+0.0)	0.142247 (-0.5)	0.066742 (+0.5)	0.657303 (+1.3)	-0.430225 (-1.1)
<b>Grupo 7</b>	-0.317813 (-0.4)	0.192031 (-0.4)	-0.206719 (-0.3)	0.064062 (+0.1)	0.792344 (+1.3)
<b>Grupo 8</b>	-0.004444 (+0.7)	0.616666 (+0.9)	0.214259 (+0.9)	0.308148 (+0.6)	0.507963 (+0.7)

Figura 49: Características dos grupos identificados no processamento realizado usando as coordenadas dos centróides como dados de entrada.  
Elaboração: Carlos José de Almeida Pereira.

Novamente precisamos analisar esta tabela, para identificar os grupos que deverão ser mapeados. Podemos restringir nossa análise às três variáveis principais (renda, longevidade e educação), pois não faria sentido analisar e comparar as médias das coordenadas geográficas (estas foram inseridas no processamento apenas para que os grupos identificados tivessem também uma proximidade espacial). Desta forma, temos:

- Os grupos 0, 3 e 8 possuem todas as médias acima das médias gerais;
- Em duas das três variáveis, o grupo 0 apresenta as maiores diferenças: +1.5 contra +0.7 (grupo 8) e +0.4 (grupo 3) na variável renda, e +1.3 contra +0.9 (grupo 8) e +0.2 (grupo 3). Estes fatos podem ser usados para representar uma certa “hierarquia” entre os grupos 0, 8 (valores **muito** acima da média) e 3 (valores acima da média);
- Os grupos 1, 2, 4 e 7 possuem todas as médias abaixo das médias gerais;
- O grupo 2 é o que apresenta as maiores diferenças (negativas);
- Os grupos 4 e 7 são bem parecidos no que se refere as diferenças com relação as médias gerais;
- Hierarquia entre os grupos abaixo da média: 2 (valores **muito** abaixo da média), 1, 4 e 7 (valores abaixo da média).

A análise acima leva a criação de um mapa temático com a seguinte configuração:

- Azul escuro: grupos 0 e 8 (valores muito acima da média);
- Azul claro: grupo 3 (valores pouco acima da média);
- Vermelho: grupo 2 (valores muito abaixo da média);
- Rosa: grupos 1, 4 e 7 (valores pouco abaixo da média).

O resultado deste mapeamento temático encontra-se na figura 50:

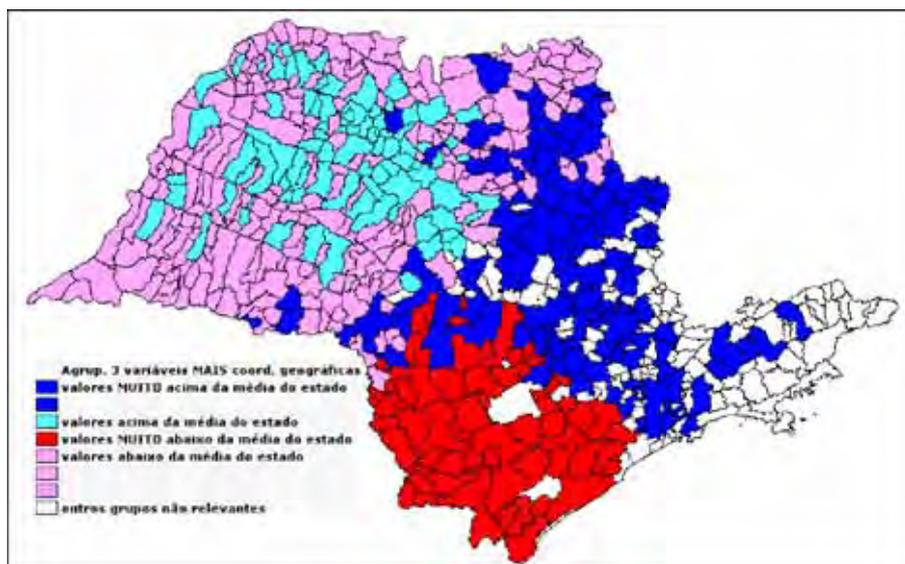


Figura 50: Mapa temático dos grupos formados pelos valores do IDH-M e das coordenadas dos centróides<sup>45</sup>.

Elaboração: Carlos José de Almeida Pereira.

O mapa da figura 50 novamente confirma a existência dos dois grupos de municípios já discutidos anteriormente, com a adição de um novo grupo, representado em azul claro, de municípios que possuem valores acima da média (porém não tão acima quanto o grupo principal). Também podemos identificar uma região de valores abaixo da média na porção oeste do Estado, mas não tão baixos quanto os encontrados na região identificada ao sul.

Este novo resultado é muito interessante se nos remetermos ao estudo da dissertação de mestrado deste autor (PEREIRA, 2003). Apresentando de uma forma bastante resumida, aquele estudo teve por objetivo mostrar a relação de influência entre o grau de desenvolvimento de uma região (representada naquele estudo pelo IDH-M) e o perfil de Capital Cultural<sup>46</sup> dos candidatos ao vestibular da UNESP para um campus localizado nessa mesma região. O perfil de Capital Cultural era representado, naquele trabalho, por um número que deveria ser usado apenas em comparação. Assim, podia-se comparar a “quantidade” de Capital Cultural disponível para os diversos grupos de alunos candidatos ao vestibular da UNESP para uma mesma carreira, localizada em campi diferentes.

Um dos cursos estudados foi o de Ciências Biológicas, disponível nos campi de Assis, São José do Rio Preto, Botucatu e Rio Claro. A figura 51 repete o mapa já apresentado na figura 39, porém com as cidades dos campi citados em destaque.

45 Não foi possível produzir uma legenda sem repetição de cores (a cor azul aparece duas vezes e a cor rosa aparece 3 vezes) devido a limitações no próprio software TerraView.

46 Para maiores detalhes sobre o conceito de Capital Cultural, bem como a metodologia adotada para o cálculo de um indicador de perfil de Capital Cultural, consultar (PEREIRA, 2003).

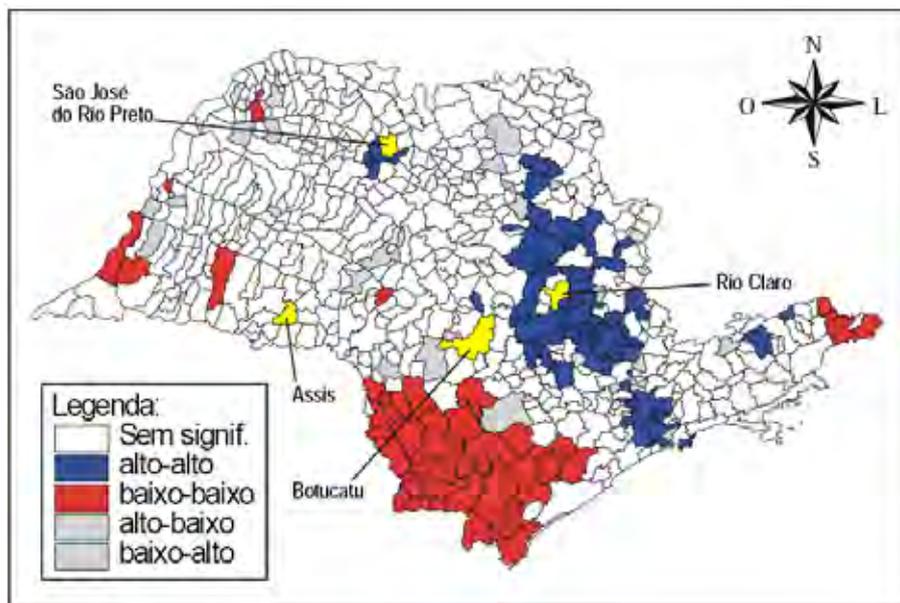


Figura 51: Campi da UNESP com Ciências Biológicas.

Fonte: (PEREIRA, 2003, p.82)

Os valores calculados para o perfil de capital cultural foram:

- Assis: 1,69
- São José do Rio Preto: 2,93
- Botucatu: 4,19
- Rio Claro: 4,54

Pereira (2003, p.82) descreve esses valores:

Novamente o valor do perfil de capital cultural para o campus de Rio Claro se destaca como maior valor entre os campi analisados, sugerindo que sua localização dentro da região de “altos” valores do IDH puxa esse valor para cima. Logo em seguida podemos notar o valor ainda alto do campus de Botucatu, localizado na “fronteira” da mesma região de “altos” valores do IDH, mas também próximo da região de “baixos” valores do IDH. [...]

A ordenação dos valores para os campi de Assis e São José do Rio Preto também reflete sua localização, ambos próximos da região de “baixos” valores do IDH localizada a oeste do Estado. O campus de Assis sofreria ainda a influência da região de “baixos” valores do IDH localizada ao sul do Estado, justificando seu menor valor entre os campi estudados.

A figura 52 apresenta a localização desses mesmos campi, mas agora utilizando o mapa temático criado com o módulo RNA do GAIA:

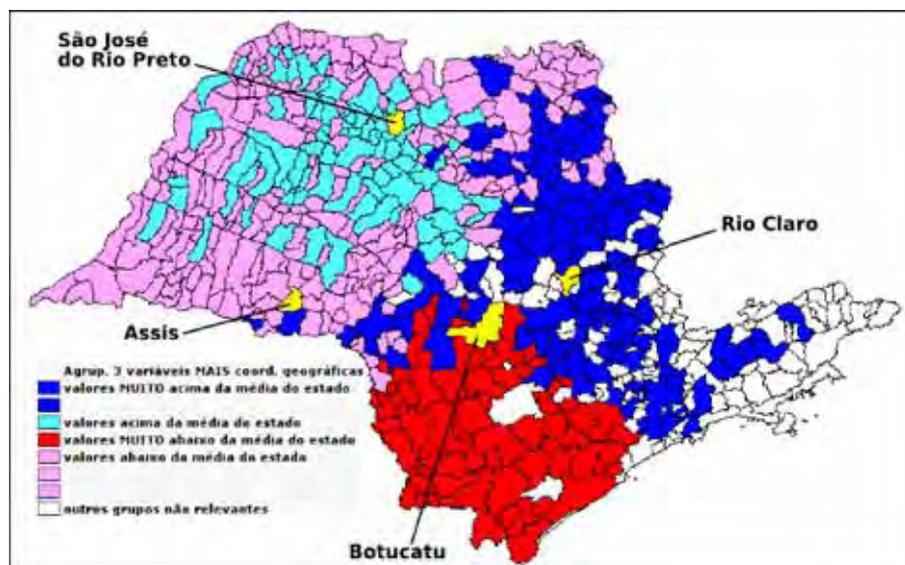


Figura 52: Campi da UNESP com Ciências Biológicas, em relação à configuração espacial do IDH-M no Estado de São Paulo identificada com o módulo RNA do GAIA.  
Elaboração: Carlos José de Almeida Pereira.

As explicações para os valores referentes aos campi de Rio Claro, Botucatu e Assis continuam as mesmas, porém obteve-se uma melhor explicação para o valor mais elevado do campus de São José de Rio Preto em relação ao campus de Assis, já que aquele campus está situado em uma região de valores levemente acima da média geral do Estado. O mapa gerado com o módulo RNA do GAIA trouxe, portanto, uma maior qualidade para a análise dos dados daquele trabalho.

São resultados bem interessantes, porém, as variáveis que compõem o IDH-M possuem, por assim dizer, uma grande qualidade: são construídas segundo uma metodologia comum, por uma mesma fonte. Mas como se comportaria o módulo RNA utilizando não só uma maior quantidade de variáveis de entrada, mas também variáveis advindas de fontes e metodologias diversas?

Realizou-se, portanto, como último teste, o mesmo tipo de análise (desenvolvimento nos municípios de São Paulo), porém utilizando variáveis diversas, disponíveis no site da Fundação Sistema Estadual de Análise de Dados - SEADE<sup>47</sup>.

47 <http://www.seade.gov.br>, link “informações socioeconômicas”, “informações municipais”, “informações dos municípios paulistas”.

As variáveis escolhidas<sup>48</sup> foram:

- grau de urbanização (ano 2000);
- média de anos de estudos da população de 15 a 64 anos (ano 2000);
- taxa de analfabetismo da população de 15 anos e mais (ano 2000);
- domicílios com infra-estrutura interna urbana adequada (ano 2000);
- médicos atuando na área da saúde municipal (ano 1999);
- população de 18 a 24 anos com ensino médio completo (ano 2000);
- latitude do centróide do município;
- longitude do centróide do município.

A variável “médicos atuando na área de saúde municipal” foi dividida pelo número de habitantes do município para se obter o número relativo, o que permitirá a comparação entre municípios. Todas as outras variáveis são médias, taxas ou porcentagens, tornando desnecessário este cuidado adicional.

Outro fato interessante deste exemplo será o de ver como o processamento via redes neurais vai se comportar com relação a variável “taxa de analfabetismo”, pois para definir uma região desenvolvida esta variável deverá ter valores pequenos (abaixo da média do Estado), enquanto todas as outras deverão ter valores acima da média (e vice-versa para definir uma região pouco desenvolvida).

Executou-se novamente o módulo RNA do GAIA, usando as oito variáveis descritas acima como entradas para a rede neural. Foram identificados desta vez 12 agrupamentos, cujas características são apresentadas na figura 53.

---

<sup>48</sup> Não foi realizado nenhum estudo específico para a escolha das variáveis. O único critério utilizado foi o de escolher variáveis que pudessem representar o estado de desenvolvimento do município em áreas diferentes, tais como infraestrutura urbana, saúde e educação. Uma escolha mais criteriosa e mais embasada dessas variáveis com certeza levaria a resultados mais adequados. A descrição completa das variáveis pode ser encontrada no Anexo 2.

resultadogaia03.txt (~RJNAPI) - gedit

File Edit View Search Tools Documents Help

New Open Save Print... Undo Redo Cut Copy Paste Find Replace

resultadogaia03.txt

	GRUBB	MDANOSEST	TXAMAF	INFRADOM	MEDICOS	ENSMED	LLONG	LLAT
Media geral:	0.331891	-0.140775	-0.079566	0.510930	-0.372078	-0.087488	-0.010930	0.082279
Desv padrao:	0.247476	0.178559	0.238182	0.215429	0.177117	0.237863	0.275733	0.298429
Grupo 0	0.512524 (+0.7)	0.110000 (+1.4)	-0.380388 (-1.3)	0.523883 (+0.1)	-0.355437 (+0.1)	0.056796 (+0.6)	0.206019 (+0.8)	-0.077476 (-0.5)
Grupo 1	0.540755 (+0.8)	-0.134717 (+0.0)	-0.202264 (-0.5)	0.190000 (-1.5)	-0.412264 (-0.2)	-0.272641 (-0.8)	0.366981 (+1.4)	-0.236604 (-1.1)
Grupo 2	-0.281765 (-2.5)	-0.382059 (-1.4)	0.190588 (+1.1)	0.332647 (-0.8)	-0.396176 (-0.1)	-0.363824 (-1.2)	0.245000 (+0.9)	-0.268529 (-1.2)
Grupo 3	0.179687 (-0.6)	-0.290781 (-0.8)	-0.045781 (+0.1)	0.520156 (+0.0)	-0.454375 (-0.5)	-0.345313 (-1.1)	0.066719 (+0.3)	-0.306875 (-1.3)
Grupo 4	0.462958 (+0.5)	-0.131972 (+0.0)	-0.164648 (-0.4)	0.647042 (+0.6)	-0.446620 (-0.4)	-0.136901 (-0.2)	-0.019014 (-0.0)	0.059155 (-0.1)
Grupo 5	0.318378 (-0.1)	-0.155811 (-0.1)	0.081757 (+0.7)	0.578784 (+0.3)	-0.460811 (-0.5)	-0.010000 (+0.3)	-0.362838 (-1.3)	0.093784 (+0.0)
Grupo 6	-0.047857 (-1.5)	-0.195714 (-0.3)	-0.197857 (-0.5)	0.713571 (+0.9)	-0.420000 (-0.3)	-0.068571 (+0.1)	0.210714 (+0.8)	0.117143 (+0.1)
Grupo 7	0.432202 (+0.4)	-0.071927 (+0.4)	-0.145505 (-0.3)	0.602385 (+0.4)	-0.348624 (+0.1)	0.058991 (+0.6)	-0.096881 (-0.3)	0.391009 (+1.0)
Grupo 8	0.360750 (+0.1)	-0.287750 (-0.8)	0.042500 (+0.5)	0.562500 (+0.3)	-0.313000 (+0.3)	-0.295500 (-0.9)	-0.019500 (-0.0)	0.388500 (+1.0)
Grupo 9	0.198710 (-0.5)	-0.232581 (-0.5)	0.233226 (+1.3)	0.497097 (-0.1)	-0.267258 (+0.6)	0.082419 (+0.7)	-0.311129 (-1.1)	0.472258 (+1.3)
Grupo 10	0.082500 (-1.0)	-0.326667 (-1.0)	0.087500 (+0.7)	0.634167 (+0.6)	0.273333 (+3.6)	-0.101667 (-0.1)	-0.037500 (-0.1)	0.067500 (-0.0)
Grupo 11	0.010000 (-1.3)	-0.228889 (-0.5)	0.232222 (+1.3)	-0.492222 (-4.7)	-0.386667 (-0.1)	-0.048889 (+0.2)	-0.443333 (-1.6)	0.147778 (+0.2)

Ln 1, Col 1 INS

Figura 53: Características dos grupos identificados no processamento realizado usando os dados provenientes do SEADE.

Elaboração: Carlos José de Almeida Pereira.

Novamente, não precisamos analisar o comportamento dos valores relativos às coordenadas geográficas, pois elas só serviram para agrupar os dados espacialmente. As demais análises da tabela acima revela que:

- os grupos 0 e 7 são os únicos que possuem todos os valores acima das médias gerais, com exceção da variável “taxa de analfabetismo” que é negativa, como aliás tínhamos previsto inicialmente que seria necessário para uma correta identificação de grupos de municípios desenvolvidos;
- comparando os valores individuais de cada variável, concluímos que o grupo 0 reúne municípios mais desenvolvidos que o grupo 7;
- analogamente, os grupos 2 e 3 são os únicos que possuem todos os valores abaixo da média, com exceção da “taxa de analfabetismo”, que é positiva;
- comparando os valores individuais de cada variável, é possível estabelecer uma pequena hierarquia entre os grupos 2 e 3, sendo o grupo 2 o que reúne os municípios menos desenvolvidos do Estado.

A análise acima leva a criação de um mapa temático com a seguinte configuração:

- Azul escuro: grupo 0;
- Azul claro: grupo 7;
- Vermelho: grupo 2;
- Rosa: grupo 3.

O resultado deste mapeamento temático encontra-se na figura 54:

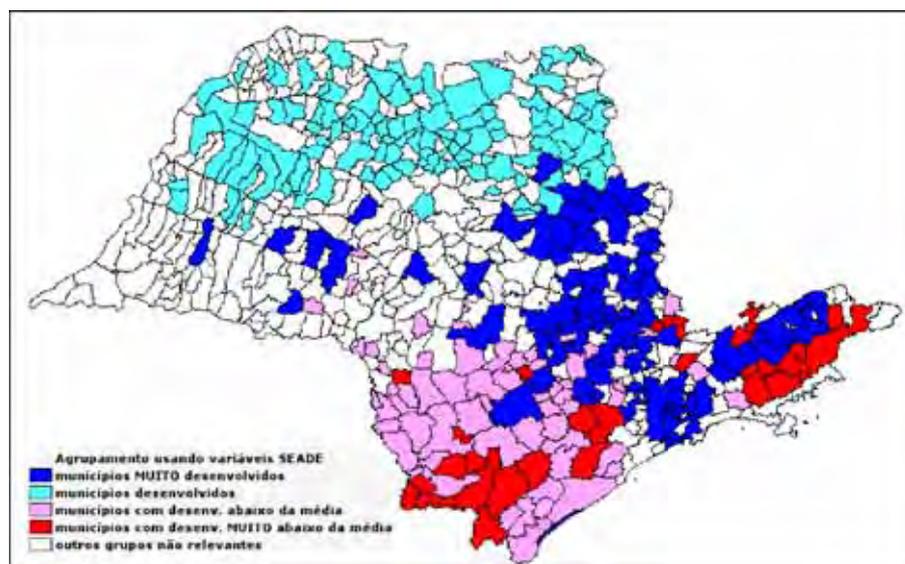


Figura 54: Mapa temático dos agrupamentos - dados do SEADE.  
Elaboração: Carlos José de Almeida Pereira.

Novamente, este resultado confirma os resultados anteriores. Também a utilização deste último mapa aumentaria a qualidade da análise realizada acerca da influência do grau de desenvolvimento sobre o perfil de capital cultural dos candidatos que buscam os vestibulares desses municípios, como visto anteriormente.

Após a apresentação desses exemplos de análise, destacamos os seguintes fatos:

- todos os processamentos foram realizados utilizando-se os parâmetros fornecidos como padrão pelo módulo RNA do GAIA. Isto significa que um pesquisador, mesmo sem conhecimento dos detalhes de funcionamento das redes neurais artificiais (e principalmente, seus parâmetros de configuração) é capaz de executar um processamento básico para obter resultados exploratórios preliminares;
- a utilização de métodos de agrupamento de dados possibilita uma maior qualidade nos resultados, pois permite uma análise mais completa, baseada em um certo número de variáveis, ao invés de baseada apenas em uma única variável. Adicionalmente, a rede neural auto-organizável permite a redução da dimensionalidade dos dados ( $n$  variáveis de entrada, representando  $n$  dimensões, reduzidas para as duas dimensões da rede de neurônios), o que causa uma melhor representação dos dados: “O objetivo do método é representar os dados de entrada em um espaço de menor dimensão, de forma que certas propriedades da estrutura dos dados sejam preservadas o mais fielmente possível” (KASKI, 1997a, p.14).
- o uso da rede neural auto-organizável de Kohonen possibilita um grande ganho de performance, reduzindo o tempo de processamento do algoritmo de agrupamento. Por exemplo, se quisermos identificar os grupos existentes em um universo composto por 5.000 itens de dados, um algoritmo de agrupamento hierárquico necessitará de 122.500.000.000<sup>49</sup> passos de processamento, enquanto que o mesmo agrupamento realizado através de uma rede neural auto-organizável necessitará de apenas 1.000.000.000<sup>50</sup> passos de processamento. A performance piora muito quando aumentamos o número de dados, pois o crescimento no

---

49 No agrupamento hierárquico, é necessário comparar cada elemento com todos os outros, logo temos 5000 x 5000 comparações = 25000000. Para se chegar a um total de 100 grupos, é preciso repetir esse processo 4900 vezes, resultando em 122.500.000.000 passos de processamento.

50 Em uma rede com 100 neurônios, precisaremos comparar cada elemento com todos os neurônios, logo temos 5000 x 100 comparações = 500000. Se programarmos o aprendizado total para 2000 épocas, teremos um total de 1.000.000.000 de passos de processamento.

tempo do algoritmo de agrupamento tradicional é exponencial. Seguindo o mesmo exemplo, o processamento tradicional de um total de 6000 itens de dados, eleva o número de passos de processamento para 212.400.000.000 (aumento de 73%), enquanto que no processo via redes neurais o número total sobe para apenas 1.200.000.000 passos de processamento (aumento de 20%).

Finalizamos esta seção, a exemplo do que foi feito na seção sobre a lógica nebulosa, apresentando alguns trabalhos que utilizaram uma RNA de Kohonen como alternativa a outros métodos, neste caso métodos estatísticos, tais como a análise fatorial, análise de componentes principais e métodos de agrupamento hierárquico (*hierarchical clustering*). Estes trabalhos atestam a eficácia do uso deste tipo de RNA perante os outros métodos, sendo que alguns deles chegam a recomendar seu uso, já que os resultados obtidos através desta ferramenta se mostraram mais vantajosos.

- Análise de componentes principais e mapas auto-organizáveis para a visualização e classificação de risco de incêndio em regiões de floresta (ANNAS; KANAI; KOYAMA, 2007):

Este trabalho realizou uma análise de dados para a avaliação e identificação dos pontos com alto risco de incêndio nas florestas da Indonésia. Utilizou um banco de dados complexo, devido à grande extensão da região de estudo e à alta variabilidade na localização desses pontos. Os dados foram analisados através do método de análise de componentes principais e de uma rede neural artificial de Kohonen e concluiu que as características gráficas dos resultados gerados pela RNA permitiram uma melhor classificação dos níveis de risco de incêndio, de forma a possibilitar uma fácil interpretação desse risco associado a um ponto específico da floresta;

- Uma comparação entre uma rede neural auto-organizável de Kohonen e métodos de agrupamento hierárquico (MANGIAMELI; CHEN; WEST, 1996):

Os métodos de agrupamento hierárquico (métodos estatísticos) tendem a gerar erros de classificação quando aplicados a conjuntos de dados que não se encaixem na condição ideal da existência de agrupamentos compactos e com limites bem definidos. Neste trabalho foram realizados testes comparativos em 252 bases de dados que apresentavam vários tipos de imperfeições, tais como

dispersão, *outliers*, variáveis irrelevantes e agrupamentos com quantidades variáveis de elementos. Demonstrou-se que os resultados dos agrupamentos obtidos através de uma RNA de Kohonen apresentaram qualidade superior aos obtidos através dos métodos de agrupamento hierárquico;

- Uma comparação entre a RNA do tipo mapa auto-organizável e alguns métodos estatísticos em estudos de comunidades ecológicas (GIRAUDEL; LEK, 2001):

Este trabalho buscou sumarizar a estrutura de uma comunidade ecológica através da análise de dados sobre espécies animais ou vegetais, relativos a densidade, frequência, proporção e presença/ausência dessas espécies, utilizando uma RNA do tipo mapa auto-organizável e técnicas estatísticas clássicas (análise de componentes principais, análise de correspondência, entre outras) objetivando comparar seus resultados. O estudo de comunidades ecológicas leva a obtenção de uma matriz de dados imensa, o que torna difícil a caracterização da sua estrutura. As similaridades encontradas entre os resultados obtidos através da RNA e os obtidos através dos métodos clássicos levaram os autores a concluir que a aplicação da RNA em estudos ecológicos não só é válida, mas também é recomendada, devido a sua capacidade de encontrar estruturas não esperadas nos dados;

- Uma avaliação das RNAs do tipo mapa auto-organizável como uma alternativa robusta à análise fatorial em aplicações de mineração de dados (*data mining*) (KIANG; KUMAR, 2001):

Este trabalho comparou as performances de uma rede neural do tipo mapa auto-organizável e do método de análise fatorial em procedimentos de identificação de agrupamentos. Os autores utilizaram um conjunto de dados criado artificialmente a partir de um modelo estatístico construído especificamente para a realização das comparações pretendidas. Assim, já se sabe previamente a que agrupamento cada item de dado pertence, permitindo uma avaliação precisa da qualidade do agrupamento gerado por cada um dos métodos.

Os testes foram realizados em quatro grupos de dados, gerados através da combinação de duas características: agrupamentos homogêneos (mesmo tamanho) ou heterogêneos (tamanhos diferentes) e dados puros ou distorcidos. Esta distorção nos dados foi simulada através da inserção de pequenas variações

aleatórias (“ruído”), porém de forma a não alterar as características do modelo estatístico definido previamente. Buscou-se, através da inserção dessas distorções, uma maior similaridade entre esses dados de teste e os que são encontrados no mundo real.

Os autores utilizaram duas métricas para avaliar as performances dos métodos: a porcentagem de itens de dados cujo agrupamento foi corretamente identificado, e uma medida de similaridade entre dois agrupamentos realizados no mesmo conjunto de dados (HUBERT; ARABIE, 1985). Esta medida é representada por um número entre 0 e 1, onde 1 representa que os dois agrupamentos comparados são exatamente iguais. Neste trabalho, comparou-se o agrupamento gerado pelo método em questão e o agrupamento original previamente definido.

Um resumo dos resultados obtidos é apresentado na tabela 2:

		Dados puros		Dados distorcidos	
		Agrupamentos homogêneos	Agrupamentos heterogêneos	Agrupamentos homogêneos	Agrupamentos heterogêneos
Porcentagem de acerto	RNA	83%	82%	88%	89%
	Análise fatorial	86%	85%	51%	51%
Medida de similaridade	RNA	0,81	0,79	0,85	0,85
	Análise fatorial	0,83	0,82	0,59	0,23

Tabela 2: Comparação entre resultados de agrupamentos obtidos através de RNAs e análise fatorial.

Fonte: (KIANG; KUMAR, 2001)

Podemos notar que, para dados não distorcidos, o método de análise fatorial gera resultados apenas um pouco melhores que os obtidos pela RNA. Porém, para dados distorcidos (isto é, mais próximos do tipo de dado encontrado em situações reais) a RNA tem uma performance muito melhor que a obtida através da técnica de análise fatorial. Esses resultados, entre outros, levaram os autores a apoiarem fortemente a adoção das RNA de Kohonen como uma alternativa à análise fatorial.

### 3.4. Aplicabilidade das técnicas apresentadas

Concluimos este capítulo com uma discussão sobre a aplicabilidade das técnicas apresentadas, isto é, para qual tipo de informação geográfica cada técnica é mais adequada, em especial focando as funcionalidades disponibilizadas pelo *software* GAIA.

A Lógica Nebulosa (através de um Sistema de Raciocínio Nebuloso), como já vimos, permite que se evite a imposição de limites rígidos aos dados. Isto é especialmente útil quando estamos trabalhando com informação geográfica numérica (figura 6, página 34), também chamada de grade regular ou MNT (modelo numérico do terreno). Neste tipo de informação geográfica, temos um valor numérico associado, teoricamente, a cada um dos pontos do terreno. Fazendo referência ao estudo de caso apresentado neste trabalho, podemos pensar que temos a informação do teor de algum componente químico referente a cada milímetro de solo. Matematicamente, utiliza-se o termo “contínua” para designar uma informação que existe em todos os pontos, em oposição a “discreta”, caso em que só teríamos informação em alguns pontos específicos<sup>51</sup>.

Como vimos na fundamentação teórica da Lógica Nebulosa (seção 3.2.1, página 54), não é possível ao ser humano trabalhar com a realidade na sua totalidade, ou seja, não é possível levar em consideração cada valor individual da propriedade em todos os pontos do terreno. Na busca, portanto, de um modelo simplificado desta realidade, criamos grupos (ou classes) de pontos com características semelhantes.

A Lógica Nebulosa possibilita não só uma representação mais adequada dessas classes (já que as mesmas não apresentarão limites rígidos e artificiais, como pode ser visto p.ex. nas figuras 22, 23, 24 e 25, páginas 68 e 69, ilustrando a propriedade química “alumínio”), mas também a geração de resultados com uma quantidade maior de informações disponíveis. Também estes resultados não apresentarão os limites rígidos e artificiais já discutidos anteriormente.

Desta forma, toda informação geográfica que for representada por valores associados a pontos do terreno poderá ser trabalhada utilizando a Lógica Nebulosa, e em especial com o módulo correspondente disponibilizado pelo GAIA, como por exemplo: propriedades

---

<sup>51</sup> Neste trabalho, transformamos uma informação discreta (propriedades químicas do solo em alguns pontos específicos), conforme pode ser visto na figura 16 (página 62), em uma informação contínua através de um procedimento estatístico denominado de interpolação.

químicas do solo, inclinação do terreno, distância do ponto a algum recurso específico (estradas, centros de distribuição, hospitais, fonte de água, depósitos, etc.), quantidade de chuvas, temperatura média, etc.

O módulo de Lógica Nebulosa do GAIA também pode ser usado para classificação e combinação de imagens de satélite, que pode ser entendida igualmente como uma grade numérica, onde a cada ponto está associado um valor numérico que representa o resultado da medição realizada pelo sensor remoto (um satélite em órbita ou uma câmera a bordo de um avião) de alguma característica<sup>52</sup> daquele ponto.

A Lógica Nebulosa não é muito adequada para o processamento de dados de área (dados associados a uma área geográfica definida, como pode ser visto na figura 8, página 35), pois os próprios limites da área em questão representam, por si só, limites rígidos e também artificiais para os dados a ela relacionados (a divisão territorial, em seus diversos níveis, é uma abstração administrativa criada pelo homem). Porém se a quantidade de áreas for muito grande, como por exemplo, a totalidade de municípios de uma das grandes regiões brasileiras, ou mesmo utilizando-se as áreas que representam os setores censitários ao invés dos municípios (caso a configuração da pesquisa assim o permita), pode-se obter vantagens com o uso desta técnica. De qualquer modo, em seu atual estágio de desenvolvimento o software GAIA não permite a utilização de dados de área no processamento efetuado pelo módulo de Lógica Nebulosa, a não ser que se faça um pré-processamento externo, como por exemplo, convertendo os dados de área em dados pontuais utilizando-se algum outro Sistema de Informação Geográfica que disponha desse recurso, como por exemplo o Spring (INPE).

A Rede Neural Artificial desenvolvida como parte deste trabalho (mapa auto-organizável de Kohonen) se propõe a identificar e evidenciar possíveis agrupamentos existentes nos dados fornecidos. A grande vantagem deste método é a capacidade que a rede neural tem de “aprender” sozinha com os dados, isto é, não exige do pesquisador um profundo conhecimento prévio da estrutura subjacente aos dados, como acontece com outros métodos matemáticos e/ou estatísticos. Isto permite que o pesquisador possa realizar, de forma bastante facilitada, um primeiro estudo (exploratório) dos dados.

Outra grande vantagem deste método é a sua aplicabilidade a qualquer tipo de informação geográfica, seja ela representada por pontos, linhas (rede), áreas, e até mesmo numéricas (grades regulares ou modelos numéricos de terreno). Adicionalmente, podemos inserir no processamento as coordenadas geográficas dos elementos cujos dados estão sendo

---

<sup>52</sup> Para maiores detalhes sobre Sensoriamento Remoto, recomendamos a consulta a Novo (1992).

processados, buscando um agrupamento não só nos valores dos dados, mas também um agrupamento geográfico, isto é, levar em consideração a proximidade entre os objetos para identificar e definir os grupos. Registramos porém que, no atual estágio do seu desenvolvimento, o *software* GAIA não permite a utilização do módulo de Rede Neural Artificial com dados armazenados em grades regulares.

Não há nenhuma restrição ao tipo de informação que pode ser processada pela Rede Neural implementada pelo GAIA, contanto que a mesma seja quantitativa, ou seja, que os valores numéricos representem quantidades, e não algum tipo de classificação categórica.

O requisito para que este método possa gerar resultados satisfatórios é a existência de uma grande quantidade de dados de entrada, de forma que a Rede Neural possa ter dados suficientes para “aprender” e identificar a estrutura interna desses dados. Quanto menor a quantidade de dados de entrada, mais difícil fica para a rede neural captar todos os detalhes relevantes e identificar corretamente os grupos existentes.

## Capítulo 4

### CONSIDERAÇÕES FINAIS

Foram apresentadas, no início deste trabalho, algumas dificuldades que podem ser encontradas na condução de procedimentos de produção e análise de informações geográficas: inadequação/incapacidade das ferramentas computacionais tradicionais, incapacidade de processamento da grande quantidade de informações que vem sendo produzida atualmente, e a grande complexidade envolvida para utilização de alguns métodos matemáticos/estatísticos.

Para auxiliar na solução desses problemas, apresentamos como alternativa a utilização de técnicas de análise provenientes da Computação Inteligente, especificamente a Lógica Nebulosa e as Redes Neurais Artificiais. Com esse objetivo em tela, foi desenvolvido um *software* específico para utilização dessas técnicas de forma integrada com a principal ferramenta utilizada no Geoprocessamento, que é o Sistema de Informações Geográficas.

Os estudos descritos nas seções 3.2.1 (Lógica Nebulosa) e 3.3.1 (Redes Neurais Artificiais), conduzidos utilizando-se o *software* citado, nos remetem as seguintes confirmações:

- é possível a utilização de forma integrada das técnicas da Computação Inteligente e das ferramentas de Geoprocessamento;
- o processamento de informações geográficas através das técnicas de Computação Inteligente produziu resultados similares ou melhores que os obtidos através de técnicas tradicionais (por exemplo, os resultados obtidos com a aplicação da Lógica Nebulosa tiveram uma qualidade muito maior do que os resultados obtidos através do método convencional. Esta qualidade maior significa principalmente maior disponibilização de resultados — o método convencional

não foi capaz de estabelecer um grau de fertilidade do solo para a maior parte do território do Estado de Santa Catarina, enquanto que o método nebuloso gerou resultados para praticamente a totalidade do território — e menor rigidez nesses resultados);

- o processamento de informações geográficas através das técnicas de Computação Inteligente, utilizando o software desenvolvido no âmbito deste trabalho, não exigiu profundos conhecimentos adicionais, que não os ligados ao Geoprocessamento e ao tema em estudo.

A elaboração de uma tese de doutorado que, além do texto final, apresenta e disponibiliza um produto — o *software* GAIA — se mostrou como uma atividade muito frutífera, uma vez que possibilitou ir além da utilização dos conceitos nas análises. Apresentamos como possíveis desdobramentos futuros:

- o prosseguimento desta pesquisa, adicionando ao GAIA novas técnicas de análise da informação geográfica baseadas na Computação Inteligente, como por exemplo os Algoritmos Genéticos e os Sistemas Especialistas;
- o estabelecimento de uma comunidade para o continuado desenvolvimento do GAIA (conserto de erros de operação, elaboração de documentação adicional e tutoriais, tradução para outras línguas e suporte colaborativo aos usuários);
- Criação de uma disciplina de pós-graduação sobre Geoprocessamento e Computação Inteligente, objetivando formar pesquisadores na utilização integrada dessas técnicas, bem como dar suporte a realização de pesquisas que utilizem tais técnicas.

Ressaltamos o caráter didático do software GAIA, bem como suas possibilidades de expansão, já que o mesmo está disponível como Software Livre. Esperamos que, desta forma, ele possa se tornar um laboratório aberto, permitindo:

- o estudo do modo de funcionamento (algoritmos) dos módulos já disponíveis;
- a realização de alterações visando melhorias nos procedimentos de análise de dados;

- a realização de experimentos, possibilitando assim o desenvolvimento de novas ferramentas de Geoprocessamento;
- a utilização como exemplo prático em processos educacionais ligados à área de Computação e de Geoprocessamento;
- a utilização como exemplo de uso da biblioteca TerraLib para o desenvolvimento de ferramentas de Geoprocessamento.

Finalmente, gostaríamos de ressaltar também o compromisso político que firmamos neste trabalho ao não só disponibilizar o *software* GAIA para uso geral, mas principalmente por fazê-lo como Software Livre. Acreditamos ser esta filosofia um requisito fundamental tanto em ambientes educacionais — para que possamos contribuir para a formação de cidadãos críticos, e não “clientes” das empresas de software proprietário — quanto nos ambientes acadêmicos de forma geral, possibilitando assim o verdadeiro acesso ao conhecimento, uma vez que acreditamos que o conhecimento não pode e não deve ser transformado em mercadoria.

## BIBLIOGRAFIA

- ANNAS, S.; KANAI, T.; KOYAMA, S. *Principal component analysis and self-organizing map for visualizing and classifying fire risks in forest regions*. **Agricultural Information Research**, n.16, v.2, p.44-51. 2007.
- ARONOFF, S. **Geographic information systems: A management perspective**. Ottawa: WDL Publications, 1989.
- BARBOSA, C. **Álgebra de mapas e suas aplicações em sensoriamento remoto e geoprocessamento**. 1997. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1997. Disponível em <[www.dpi.inpe.br/teses/claudio/](http://www.dpi.inpe.br/teses/claudio/)>. Acesso em 29.julho.2007.
- BERGER, L. **Estudo do emprego de técnicas da análise transacional e da programação neurolinguística na melhoria da comunicação pessoal e organizacional**. 1999. Dissertação (Mestrado em Engenharia de Produção) - Programa de pós-graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 1999. Disponível em <[www.eps.ufsc.br/disserta99/berger](http://www.eps.ufsc.br/disserta99/berger)>. Acesso em 29.julho.2007.
- BÖNISCH, S. **Geoprocessamento ambiental com tratamento de incerteza: o caso do zoneamento pedoclimático para a soja no estado de Santa Catarina**. 2001. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2001. Disponível em <<http://www.dpi.inpe.br/teses/simone/>>. Acesso em 29.julho.2007.
- BOURDIEU, P. *A Escola conservadora: as desigualdades frente à escola e à cultura*. IN: NOGUEIRA, M. A. e CATANI, A. (orgs). **Escritos de educação**. Petrópolis: Vozes, 1998. Capítulo 2, p.39-64.
- . *Os três estados do capital cultural*. IN: NOGUEIRA, M. A. e CATANI, A. (orgs). **Escritos de educação**. Petrópolis: Vozes, 1998a. Capítulo 4, p.71-79.
- BURROUGH, P. **Principles of geographical information systems for land resources assessment**. Oxford: Oxford University Press, 1986.
- BURROUGH, P. A. *Fuzzy mathematical methods for soil survey and land evaluation*. **Journal of Soil Science**, v.40, p.477-492. 1989.
- CÂMARA, G. **Modelos, Linguagens e Arquiteturas para Bancos de Dados Geográficos**. 1995. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995. Disponível em <<http://www.dpi.inpe.br/teses/gilberto/>>. Acesso em 31.julho.2007.
- CÂMARA, G.; CASANOVA, M.; HEMERLY, A. S.; MAGALHÃES, G. C.; MEDEIROS, C. **Anatomia de Sistemas de Informação Geográfica**. Campinas: Instituto de Computação/UNICAMP, 1996. 193p. Disponível em <[www.dpi.inpe.br/geopro/trabalhos/analise.pdf](http://www.dpi.inpe.br/geopro/trabalhos/analise.pdf)>. Acesso em 29.julho.2007.

- CÂMARA, G.; DAVIS, C. *Introdução*. IN: CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. (orgs) **Introdução a ciência da geoinformação**. São José dos Campos: INPE, 2001. Disponível em <<http://www.dpi.inpe.br/gilberto/livro/introd/>>. Acesso em 29.julho.2007.
- CÂMARA, G.; MEDEIROS, J. S. **Geoprocessamento para projetos ambientais**. 1998. Curso apresentado nos congressos GIS Brasil (96,97 e 98) e Simposio Brasileiro de Sensoriamento Remoto (96 e 98). Disponível em <[http://www.dpi.inpe.br/gilberto/tutoriais/gis\\_ambiente/](http://www.dpi.inpe.br/gilberto/tutoriais/gis_ambiente/)>. Acesso em 1.agosto.2007.
- CÂMARA, G.; MONTEIRO, A. M. *Conceitos básicos em ciência da geoinformação*. IN: CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. (orgs) **Introdução a ciência da geoinformação**. São José dos Campos: INPE, 2001. Disponível em <<http://www.dpi.inpe.br/gilberto/livro/introd/>>. Acesso em 29.julho.2007.
- CÂMARA, G.; MONTEIRO, A. M.; MEDEIROS, J. S. *Representações computacionais do espaço: Fundamentos epistemológicos da ciência da geoinformação*. **GEOGRAFIA**, Rio Claro, v.28, n.1, p.83-96, 2003. Disponível em <<http://www.dpi.inpe.br/gilberto/livro/introd/cap5-epistemologia.pdf>>. Acesso em 29.julho.2007.
- CÂMARA, G.; SOUZA, R. C. M.; PEDROSA, B.; VINHAS, L.; MONTEIRO, A. M. V.; PAIVA, J. A.; CARVALHO, M. T.; GATTASS, M. *TerraLib: Technology in Support of GIS Innovation*. In: **Simpósio Brasileiro em Geoinformática**, n.2, 2000, São Paulo. Disponível em <[http://www.dpi.inpe.br/terralib/docs/papers/TerraLib\\_Paper\\_GeoInfo2000.pdf](http://www.dpi.inpe.br/terralib/docs/papers/TerraLib_Paper_GeoInfo2000.pdf)>. Acesso em 29.julho.2007.
- CAPRA, F. **O ponto de mutação**. 22a ed. São Paulo: Cultrix, 1999.
- CARVALHO, S.; SILVA, B. N. *Os sistemas de informação geográfica e a questão geográfica*. **Revista GEONORDESTE**, São Cristóvão, Universidade Federal de Sergipe, n.1, p.50-69, 2006. Disponível em <[www.posgrap.ufs.br/periodicos/pdf/revista\\_geo\\_06\\_1/Silvana.pdf](http://www.posgrap.ufs.br/periodicos/pdf/revista_geo_06_1/Silvana.pdf)>. Acesso em 29.julho.2007.
- CASA (Centre for Advanced Spatial Analysis). **GIS TiMELiNe**. GIS TiMELiNe Team, 2000. O objetivo do GiS TiMELiNE é apresentar um resumo visual dos eventos históricos principais no desenvolvimento dos Sistemas de Informação Geográfica, desde a sua concepção inicial na década de 60 até os dias atuais. Disponível em <<http://www.casa.ucl.ac.uk/gistimeline/welcome.htm>>. Acesso em 31.julho.2007.
- CHANG, L.; BURROUGH, P. A. *Fuzzy reasoning: A new quantitative aid for land evaluation*. **Soil survey and land evaluation**, v.7, p.69-80, 1987.
- CORRÊA, R. *Espaço, um conceito chave da Geografia*. In: CASTRO, I.; GOMES, P. C.; CORRÊA, R. (orgs.) **Geografia: conceitos e temas**. Rio de Janeiro: Ed. Bertrand Brasil, 1995. 353p.
- COX, E. **The fuzzy systems handbook: A practitioner's guide do building, using, and maintaining fuzzy systems**. London: Academic Press, 1994.
- DELATTRE, P. *Teoria/modelo*. In: ROMANO, R. (director) **Enciclopédia Einaudi**. ? : Imprensa Nacional - Casa da Moeda, 1992. V.21, p.223-287.
- DENT, B. **Principles of thematic map design**. Reading: Addison-Wesley, 1985.

- DUTRA, R. M., SPERANDIO, M., COELHO, J. *O Método Ward de Agrupamento de Dados e sua Aplicação em Associação com os Mapas Auto-Organizáveis de Kohonen*. IN: **I WorkComp Sul - Workshop de Ciências da Computação e Sistemas da Informação da Região Sul**, 2004, Florianópolis. Anais do I WorkComp Sul. Florianópolis: UNISUL, 2004. Disponível em <[http://www.labplan.ufsc.br/sperandio/ward22\\_final.pdf](http://www.labplan.ufsc.br/sperandio/ward22_final.pdf)>. Acesso em 9.dezembro.2008.
- ESRI. **Geocomputation**. GIS Dictionary, 2006a. Disponível em <<http://support.esri.com/index.cfm?fa=knowledgebase.gisDictionary.search&search=true&searchTerm=geocomputation>>. Acesso em 30.julho.2007.
- ESRI. **Geoprocessing**. GIS Dictionary, 2006b. Disponível em <<http://support.esri.com/index.cfm?fa=knowledgebase.gisDictionary.search&search=true&searchTerm=geoprocessing>>. Acesso em 30.julho.2007.
- FAUSETT, L. **Fundamentals of neural networks: Architectures, algorithms, and applications**. Prentice Hall, 1994.
- FERNANDES, A. M. **Inteligência Artificial: noções gerais**. Florianópolis: Visual Books, 2005. 160p.
- FREEMAN, J.; SKAPURA, D. **Neural Networks: Algorithms, Applications, and Programming Techniques**. Addison-Wesley, 1991.
- GALVÃO, C. O.; VALENÇA, M. J. S. (orgs) **Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais**. Porto Alegre: Editora da Universidade/UFRGS/ABRH, 1999. 246p.
- GARO, L. **Color Theory**. Department of Geography & Earth Sciences, University of North Carolina at Charlotte, in conjunction with The Virtual Geography Department, The University of Texas at Austin, 1998. Disponível em <<http://personal.uncc.edu/lagaro/cwg/color/index.html>>. Acesso em 9.dezembro.2008.
- GERARDI, L.; SILVA, B. N. **Quantificação em Geografia**. São Paulo: DIFEL, 1981. 161p.
- GIRAUDEL, J.; LEK, S. *A comparison of self-organizing map algorithm and some conventional statistical methods for ecological community ordination*. **Ecological Modelling**, n.146, p.329-339. 2001.
- GOODCHILD, M. *The vality and usefulness of laws in Geographic Information Science and Geography*. **Annals of the Association Geographers**, Malden, Association of American Geographers, n.94, v.2, 2003. Disponível em <<http://www.geog.ucsb.edu/~good/papers/393.pdf>>. Acesso em 29.julho.2007.
- HARTSHORNE, R. **The nature of Geography**. Lancaster: Association of American Geographers, 1939.
- HARVEY, D. **The condition of postmodernity**. London: Basil Blackwell, 1989. Disponível parcialmente em <[http://books.google.com.br/books?id=m4HyQpeE\\_joC&printsec=frontcover](http://books.google.com.br/books?id=m4HyQpeE_joC&printsec=frontcover)>. Acesso em 6.agosto.2008.
- HEWITSON, B; CRANE, R. (eds) **Neural Nets: Applications in Geography**. Dordrecht: Kluwer Academic Publishers, 1994.

- HUBERT, L.; ARABIE, P. *Comparing partitions*. **Journal of Classification**, n.2, p.193-218. 1985.
- JAPIASSÚ, H. **Dicionário Básico de Filosofia**. 3a ed. Rio de Janeiro: Jorge Zahar Ed., 1996.
- JULIÃO, R. P. *Geografia, Informação e Sociedade*. **GEOINOVA - Revista do Departamento de Geografia e Planejamento Regional**, Lisboa, n.0, p.95-108, 1999. Disponível em <<http://www.fcsh.unl.pt/docentes/rpj/docs/GIS.pdf>>. Acesso em 29.julho.2007.
- KASKI, S. **Data exploration using self-organizing maps**. 1997a. Tese (Doutorado em Tecnologia) - Universidade de Tecnologia de Helsinki, Espoo, 1997. Disponível em <<http://www.cis.hut.fi/sami/thesis/thesis.html>>. Acesso em 9.julho.2008.
- KASKI, S. **Example of application of the SOM: World Poverty Map**. 1997b. Disponível em <<http://www.cis.hut.fi/research/som-research/worldmap.html>>. Acesso em 1.agosto.2007.
- KASKI, S.; KOHONEN, T. *Exploratory data analysis by the self-organizing map: Structures of welfare and poverty in the world*. In: Refenes, A.; Abu-Mostafa, Y.; Moody, J.; Weigend, A. (eds). **Neural Networks in Financial Engineering**. Proceedings of the Third International Conference on Neural Networks in the Capital Markets. Singapura: World Scientific, 1996. p.498-507. Disponível em <<http://www.cis.hut.fi/sami/therest.html>>. Acesso em 9.julho.2008.
- KIANG, M. *Extending the Kohonen self-organizing map networks for clustering analysis*. **Journal Comput. Statist. Data Anal.** (CSDA), v38, 161-180, 2001.
- KIANG, M.; KUMAR, A. *An evaluation of self-organizing map networks as a robust alternative to factor analysis in data mining applications*. **Information Systems Research**, v.12, n.2, p.177-194. 2001.
- KOHONEN, T. **Self-Organizing Maps**. 3a ed. Berlin: Springer Verlag, 2001.
- LONGLEY, P.; GOODCHILD, M.; MAGUIRE, D.; RHIND, D. (eds) **Geographical Information Systems**. 2a ed. New York:Wiley, 2001. Volume 1.
- LUDWIG Jr., O.; MONTGOMERY, E. **Redes Neurais: Fundamentos e aplicações com programas em C**. Rio de Janeiro: Editora Ciência Moderna, 2007.
- MANGIAMELI, P.; CHEN, S.; WEST, D. *A comparison of SOM neural network and hierarchical clustering methods*. **European Journal of Operational Research**, n.93, p.402-417. 1996.
- MASTERS, T. **Practical neural network recipes in C++**. California: Academic Press, 1993.
- MEDEIROS, J. S. **Bancos de Dados Geográficos e Redes Neurais Artificiais: Tecnologias de Apoio à Gestão de Território**. 1999. Tese (Doutorado em Geografia) - Universidade de São Paulo, São Paulo, 1999. Disponível em <<http://www.dpi.inpe.br/teses/simeao>>. Acesso em 2.agosto.2007.
- MEIRELLES, M. S. **Análise integrada do ambiente através de geoprocessamento: uma proposta metodológica para elaboração de zoneamentos**. Rio de Janeiro, 1997. 192p. Tese (Doutorado em Geografia). Universidade Federal do Rio de Janeiro.

- MOTA FILHO, J. E. **Descobrimo o Linux**. São Paulo: Novatec, 2006. 424p.
- NARCISO, M. G., LORENA, L. A. *Uso de algoritmos genéticos em sistema de apoio à decisão para alocação de recursos no campo e na cidade*. **Revista brasileira de agroinformática**, São Paulo, v.4, n.2, p.90-101. 2002.
- NEDOVIC-BUDIC, Z. **Geographical Information Systems**, 2a ed. 2 vols. Resenha de: LONGLEY, P.; GOODCHILD, M.; MAGUIRE, D.; RHIND, D. (eds) *Geographical Information Systems*. 2a ed. 2 vols. New York:Wiley, 2001. *URISA Journal*, Illinois, v.13, n.2, p.41-43, 2001. Disponível em <<http://www.urisa.org/Journal/protect/Vol13No2/pdfs%20for%20web/budic.pdf>>. Acesso em 31.julho.2007.
- NOVO, E.M. **Sensoriamento Remoto: princípios e aplicações**. São Paulo: Editora Edgard Blücher, 1992. 308p.
- OLIVEIRA, M.T. **Comparação entre os métodos de classificação Fuzzy e Booleano para a determinação do mapa de umidade: estudo de caso**. Rio de Janeiro: Instituto Militar de Engenharia, 1994.
- OPENSHAW, S.; OPENSHAW, C. **Artificial Intelligence in Geography**. Chichester: Wiley, 1997. 329p.
- PEREIRA, C. J. **Urbanização e perfil de capital cultural de vestibulandos da Unesp: o geoprocessamento como ferramenta para estudos sociológicos**. Pesquisa Vunesp n. 20. São Paulo: Fundação Vunesp, 2005.
- PEREIRA, C. J. **O geoprocessamento como ferramenta para estudos sociológicos: O caso da relação de influência entre urbanização e o perfil de capital cultural dos vestibulandos da UNESP**. Rio de Janeiro, 2003. 90p. Dissertação (Mestrado em Estudos Populacionais e Pesquisas Sociais). Escola Nacional de Ciências Estatísticas (ENCE/IBGE). Disponível em <<http://starfighter.carlao.blogspot.com/2008/06/dissertao-de-mestrado.html>>. Acesso em 4/6/2008.
- . *Geoprocessamento e Computação Inteligente: Possibilidades, vantagens e necessidades*. In: **SEMINÁRIO DE PÓS-GRADUAÇÃO EM GEOGRAFIA DA UNESP DE RIO CLARO**, n.6, 2006, Rio Claro. Anais do 6o Seminário de Pós-Graduação da Unesp. Rio Claro: Comissão Organizadora, 2006. CD-ROM. Disponível em <<http://www.carlao2006.xpg.com.br/2006/CarlosP.pdf>>. Acesso em 29.julho.2007.
- . **Via de acesso ao conhecimento**. *Revista A Rede*, São Paulo, n.37, p.50. jun. 2008. Disponível em <[http://www.aredo.inf.br/index.php?option=com\\_content&task=view&id=1494&Itemid=465](http://www.aredo.inf.br/index.php?option=com_content&task=view&id=1494&Itemid=465)>. Acesso em 15.agosto.2008.
- POPPER, K. **A lógica da pesquisa científica**. São Paulo: EDUSP, 1975.
- RODRIGUES, M. *Geoprocessamento: um retrato atual*. **Revista Fator GIS**. Curitiba, ano 1, n.2, p.20-23, 1993.
- ROGERS, J. **Object-Oriented Neural Networks in C++**. San Diego: Academic Press, 1997.
- ROSS, T. J. **Fuzzy Logic with Engineering Applications**. New York: McGraw-Hill, 1995.

- RUSSELL, B. **Vagueness**. The Australasian Journal of Psychology and Philosophy, n.1, p. 84-92, 1923. Disponível em <<http://cscs.umich.edu/~crshalizi/Russell/vagueness>>. Acesso em 29.julho.2007.
- SALVADOR, S.; CHAN, P. *Determining the Number of Clusters/Segments in Hierarchical Clustering/Segmentation Algorithms*. **Proceedings of the 16th IEEE International Conference on Tools with Artificial Intelligence**, p.576-584, 2004. Disponível em <<http://www.cs.fit.edu/~pkc/papers/ictai04salvador.pdf>>. Acesso em 9.dezembro.2008.
- SAMT. **Introduction do SAMT**. 2008. Disponível em <[http://www.zalf.de/home\\_samt-1sa/samt1/introduction.html](http://www.zalf.de/home_samt-1sa/samt1/introduction.html)>. Acesso em 5.agosto.2008.
- SANTOS, M. **Espaço e método**. São Paulo: Nobel, 1985.
- SHELDRAKE, R. **O renascimento da natureza: O reflorescimento da ciência e de Deus**. São Paulo: Cultrix, 1991.
- SILVA, M. A. S. **Mapas auto-organizáveis na análise exploratória de dados geoespaciais multivariados**. São José dos Campos, 2004. Dissertação (Mestrado em computação aplicada). Instituto Nacional de Pesquisas Espaciais (INPE). Disponível em <<http://www.dpi.inpe.br/teses/aurelio/>>. Acesso em 9.julho.2008.
- STEFANAKIS, E.; VAZIRGIANNIS, M.; SELLIS, T. **Incorporating fuzzy logic methodologies into GIS operations**. In: INTERNATIONAL CONFERENCE ON GEOGRAPHIC INFORMATION SYSTEMS IN URBAN, REGIONAL AND ENVIRONMENTAL PLANNING, 1st, 1996, Samos, Greece. Proceedings... pp. 61-68. Disponível em <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.45.7442>>. Acesso em 2.agosto.2008.
- TEIXEIRA, A. L. **Sistemas de Informação Geográfica: Uma solução para microcomputadores de 8 bits**. Rio Claro, 1987, 242p. Tese (Doutorado em Geografia). Universidade Estadual Paulista (UNESP).
- . **Geo-Inf + Map. Um sistema de informação geográfica**. Tese de Livre-Docência. Rio Claro, UNESP, 1990.
- TOBLER, W. R. *A computer movie simulating urban growth in the Detroit region*. **Economic Geography**, 46(2), p.234-240, 1970
- . *Cellular Geography*. In: GALE, S.; OLSSON, G. (eds) **Philosophy in geography**. Dordrecht: Riedel, 1979, p.379-386. Disponível em <[www.geog.ucsb.edu/~tobler/publications/pdf\\_docs/geog\\_analysis/CellularGeog.pdf](http://www.geog.ucsb.edu/~tobler/publications/pdf_docs/geog_analysis/CellularGeog.pdf)>. Acesso em 29.julho.2007.
- VINHAS, L.; FERREIRA, K. R. *Descrição da TerraLib*. In: CASANOVA, M.; CÂMARA, G.; DAVIS, C.; VINHAS, L.; QUEIROZ, G. R. (eds) **Bancos de Dados Geográficos**. Curitiba: MundoGEO, 2005. Disponível em <<http://www.dpi.inpe.br/livros/bdados/>>. Acesso em 29.julho.2007.
- WANG, F.; SUBARYONO, B. H. *Fuzzy information representation and processing in conventional GIS software: Database design and application*. **International Journal of Geographical Information Systems**, v.4, n. 3, p.261-283. 1990.

WARD, J. H. *Hierarchical Grouping to Optimize an Objective Function*. **Journal American Statist. Assoc.**, n.58, p.236-244. 1963

WHITAKER, D. **A seleção dos privilegiados**. São Paulo: Semente, 1981.

ZADEH, L. *Forward*. In: **The Mathworks Inc. Fuzzy Logic Toolbox: User's Guide**. The Mathworks Inc., 2000. Disponível em <[www.mathworks.com/access/helpdesk/help/pdf\\_doc/fuzzy/fuzzy\\_tb.pdf](http://www.mathworks.com/access/helpdesk/help/pdf_doc/fuzzy/fuzzy_tb.pdf)>. Acesso em 12.janeiro.2002.

# **A N E X O S**

Anexo A  
DOCUMENTAÇÃO TÉCNICA DO GAIA

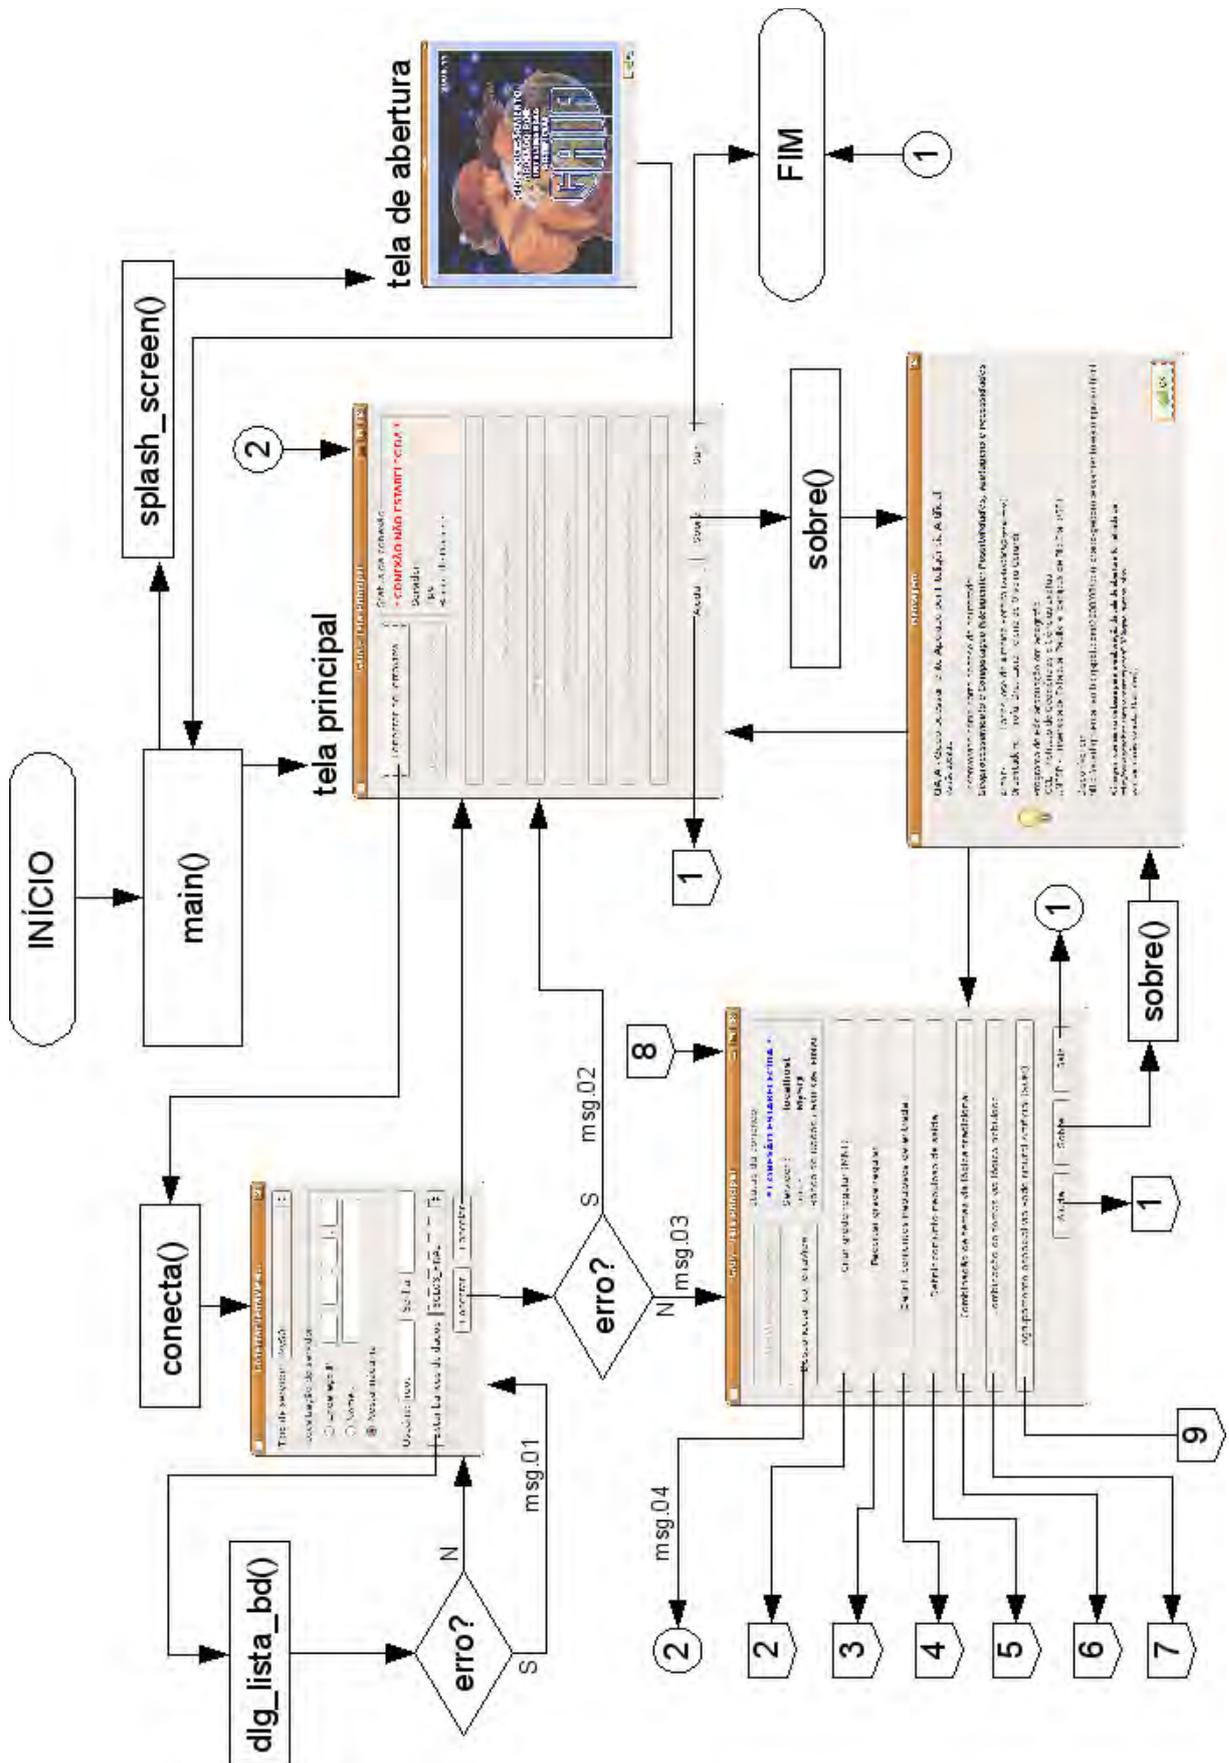
Apresentamos a seguir a documentação do *software* GAIA, dividida nas seguintes partes:

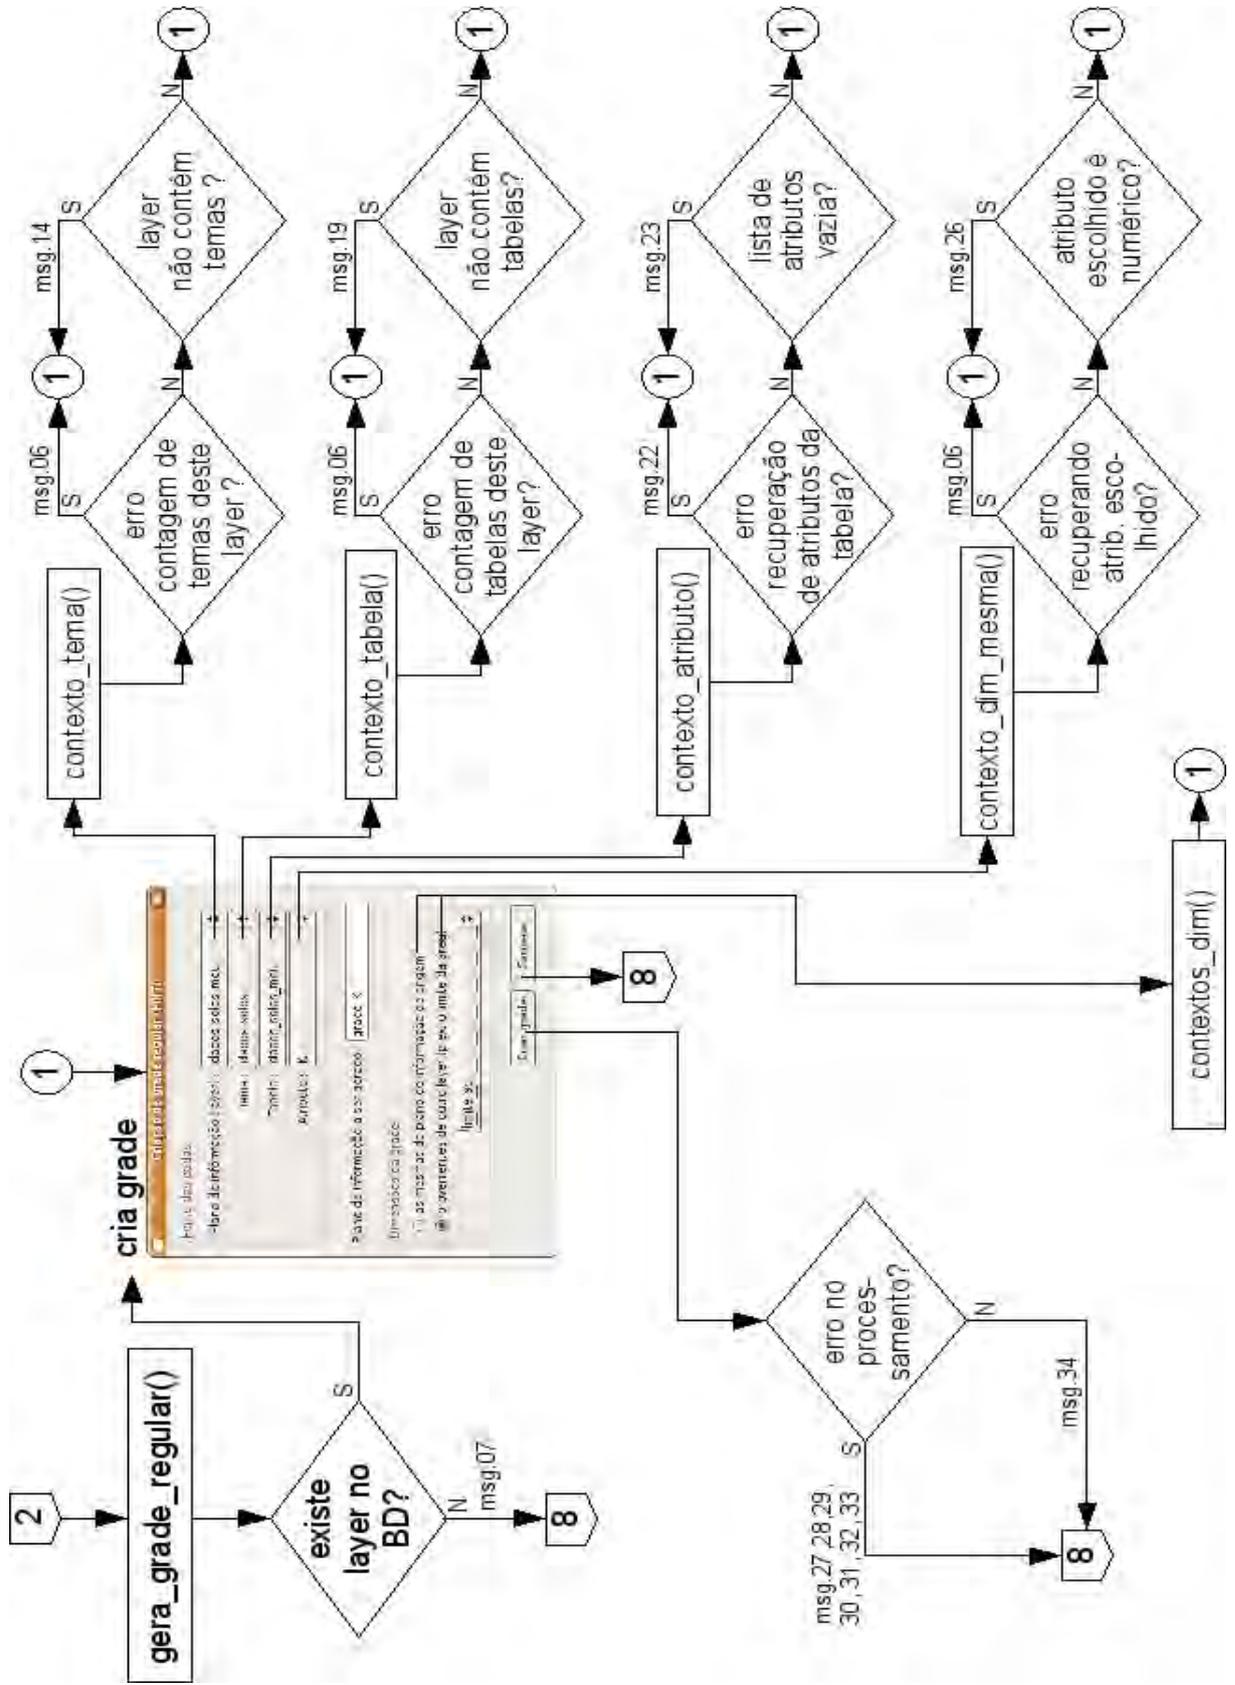
- Fluxograma da interação entre os vários elementos da interface, as principais funções que os implementam, e as mensagens apresentadas pelo programa;
- Listagem de todas as mensagens emitidas pelo programa;
- Descrição das telas e seus objetos gráficos;
- Passo-a-passo de utilização para reproduzir os resultados apresentados no texto.

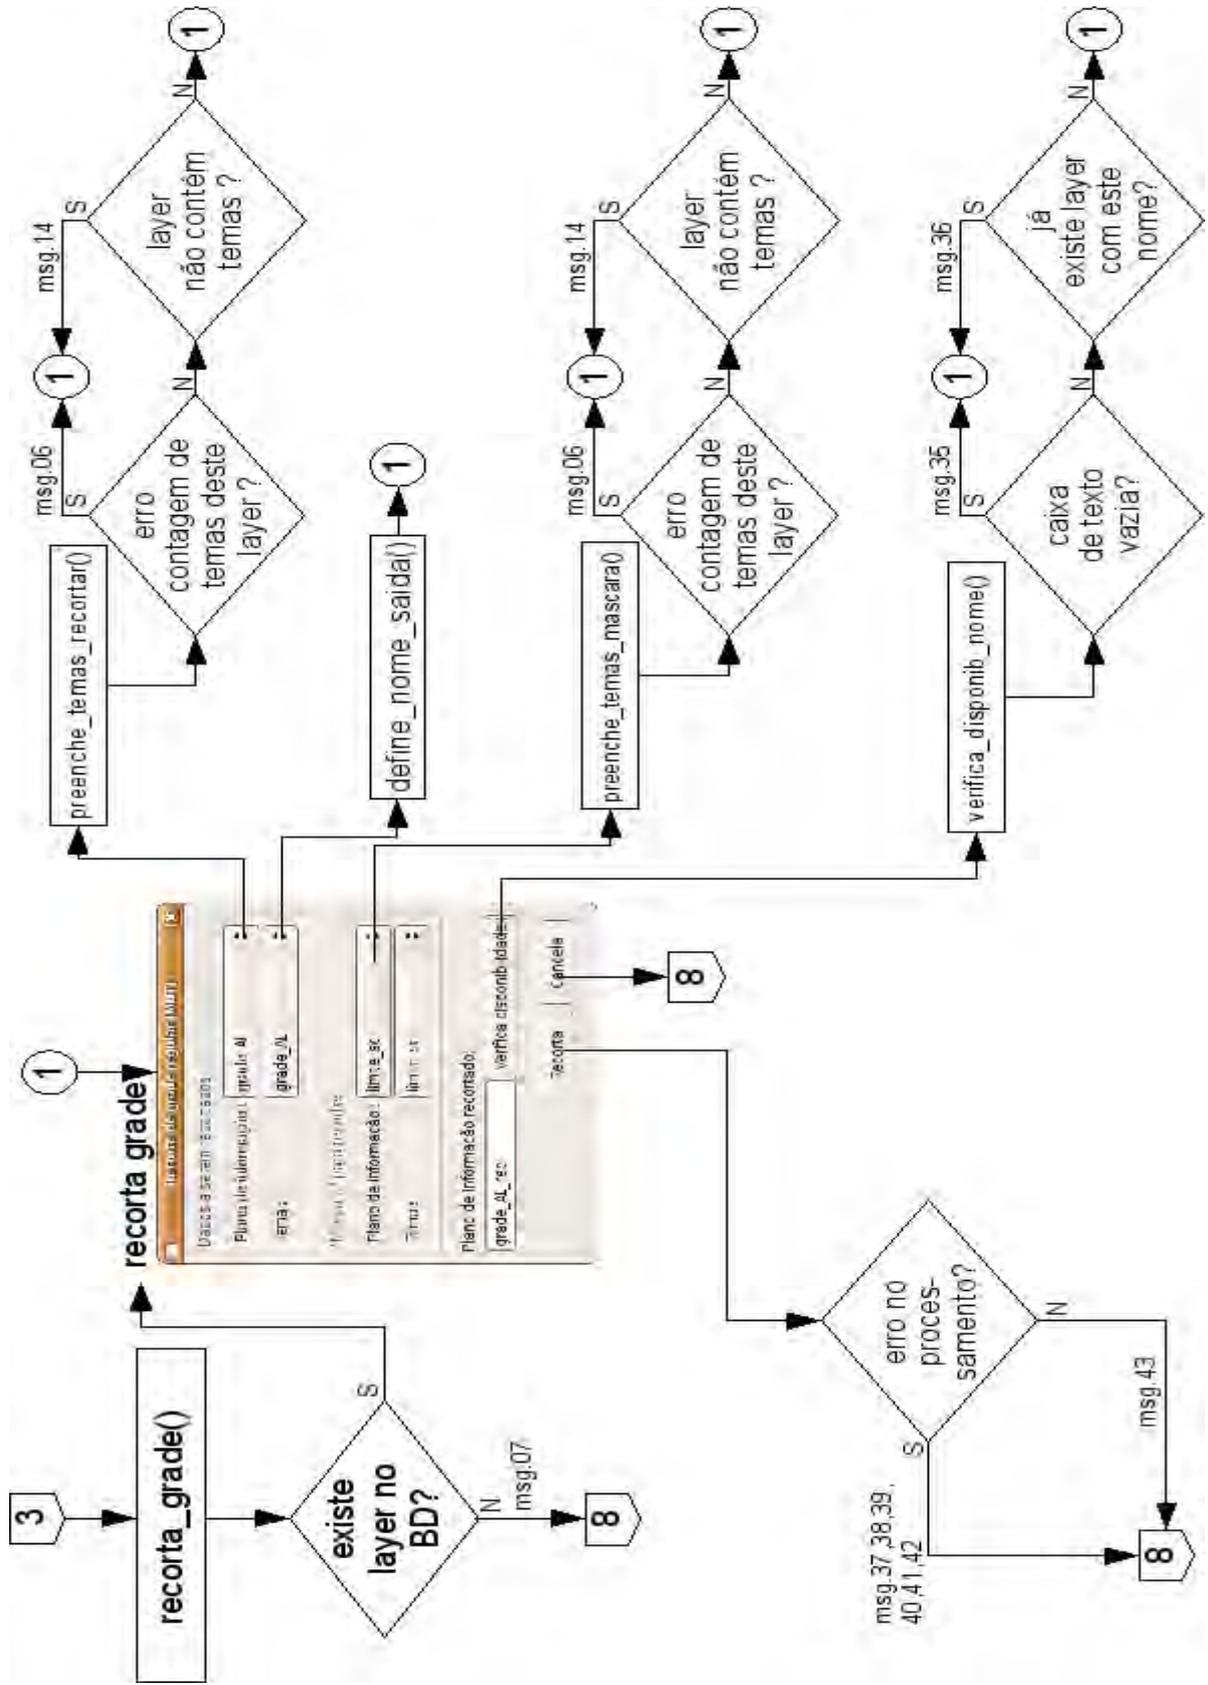
Lembramos ainda que a versão mais atual de toda a documentação encontra-se disponível na Internet no endereço:

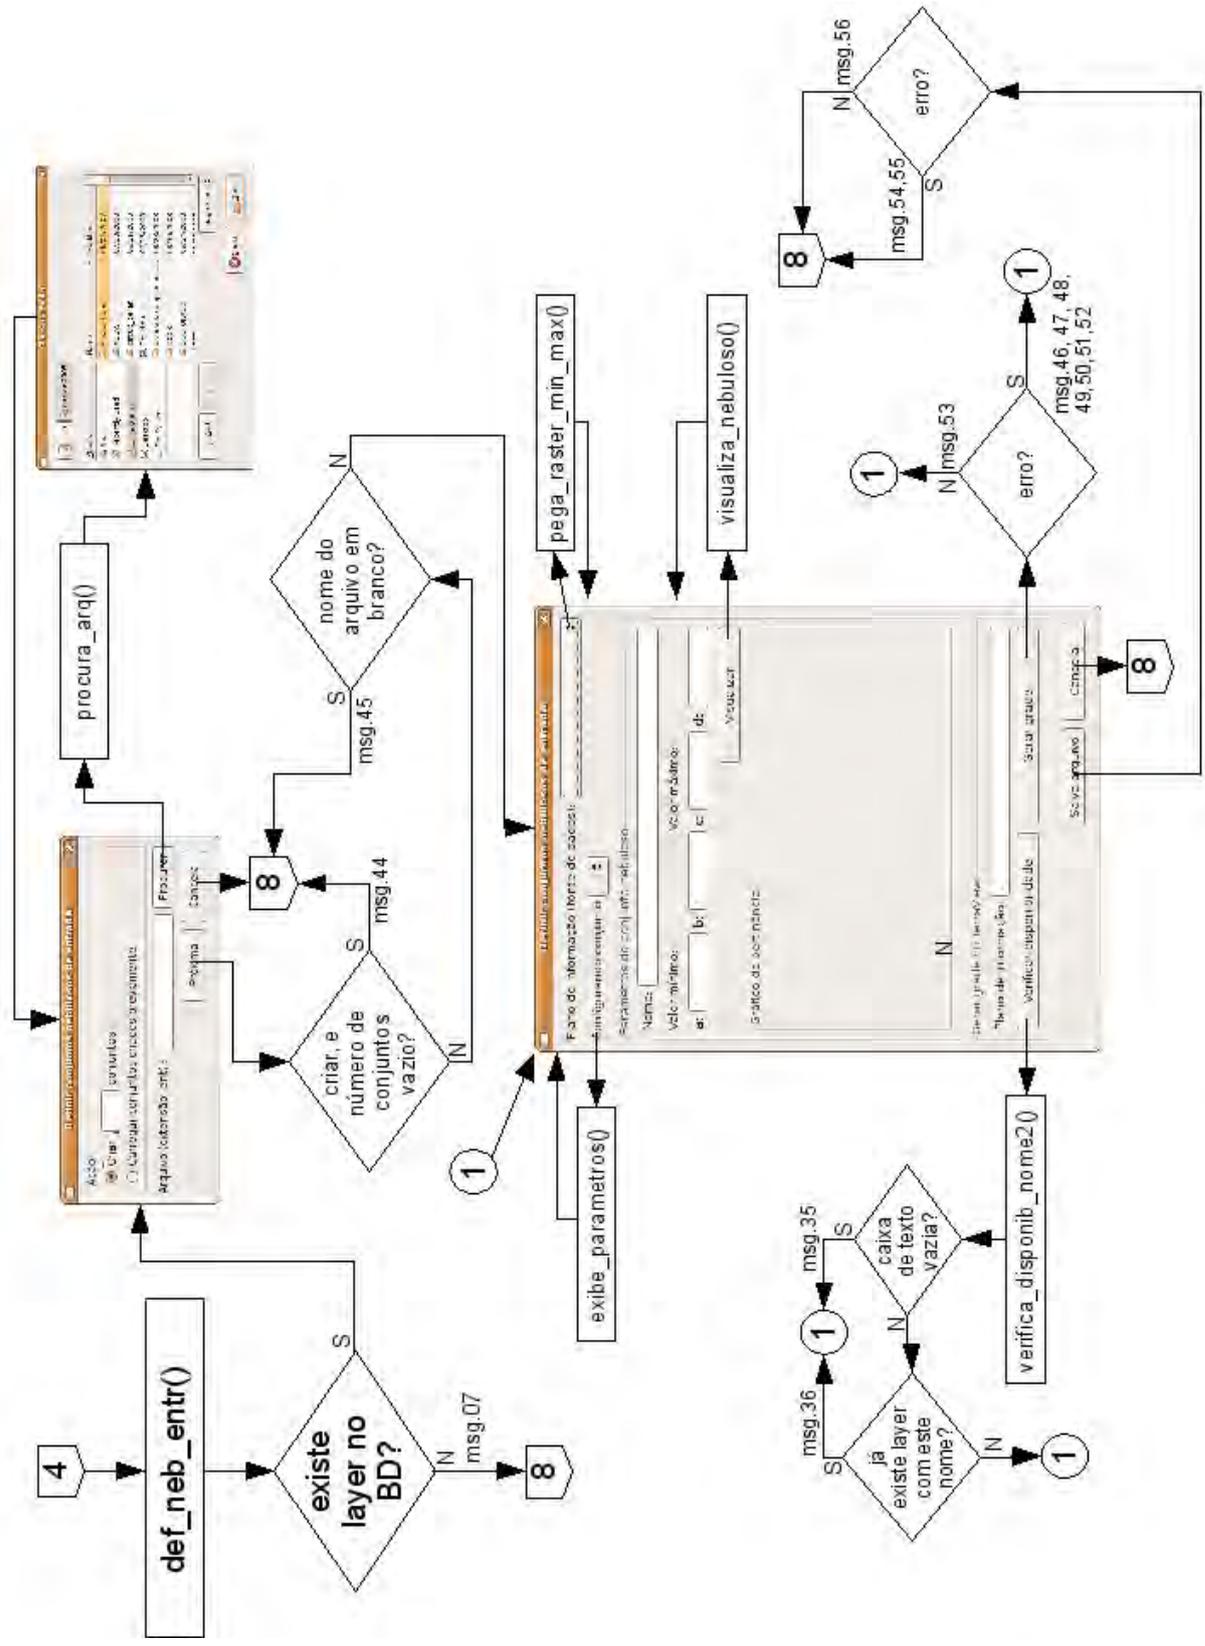
<http://starfightercarlao.blogspot.com/2008/08/doutorado-geoprocessamento-e-computao.html>

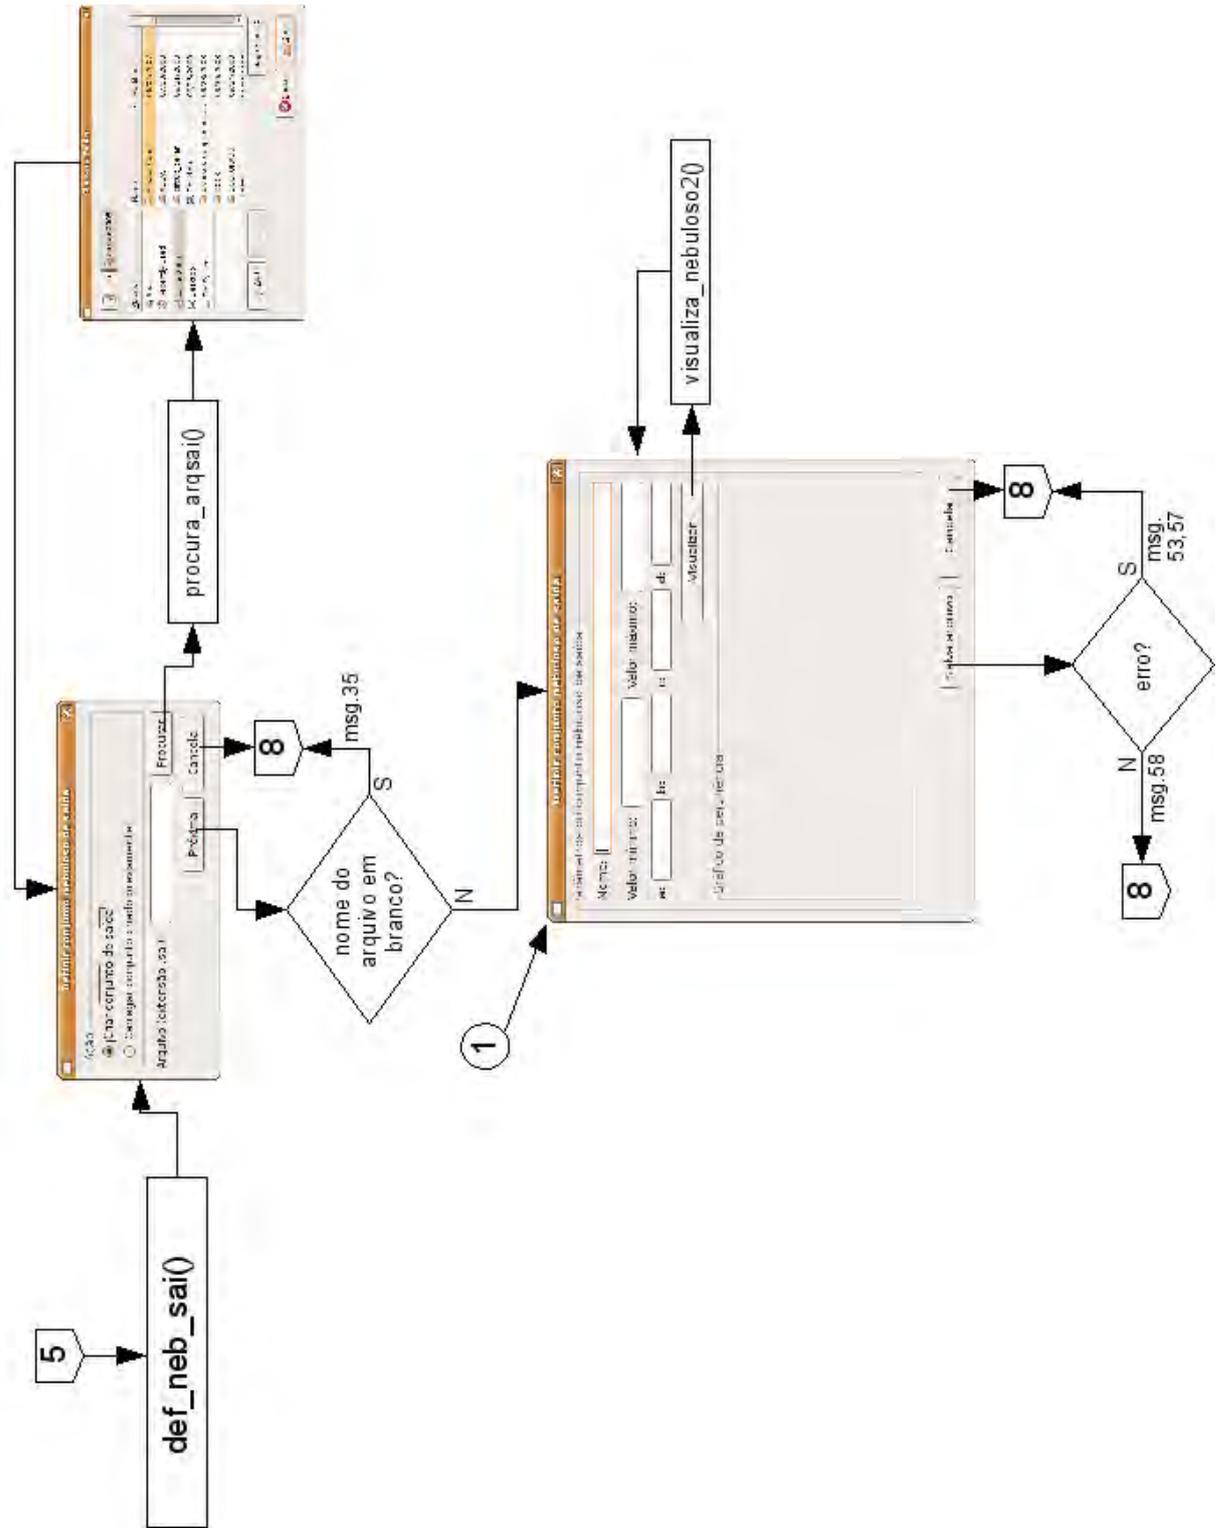
A.1. Fluxograma



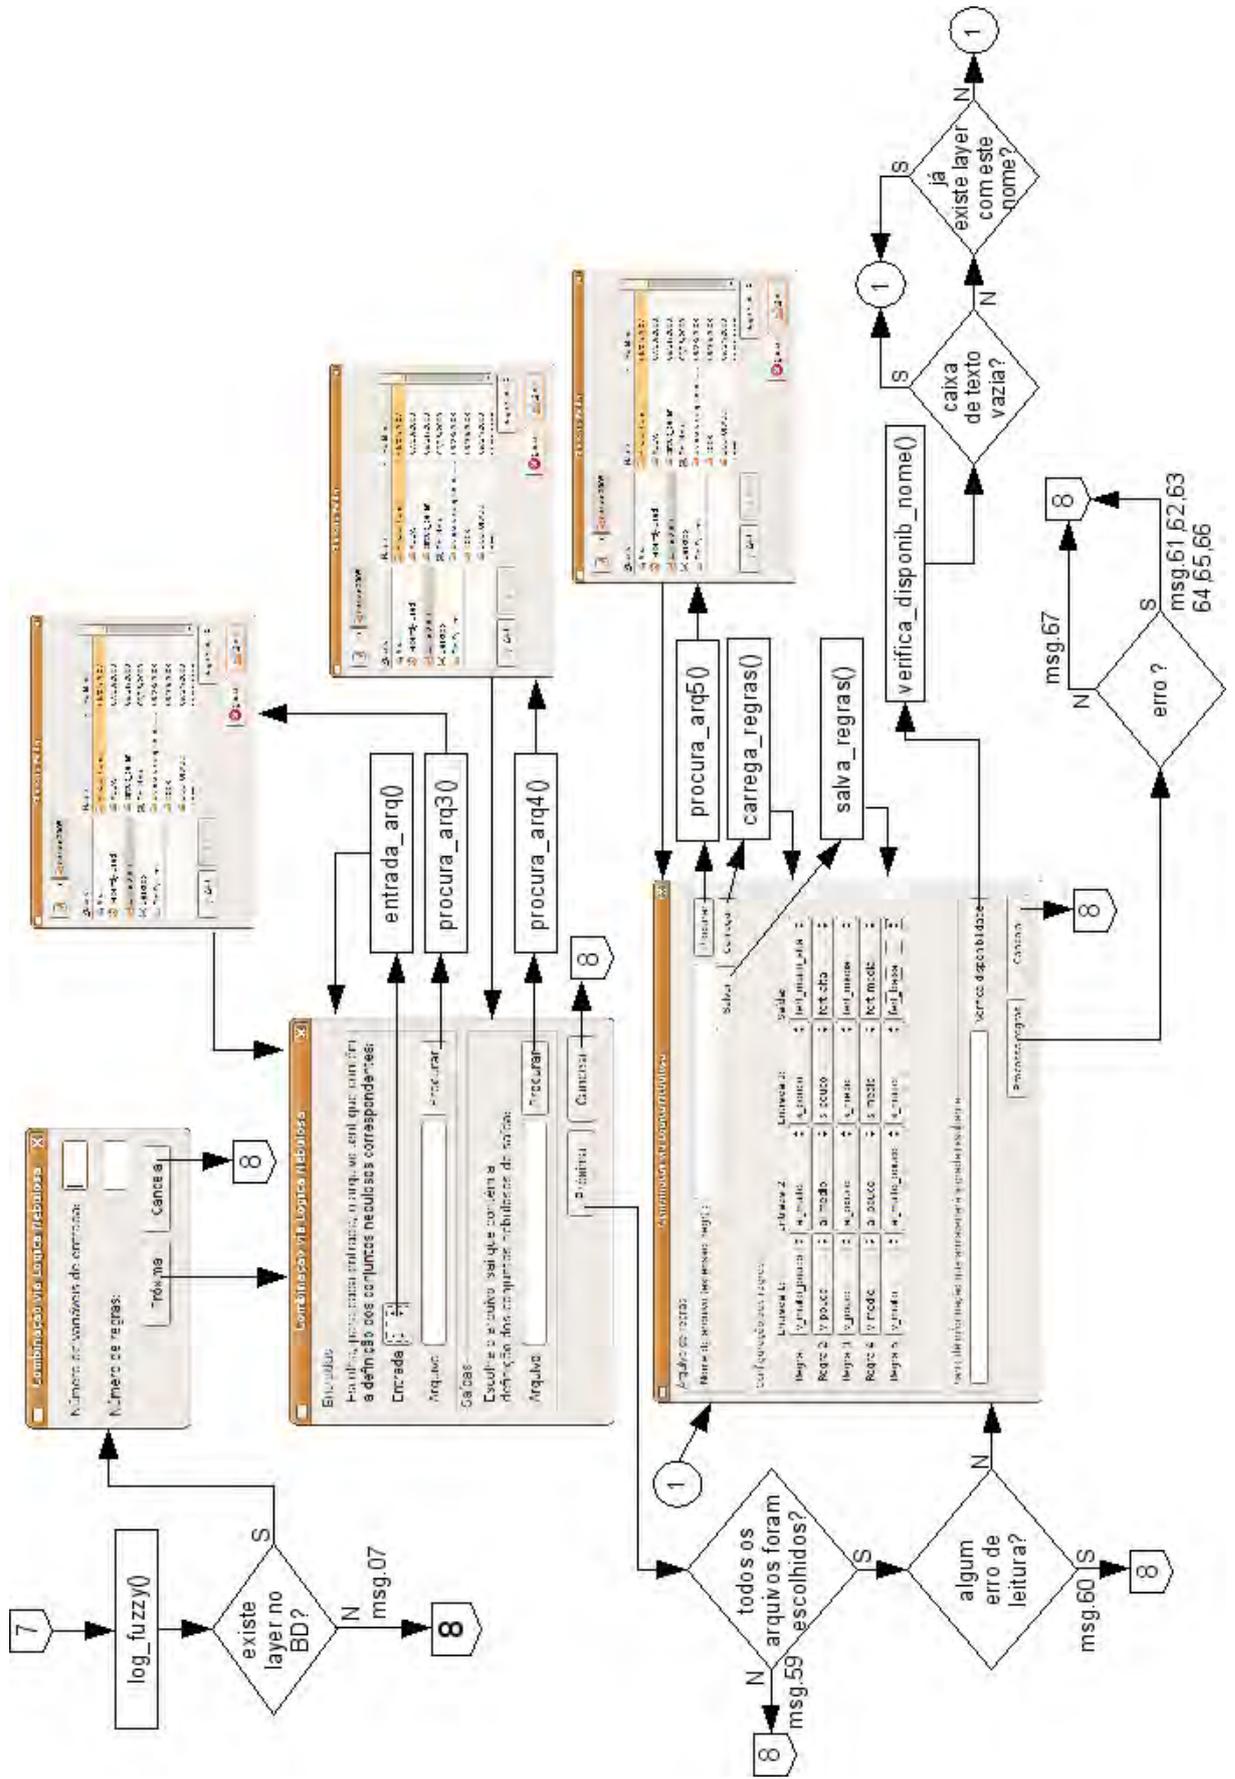


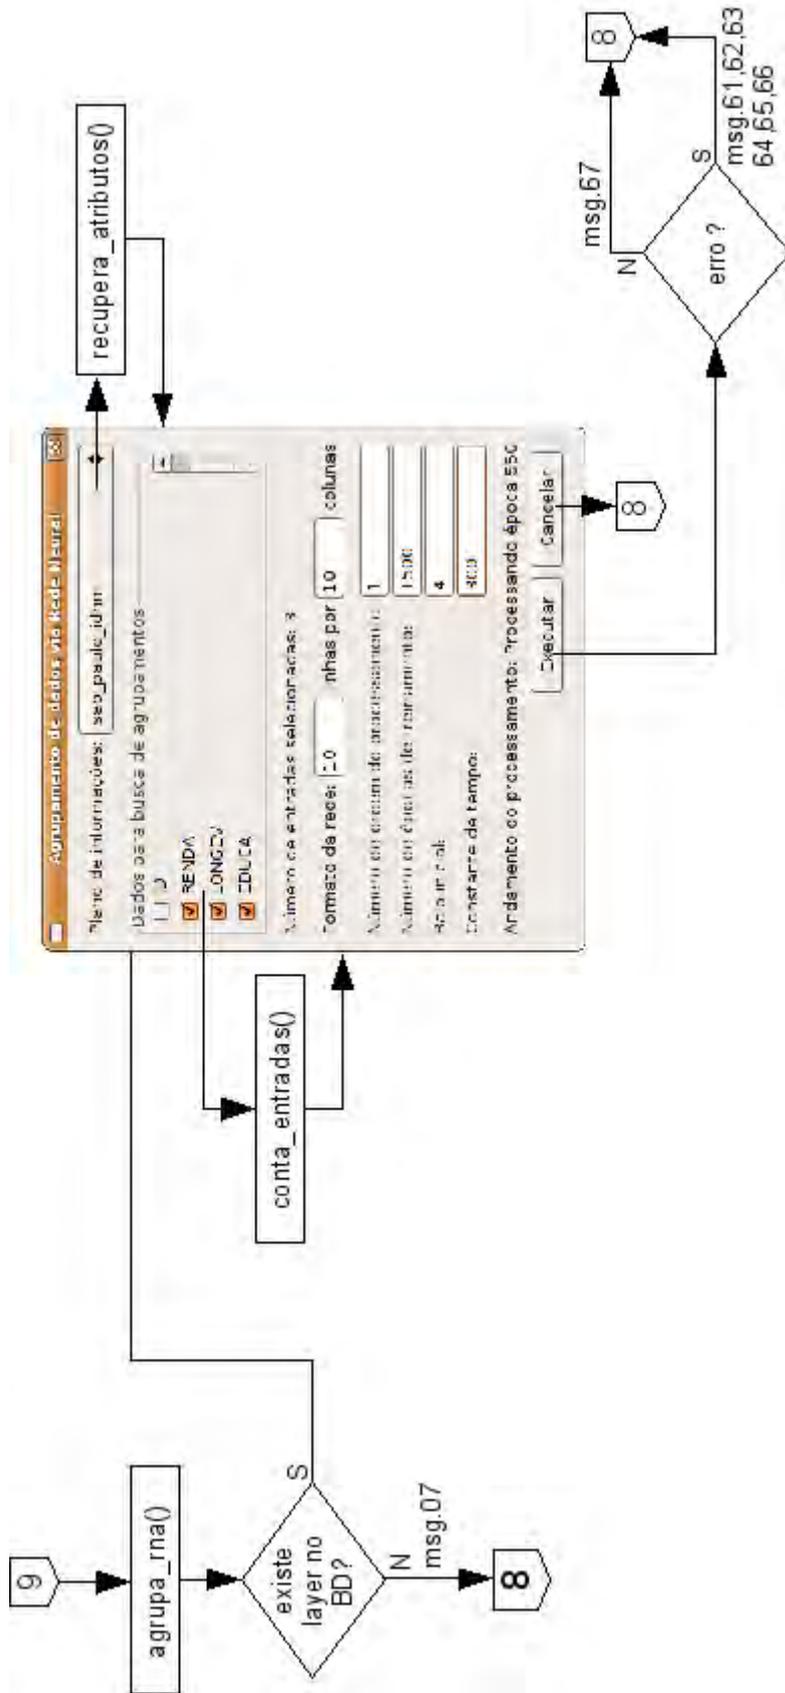












## A.2. Mensagens

### msg.01

*Erro ao tentar acessar o servidor.  
... mensagem de erro informada pela TerraLib ...*

### msg.02

*Erro ao tentar conectar com o banco de dados.  
... mensagem de erro informada pela TerraLib ...*

### msg.03

*Conexão com o TerraView feita com sucesso!!*

### msg.04

*TerraView desconectado com sucesso!*

### msg.05

*Erro interno irrecoverável!!  
Não foi possível criar portal de consulta!  
(função quantos\_layers)*

### msg.06

*Erro interno irrecoverável!!  
(função quantos\_layers)  
... mensagem de erro informada pela TerraLib ...*

### msg.07

*\* ERRO \*  
Não existem planos de informação no banco de dados conectado!*

### msg.08

*Erro interno irrecoverável!!  
Não foi possível criar portal de consulta!(função nomes\_layers)*

### msg.14

*\* ERRO \*  
Não existem temas no plano de informação escolhido!*

### msg.19

*\* ERRO \*  
Não existem tabelas no plano de informação escolhido!*

### msg.22

*\* ERRO \*  
Não foi possível recuperar a lista de atributos desta tabela*

**msg.23**

*\* ERRO \**  
*Não existem atributos na tabela escolhida!*

**msg.26**

*\* ERRO \**  
*O atributo escolhido não é numérico!*

**msg.27**

*\* ERRO \**  
*Não foi possível carregar o layer do BD para a memória*  
*(função gera\_grade\_regular)*  
*... mensagem de erro informada pela TerraLib ...*

**msg.28**

*\* ERRO \**  
*Não foi possível carregar o tema do BD para a memória*  
*(função gera\_grade\_regular)*  
*... mensagem de erro informada pela TerraLib ...*

**msg.29**

*\* ERRO \**  
*Não foi possível carregar o layer (dimensões) do BD para a memória*  
*(função gera\_grade\_regular)*  
*... mensagem de erro informada pela TerraLib ...*

**msg.30**

*\* ERRO \**  
*Não foi possível criar o layer raster na memória!*  
*(função gera\_grade\_regular)*  
*... mensagem de erro informada pela TerraLib ...*

**msg.31**

*\* ERRO \**  
*O nome que você escolheu para o plano de informações que irá armazenar*  
*a grade (MNT) resultante já existe no Banco de Dados.*  
*Reinicie o processo e escolha outro nome.*

**msg.32**

*\* ERRO \**  
*Não foi possível criar o plano de informações de saída*  
*(função gera\_grade\_regular)*  
*... mensagem de erro informada pela TerraLib ...*

**msg.33**

*\* ERRO \**  
*Não foi possível gravar o resultado no banco de dados*

**msg.34**

*Grade regular (MNT) criada com sucesso!*

**msg.35**

*É preciso digitar um nome para verificação de disponibilidade!*

**msg.36**

*\* ERRO \**

*O nome que você escolheu para o plano de informações que será gerado como resultado do processo já existe no Banco de Dados.*

**msg.37**

*\* ERRO \**

*Não foi possível carregar o layer do BD para a memória (função recorta\_grade)  
... mensagem de erro informada pela TerraLib ...*

**msg.38**

*\* ERRO \**

*Não foi possível carregar o tema do BD para a memória (função recorta\_grade)  
... mensagem de erro informada pela TerraLib ...*

**msg.39**

*\* ERRO \**

*Não foi possível carregar o layer-máscara do BD para a memória (função recorta\_grade)  
... mensagem de erro informada pela TerraLib ...*

**msg.40**

*\* ERRO \**

*Não foi possível carregar o tema-mascara do BD para a memória (função recorta\_grade)  
... mensagem de erro informada pela TerraLib ...*

**msg.41**

*\* ERRO \**

*Não foi possível criar o plano de informações recortado (função recorta\_grade)  
... mensagem de erro informada pela TerraLib ...*

**msg.42**

*\* ERRO \**

*Não foi possível recortar a grade!*

**msg.43**

*Grade recortada com sucesso!*

**msg.44**

*Necessário definir o número de conjuntos a serem criados!*

**msg.45**

*É necessário digitar um nome de arquivo!*

**msg.46**

*\* ERRO \**

*Não foi possível acessar o plano de informações selecionado!*

**msg.47**

*\* ERRO \**

*O plano de informações selecionado não contém uma grade regular (MNT)!*

**msg.48**

*\* ERRO \**

*Não foi possível criar a grade que vai receber o conjunto nebuloso na memória!*

**msg.49**

*\* ERRO \**

*Todos os parâmetros (a, b, c, d) devem estar preenchidos!*

**msg.50**

*\* ERRO \**

*O nome que você escolheu para o plano de informações que será gerado como resultado do processo já existe no Banco de Dados.*

**msg.51**

*\* ERRO \**

*Não foi possível criar o plano de informações de saída.  
... mensagem de erro informada pela TerraLib ...*

**msg.52**

*\* ERRO \**

*Não foi possível gravar o resultado no banco de dados*

**msg.53**

*Grade nebulosa criada com sucesso!*

**msg.54**

*\* ERRO \**

*Não foi possível criar/alterar o arquivo.*

**msg.55**

*\* ERRO \*  
Um conjunto nebuloso não foi configurado!*

**msg.56**

*Definição dos conjuntos nebulosos de entrada gravada com sucesso!*

**msg.57**

*\* ERRO \*  
Está faltando algum dos parâmetros necessários*

**msg.58**

*Definição do conjunto nebuloso de saída gravada com sucesso!*

**msg.59**

*\* ERRO \*  
Você deixou de definir algum arquivo!*

**msg.60**

*\* ERRO \*  
Erro irrecoverável em algum dos arquivos escolhidos!*

**msg.61**

*\* ERRO \*  
Não foi possível acessar um dos planos de informações selecionado!*

**msg.62**

*\* ERRO \*  
O plano de informações selecionado não contém uma grade regular (MNT)!*

**msg.63**

*\* ERRO \*  
Não foi possível criar a grade que vai receber o resultado do processamento na memória!*

**msg.64**

*\* ERRO \*  
O nome que você escolheu para o plano de informações que será gerado como resultado do processo já existe no Banco de Dados.*

**msg.65**

*\* ERRO \*  
Não foi possível criar o plano de informações de saída  
... mensagem de erro informada pela TerraLib ...*

**msg.66**

*\* ERRO \**

*Não foi possível gravar o resultado no banco de dados*

**msg.67**

*Processamento clássico realizado com sucesso!*

### A.3. Descrição das telas e seus objetos gráficos.

#### TELA DE ABERTURA



Tela de entrada do programa. Apresenta no canto superior direito a versão atual no formato <ano>.<mês de lançamento>

Objetos gráficos:

- botão “OK”: fecha a tela de abertura e prossegue a execução (janela principal).

## JANELA PRINCIPAL



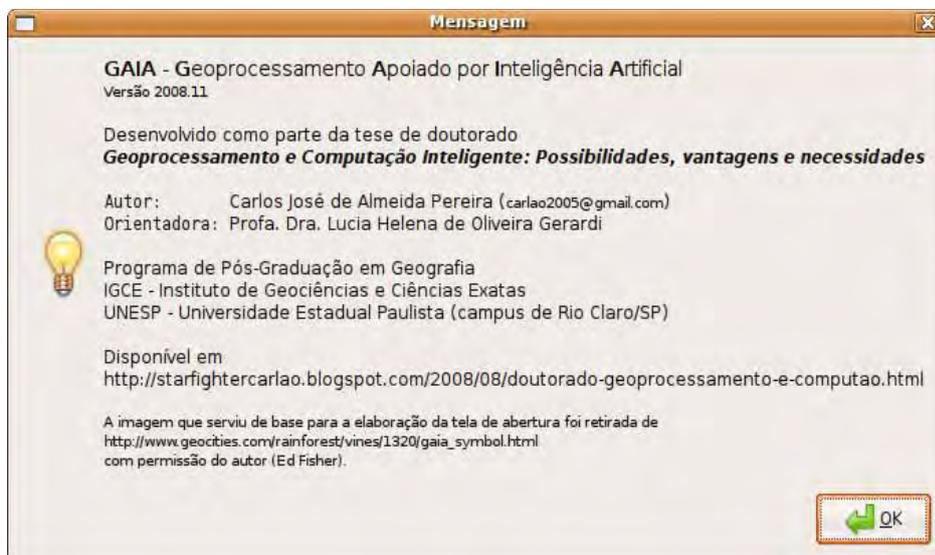
Menu principal do sistema. Apresenta ao usuário o estado atual da conexão com o banco de dados do TerraView.

Arquivo: janela\_principal.glade

Objetos gráficos:

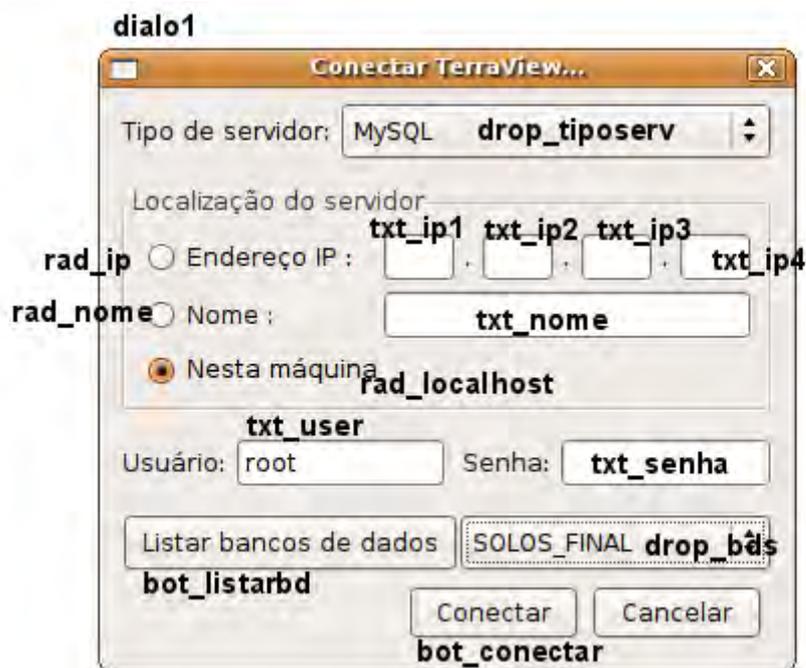
- lbl\_status\_conexao: exibe “\* CONEXÃO NÃO ESTABELECIDADA \*” em vermelho ou “\* CONEXÃO ESTABELECIDADA \*” em azul, conforme o estado da conexão do GAIA com o banco de dados;
- lbl\_servidor: exibe o nome ou o endereço IP do servidor de banco de dados conectado. Ou exibe “localhost”, caso o servidor esteja na própria máquina;
- lbl\_tiposervidor: exibe o tipo de servidor de banco de dados utilizado. Na versão atual, só trabalha com o servidor MySQL;
- lbl\_bd: exibe o nome do banco de dados com o qual foi feita a conexão;

- bot\_sair: finaliza a execução do programa;
- bot\_sobre: exhibe algumas informações relativas à autoria do programa e à tese de doutorado ao qual ele está vinculado;



- bot\_conecta: vai para tela CONECTAR TERRAVIEW;
- bot\_desconecta: desfaz a conexão com o servidor de banco de dados;
- bot\_geragrad: vai para a tela CRIA GRADE;
- bot\_recortgrade: vai para a tela RECORTA GRADE;
- bot\_defent: vai para a tela DEFINE CONJUNTOS DE ENTRADA;
- bot\_defsai: vai para a tela DEFINE CONJUNTO DE SAÍDA;
- bot\_logtrad: vai para a tela LÓGICA TRADICIONAL;
- bot\_logfuzzy: vai para a tela LÓGICA NEBULOSA;
- bot\_rna: vai para a tela AGRUPAMENTO VIA RNA;

## CONECTAR TERRAVIEW



Recebe do usuário os dados necessários (tipo de servidor, endereço ou nome do servidor na rede, nome do usuário, senha e nome do banco de dados) para a conexão do GAIA com o banco de dados usado pelo TerraView.

Arquivo: dlg1\_conecta.glade

Objetos gráficos:

- drop\_tiposerv: permite a escolha do tipo de servidor que vai ser conectado. Na versão atual, apenas MySQL. Nas próximas versões, poderá escolher PostgreSQL e Oracle.
- rad\_ip: indica que o usuário vai informar o endereço IP do servidor a ser conectado;
- txt\_ip1, txt\_ip2, txt\_ip3, txt\_ip4: componentes do endereço IP do servidor a ser conectado;
- rad\_nome: indica que o usuário vai informar o nome de rede do servidor a ser conectado
- txt\_nome: nome de rede do servidor a ser conectado;
- rad\_localhost: indica que o servidor a ser conectado está localizado na própria máquina onde o GAIA está sendo executado (localhost);
- txt\_user: nome de usuário para conexão ao banco de dados;

- txt\_senha: senha do usuário definido em txt\_user, para conexão ao banco de dados;
- bot\_listarbd: utiliza os dados relativos ao nome e endereço do servidor, mais o nome do usuário e sua senha, para recuperar a lista de bancos de dados disponíveis e preencher drop\_bds;
- drop\_bds: permite escolha de um dos bancos de dados disponíveis no servidor escolhido pelo usuário;
- bot\_conectar: realiza a conexão do GAIA com o banco de dados escolhido;
- botão “cancelar”: fecha esta janela, voltando para a janela principal.

## CRIA GRADE



Recebe as informações necessárias para gerar um plano de informação (layer) do tipo grade regular (MNT).

Arquivo: criagrade.glade

Objetos gráficos:

- `drop_layer_in`: exibe os planos de informação existentes no BD conectado, para que o usuário escolha qual tem os dados que irão gerar a grade regular;
- `drop_tema_in`: exibe os temas do layer escolhido, para escolha pelo usuário;
- `drop_tabela_in`: exibe as tabelas existentes no layer escolhido, para escolha pelo usuário;
- `drop_coluna_in`: exibe os campos (atributos) da tabela escolhida, para que o usuário escolha qual campo vai ser a fonte de dados do processo de geração da grade regular, via interpolação;

- `txt_layer_out`: nome do layer que será gerado para armazenar a grade regular resultante;
- `radio_dim_mesmo`: indica que as dimensões do layer a ser criado serão as mesmas do layer de entrada (origem dos dados);
- `radio_dim_outro`: indica que as dimensões do layer a ser criado serão as mesmas do layer que será escolhido pelo usuário em `drop_dim_outrolayer`;
- `drop_dim_outrolayer`: exibe os layers existentes no banco de dados conectado, para que o usuário escolha;
- `bot_cancelar`: cancela o processo, retornando para a janela principal;
- `bot_cria`: cria o plano de informação (layer) cujo nome está indicado em `txt_layer_out`, armazenando o resultado da interpolação executada nos dados do atributo indicado em `drop_coluna_in`.

## RECORTA GRADE



Recorta uma grade regular utilizando outro plano de informações (layer) como máscara (por exemplo, os limites de um estado).

Arquivo: recortagrade.glade

Objetos gráficos:

- drop\_layer\_in: exibe os planos de informação existentes no banco de dados para escolha pelo usuário daquele que contém os dados (grade regular) a serem recortados;
- drop\_tema\_in: exibe os temas existentes no layer escolhido em drop\_layer\_in;
- drop\_layer\_mask: exibe os planos de informação existentes no banco de dados para escolha pelo usuário daquele que contém a máscara (formato) do recorte;
- drop\_tema\_mask: exibe os temas existentes no layer escolhido em drop\_layer\_mask;
- txt\_layer\_out: nome do layer que será gerado para armazenar a grade com o resultado do recorte;
- bot\_berifica: verifica se já existe, no banco de dados, algum layer com o nome que está em txt\_layer\_out;

- `bot_recorta`: cria o layer cujo nome está em `txt_layer_out`, e nele armazena o resultado do recorte realizado nos dados da grade contida no layer em `drop_layer_in`, usando para esse recorte a máscara contida no layer em `drop_layer_mask`;
- `bot_cancelar`: cancela o processo, retornando para a janela principal.

## DEFINE CONJUNTOS DE ENTRADA



Primeiro passo na criação dos conjuntos nebulosos que servirão de entrada do sistema de raciocínio nebuloso. Permite criar novos conjuntos, informando quantos conjuntos serão criados, ou carregar um arquivo de conjuntos de entrada (extensão .ent) previamente criado. Em ambos os caso é necessário informar um nome de arquivo, seja para carregar ou gravar os conjuntos.

Arquivo: gera\_neb\_entr1.glade

Objetos gráficos:

- rad\_criar: indica que o usuário quer criar um novo arquivo;
- txt\_numconj: indica o número de conjuntos nebulosos que serão criados;
- rad\_carregar: indica que o usuário quer carregar um arquivo de conjuntos nebuloso criado previamente;
- txt\_arquivo: nome do arquivo que contém ou conterá os conjuntos nebulosos;
- bot\_procura: abre um navegador de arquivos, para que o usuário possa escolher qual arquivo ele quer carregar;
- bot\_cancela1: cancela o processo, retornando para a janela principal;
- bot\_proxima: fecha esta janela e vai para o próximo passo na criação/edição do arquivo de conjuntos nebulosos.



Permite a definição de vários conjuntos nebulosos relativos aos dados localizados em um plano de informação. Permite a geração de grades regulares com cada definição de conjunto nebuloso.

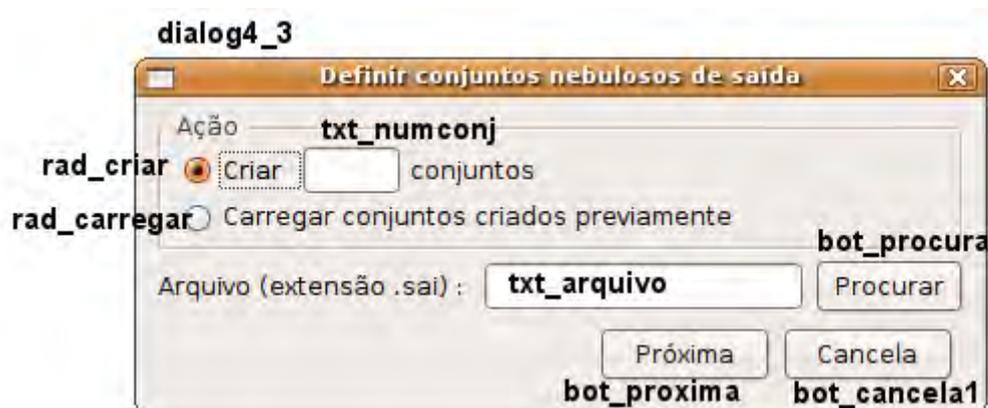
Arquivo: gera\_neb\_entr2.glade

Objetos gráficos:

- drop\_layer\_in: lista os planos de informação disponíveis no banco de dados conectado, para escolha do usuário;

- drop\_conjunto: alterna entre as várias definições de conjuntos nebulosos relativos a este plano de informação;
- txt\_nome\_conj: nome do conjunto nebuloso;
- lbl\_min: exibe o menor valor da grade contida no plano de informações escolhido;
- lbl\_max: exibe o maior valor da grade contida no plano de informações escolhido;
- txt\_a, txt\_b, txt\_c, txt\_d: para digitar os parâmetros dos conjuntos nebulosos;
- bot\_visualiza: desenha na drawingarea o gráfico de pertinência do conjunto nebuloso definido pelos parâmetros em txt\_a, txt\_b, txt\_c e txt\_d;
- drawingarea: área de desenho, mostra o gráfico de pertinência de um conjunto nebuloso;
- txt\_layer\_out: recebe o nome do plano de informação onde será gerada a grade contendo a saída de cada conjunto nebuloso;
- bot\_verifica: verifica se já existe algum layer com o mesmo que está em txt\_layer\_out;
- bot\_geragrade: cria o plano de informações com a grade que representa o conjunto nebuloso;
- bot\_salva: salva as definições dos conjuntos nebulosos no arquivo;
- rad\_cancela2: cancela a operação e retorna para a janela principal.

## DEFINE CONJUNTO DE SAÍDA



Primeiro passo na criação dos conjuntos nebulosos que servirão de saída do sistema de raciocínio nebuloso. Permite criar novos conjuntos, informando quantos conjuntos serão criados, ou carregar um arquivo de conjuntos de saída (extensão .sai) previamente criado. Em ambos os casos é necessário informar um nome de arquivo, seja para carregar ou gravar os conjuntos.

Arquivo: gera\_neb\_sai1.glade

Objetos gráficos:

- rad\_criar: indica que o usuário quer criar um novo arquivo;
- txt\_numconj: indica o número de conjuntos nebulosos que serão criados;
- rad\_carregar: indica que o usuário quer carregar um arquivo de conjuntos nebuloso criado previamente;
- txt\_arquivo: nome do arquivo que contém ou conterá os conjuntos nebulosos;
- bot\_procura: abre um navegador de arquivos, para que o usuário possa escolher qual arquivo ele quer carregar;
- bot\_cancela1: cancela o processo, retornando para a janela principal;
- bot\_proxima: fecha esta janela e vai para o próximo passo na criação/edição do arquivo de conjuntos nebulosos.



Permite a definição de vários conjuntos nebulosos que serão utilizados como saída do sistema de raciocínio nebuloso, e a gravação desses conjuntos em um arquivo.

Arquivo: gera\_neb\_sai2.glade

Objetos gráficos:

- drop\_conjunto: alterna entre as várias definições de conjuntos nebulosos relativos a este plano de informação;
- txt\_nome\_conj: nome do conjunto nebuloso;
- txt\_min: definição do valor mínimo do conjunto;
- txt\_max: definição do valor máximo do conjunto;
- txt\_a, txt\_b, txt\_c, txt\_d: para digitar os parâmetros dos conjuntos nebulosos;

- bot\_visualiza: desenha na drawingarea o gráfico de pertinência do conjunto nebuloso definido pelos parâmetros em txt\_a, txt\_b, txt\_c e txt\_d;
- drawingarea: área de desenho, mostra o gráfico de pertinência de um conjunto nebuloso;
- bot\_salva: salva as definições dos conjuntos nebulosos no arquivo;
- rad\_cancela2: cancela a operação e retorna para a janela principal.

## LÓGICA TRADICIONAL

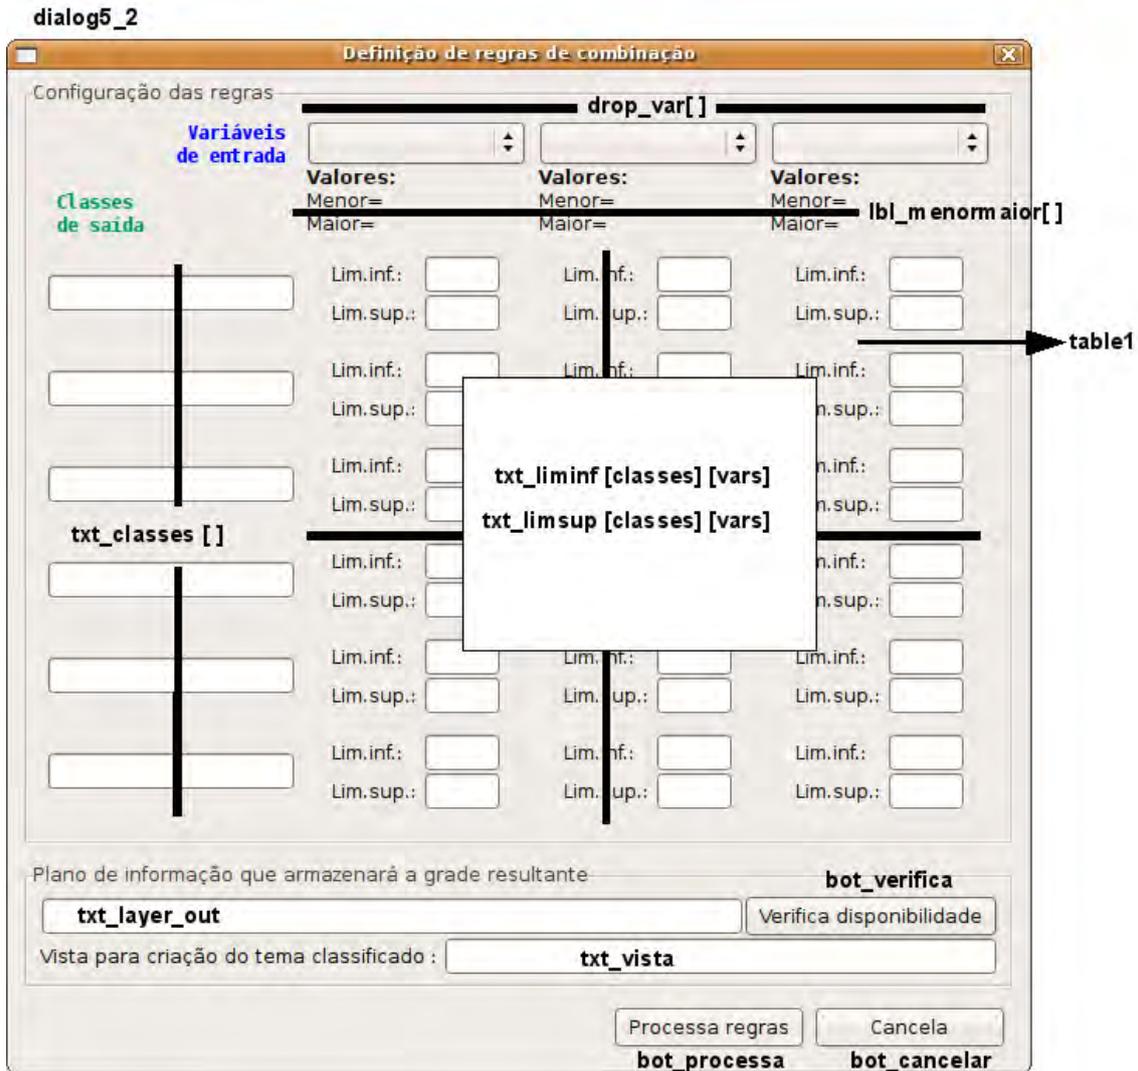


Primeiro passo para combinação via lógica tradicional. Recebe a quantidade de número de classes de saída e o número de variáveis de entrada.

Arquivo: combina\_classical.glade

Objetos gráficos:

- txt\_classes\_saida: recebe o número de classes de saída do processamento;
- txt\_vars\_entrada: recebe o número de variáveis de entrada



Segundo passo para combinação via lógica tradicional. Permite a escolha de cada plano de informação que servirá como entrada, a definição do texto que descreve a classe de saída, e as regras de combinação (valores inferiores e superiores).

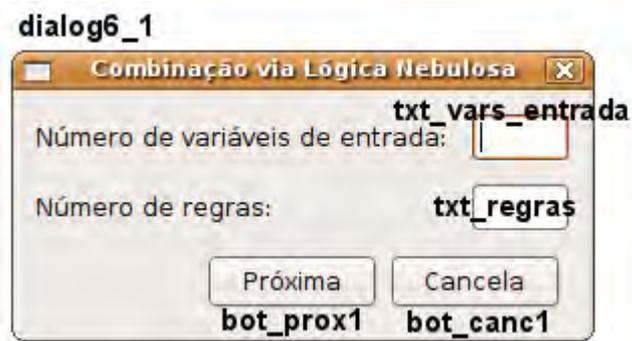
Arquivo: combina\_classica2.glade

Objetos gráficos:

- table1: tabela que organiza os elementos na tela. Seu conteúdo é montado dinamicamente a partir das respostas do usuário na tela anterior;
- drop\_var[] : vetor de drop-downs, cada um preenchido com os planos de informação existentes no banco de dados. Cada um corresponde a uma entrada;
- lbl\_menormaior[] : vetor de labels, que exibem os valores menor e maior quando o usuário escolhe um plano de informação;

- `txt_classes[]` : vetor de caixas de texto, com uma para cada classe de saída, permitindo que o usuário defina o nome da classe. Este nome será usado para construir um mapa temático no `TerraView` com o resultado do processamento;
- `txt_liminf [][]` : matriz de caixas de texto que recebem o patamar inferior das regras, relacionando cada entrada com cada classe de saída;
- `txt_limsup [][]` : matriz de caixas de texto que recebem o patamar superior das regras, relacionando cada entrada com cada classe de saída;
- `txt_layer_out`: recebe o nome do plano de informação onde será gerada a grade contendo o resultado do processamento;
- `bot_verifica`: verifica se já existe algum layer com o mesmo que está em `txt_layer_out`;
- `txt_vista`: recebe o nome da vista que será criada no `TerraView` com o mapa temático resultante do processamento;
- `bot_processa`: realiza o processamento, gerando o plano de informação definido em `txt_layer_out` e um tema com o mesmo nome na vista definida em `txt_vista`;
- `bot_cancelar`: cancela a operação, retornando para a janela principal.

## LÓGICA NEBULOSA

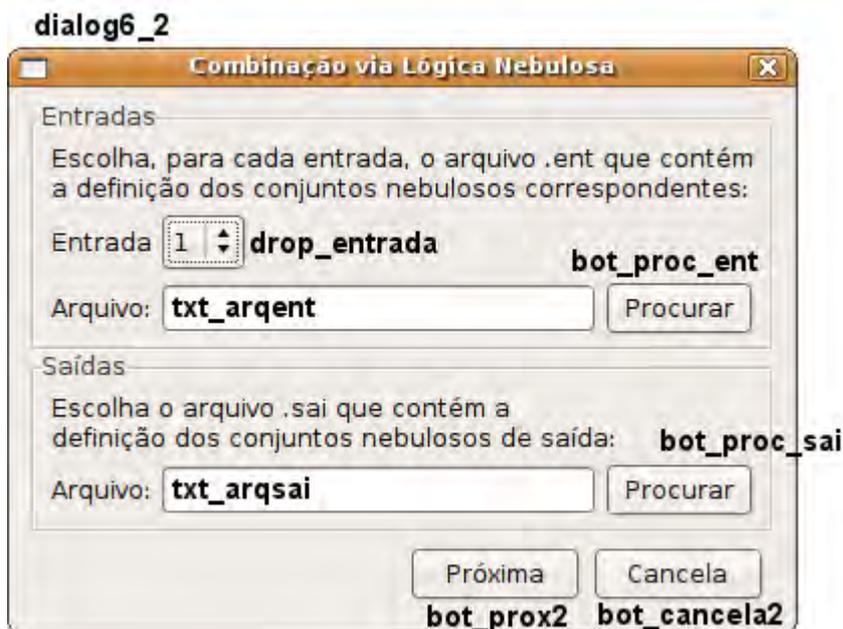


Primeiro passo para combinação via lógica nebulosa. Recebe a quantidade de variáveis de entrada e o número de regras de combinação.

Arquivo: sin\_1.glade

Objetos gráficos:

- txt\_vars\_entrada: recebe o número de variáveis de entrada;
- txt\_regras: recebe o número de regras de combinação;
- bot\_prox1: vai para o passo seguinte;
- bot\_canc1: cancela a operação, retornando para a janela principal.

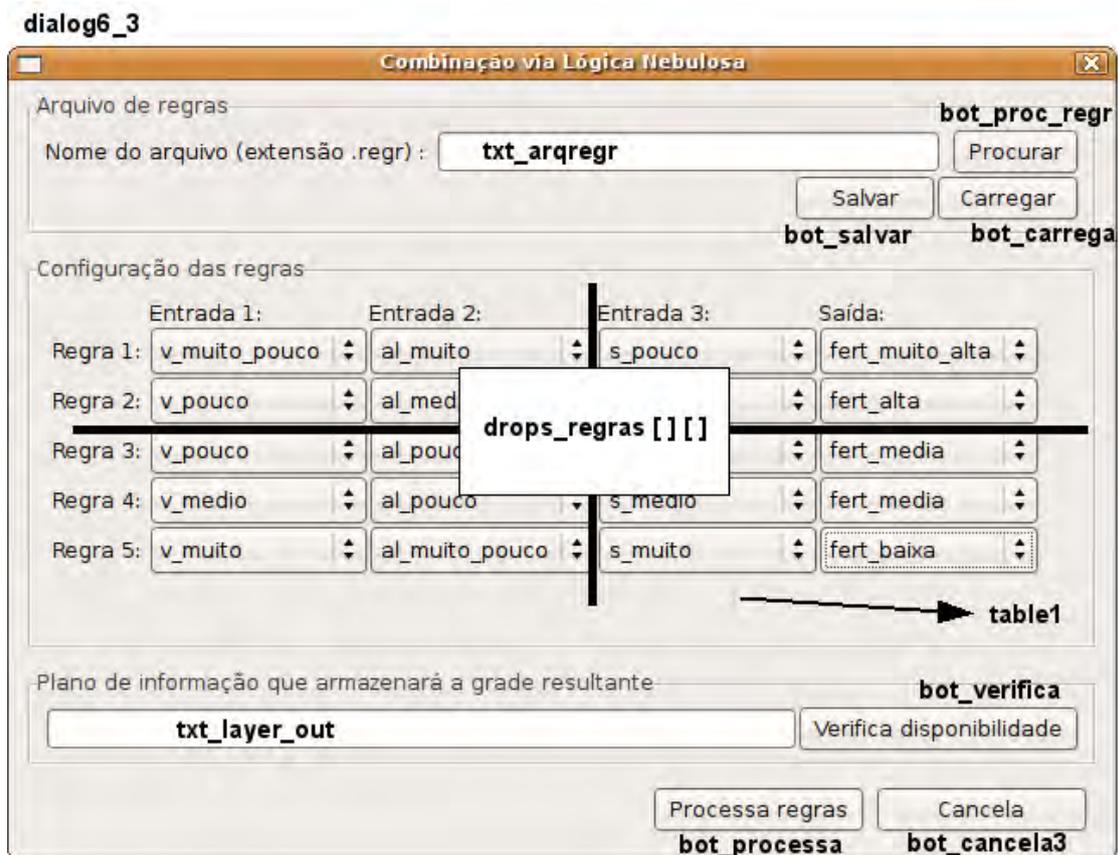


Segundo passo para combinao via lgica nebulosa. Permite a associao entre as entradas e os arquivos de definem os conjuntos nebulosos de entrada. Define tambm qual arquivo contm os conjuntos nebulosos de saıda.

Arquivo: sin\_2.glade

Objetos grficos:

- drop\_entrada: utilizado para alternar entre as definies dos arquivos com os conjuntos de entrada e o nmero da entrada;
- txt\_arqent: recebe o nome do arquivo que contm as definies dos conjuntos nebulosos que sero utilizados como entradas do processamento;
- bot\_proc\_ent: exibe um navegador de arquivos, para que o usurio possa procurar os arquivos que contm os conjuntos nebulosos de entrada;
- txt\_arqsai: recebe o nome do arquivo que contm as definies dos conjuntos nebulosos que sero utilizados como saıda do processamento;
- bot\_proc\_sai: exibe um navegador de arquivos, para que o usurio possa procurar o arquivo que contm os conjuntos nebulosos de saıda;
- bot\_prox1: vai para o passo seguinte;
- bot\_cancel1: cancela a operao, retornando para a janela principal.



Passo final para combinação via lógica nebulosa. Permite a montagem das regras de combinação. O usuário escolhe nos drop-downs os conjuntos nebulosos definidos nos arquivos escolhidos na tela anterior. Define o nome do plano de informação que será gerado com o resultado do processamento.

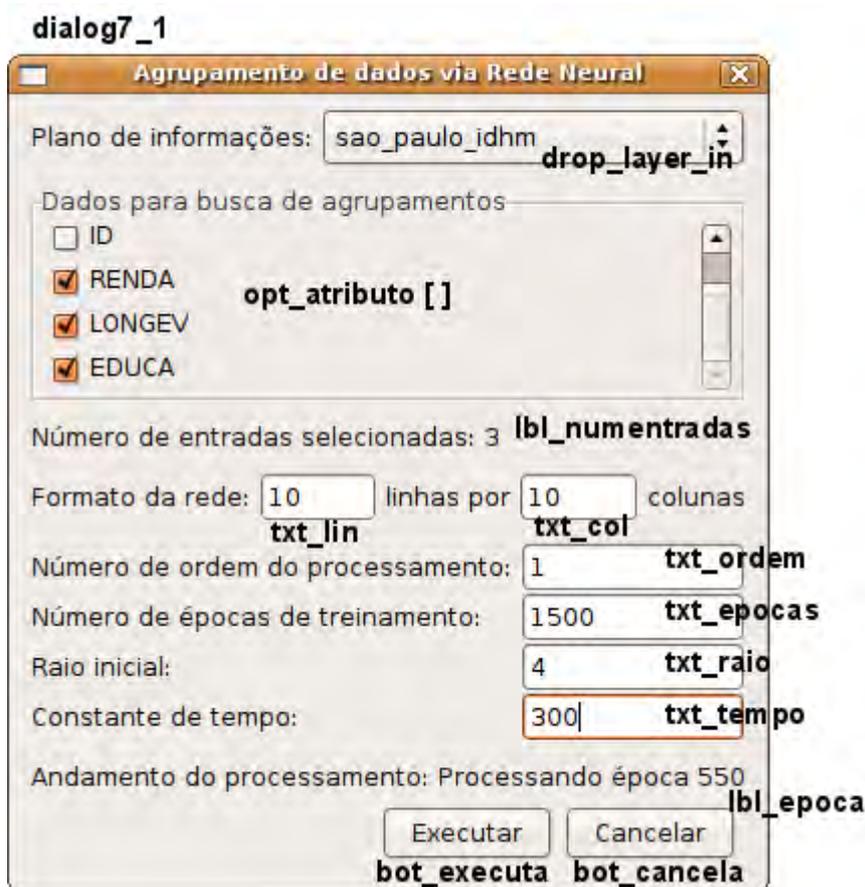
Arquivo: sin\_3.glade

Objetos gráficos:

- table1: tabela que organiza os elementos na tela. Seu conteúdo é montado dinamicamente a partir das respostas do usuário nas telas anteriores;
- txt\_arqregr: nome do arquivo para gravação das regras de combinação;
- bot\_proc\_regr: exibe um navegador de arquivos, para que o usuário possa procurar o arquivo que contém ou conterá as regras de combinação;
- bot\_salva: realiza a gravação das regras no arquivo definido em txt\_arqregr;
- bot\_carrega: carrega as regras do arquivo definido em txt\_arqregr;

- `drops_regras [][]` : matriz de drop-downs que recebem os conjuntos nebulosos definidos nos arquivos de entrada, para que o usuário monte as regras de combinação;
- `txt_layer_out`: recebe o nome do plano de informação onde será gerada a grade contendo o resultado do processamento;
- `bot_verifica`: verifica se já existe algum layer com o mesmo que está em `txt_layer_out`;
- `bot_processa`: realiza o processamento, gerando o plano de informação definido em `txt_layer_out`;
- `bot_cancela3`: cancela a operação, retornando para a janela principal.

## AGRUPAMENTO VIA RNA



Tela de configuração para treinamento da rede neural para agrupamento de dados.

Arquivo: rna\_1.glade

Objetos gráficos:

- drop\_layer\_in: para escolher o plano de informação que contém os dados de entrada para a rede neural;
- opt\_atributo [ ] : vetor de caixas de opção, para que o usuário escolha os campos que farão parte da entrada da rede neural;
- lbl\_numentradas: exibe o número de atributos escolhidos pelo usuário;
- txt\_lin, txt\_col: recebe a configuração de linhas e colunas da camada de neuronios da rede neural;
- txt\_ordem: número de ordem, para ser usado nos nomes dos campos que o GAIA vai gerar nas tabelas do banco de dados no TerraView;

- txt\_époacas: número de épocas de treinamento;
- txt\_raio: raio inicial do treinamento da rede neural;
- txt\_tempo: contante de tempo utilizada no treinamento da rede neural;
- lbl\_época: mostra o número da época durante o treinamento;
- bot\_executa: realiza o treinamento da rede e geração dos resultados no banco de dados;
- bot\_cancela: cancela a operação, retornando para a janela principal;

#### A.4. Passo-a-passo de utilização do GAIA para reprodução dos exemplos apresentados no texto

ATENÇÃO: PARA ACOMPANHAR ESTE PASSO-A-PASSO, É NECESSÁRIO TER CONHECIMENTO BÁSICO SOBRE A OPERAÇÃO DO TERRAVIEW. PARA ESTA FINALIDADE, RECOMENDAMOS ACOMPANHAR O TUTORIAL DISPONÍVEL NO PRÓPRIO SITE DO TERRAVIEW.

- executar o TerraView 3.20;
- criar o banco de dados “passo\_a\_passo”, utilizando o servidor de banco de dados MYSQL (o GAIA, nesta versão inicial, trabalha apenas com este tipo de servidor de banco de dados);

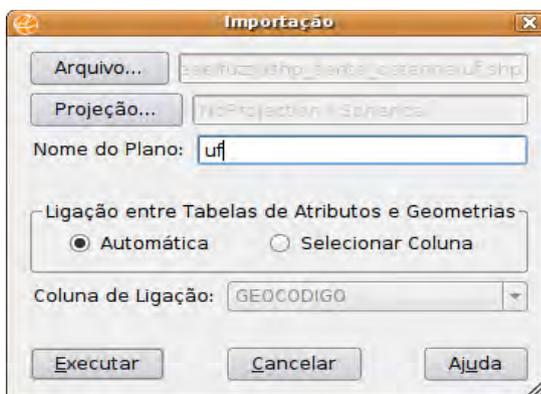


- executar o GAIA;
- conectar o GAIA ao banco de dados “passoapasso”;



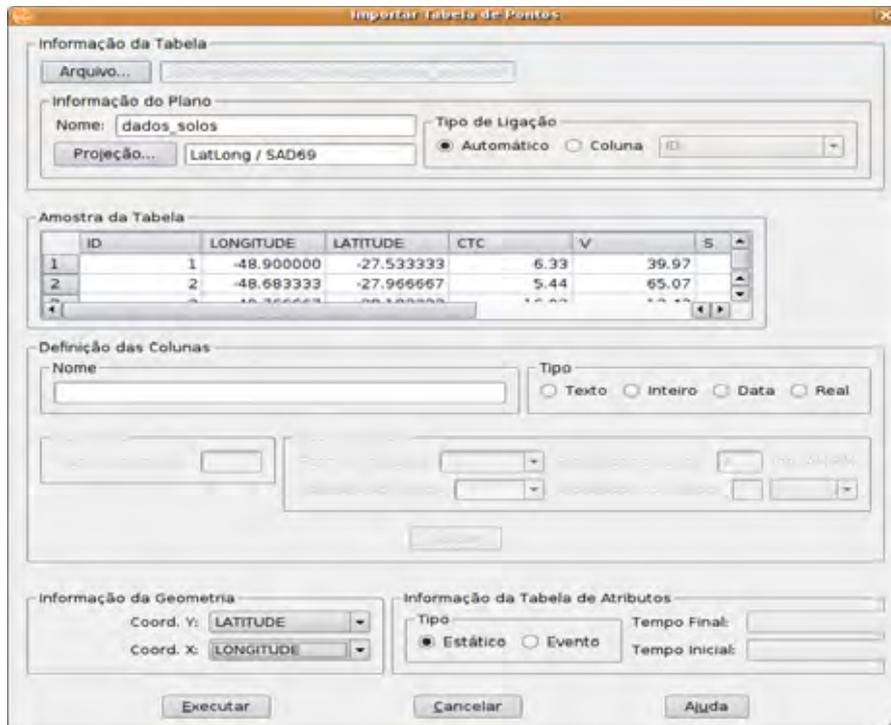
## MAPA DE SOLOS VIA LÓGICA NEBULOSA

- importar, no TerraView, o arquivo com o limite do estado de Santa Catarina (shapefile localizado no diretório “... /dados\_tese/fuzzy/shp\_santa\_catarina” (projeção latlong, elipsóide SAD69); Vai gerar o plano de informação (layer) “uf”;



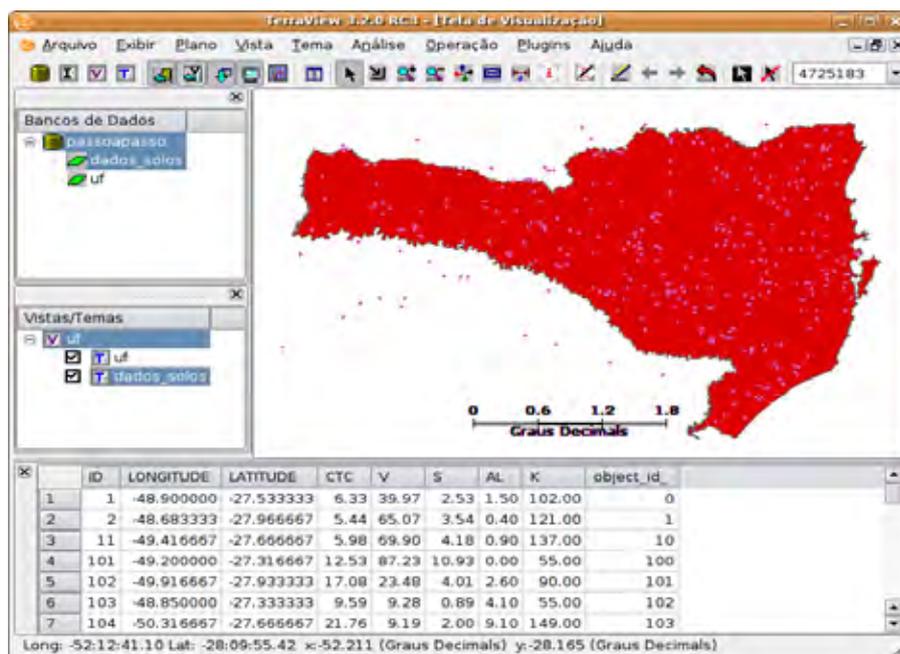
- responder “sim” a pergunta sobre visualização dos dados;

- importar, no TerraView, o arquivo com os dados químicos das amostras de solo (pontos). Arquivo “dados\_solos.dbf”, localizado no diretório “... /dados\_tese/fuzzy”. Projeção latlong, elipsóide SAD69. Defina o campo “LATITUDE” como coordenada y e o campo “LONGITUDE” como coordenada x. Vai gerar o plano de informação “dados\_solos”;



- responda “não” a pergunta sobre visualizar os dados importados;

- crie um novo tema na vista “uf”, a partir dos dados no plano de informação “dados\_solos” (tema “dados\_solos”);



- criação de grade numérica (mnt) com valores relativos à componente química “saturação por bases” (campo V): no GAIA, escolher “criar grade regular”;

- escolher: plano de informação=”dados\_solos”, tema=”dados\_solos”, tabela=”dados\_solos”, atributo=”V”. O GAIA sugere o nome para o plano de informação a ser gerado como “grade\_V”. Informe que as dimensões da grade serão provenientes de outro plano de informação, e escolha “uf” (o plano de informação que contém os limites do estado de Santa Catarina”;

Fonte dos dados:

Plano de informação (layer): dados\_solos

Tema: dados\_solos

Tabela: dados\_solos

Atributo: V

Plano de informação a ser gerado: grade\_V

Dimensões da grade:

as mesmas do plano de informação de origem

provenientes de outro layer (p.ex. o limite da área)

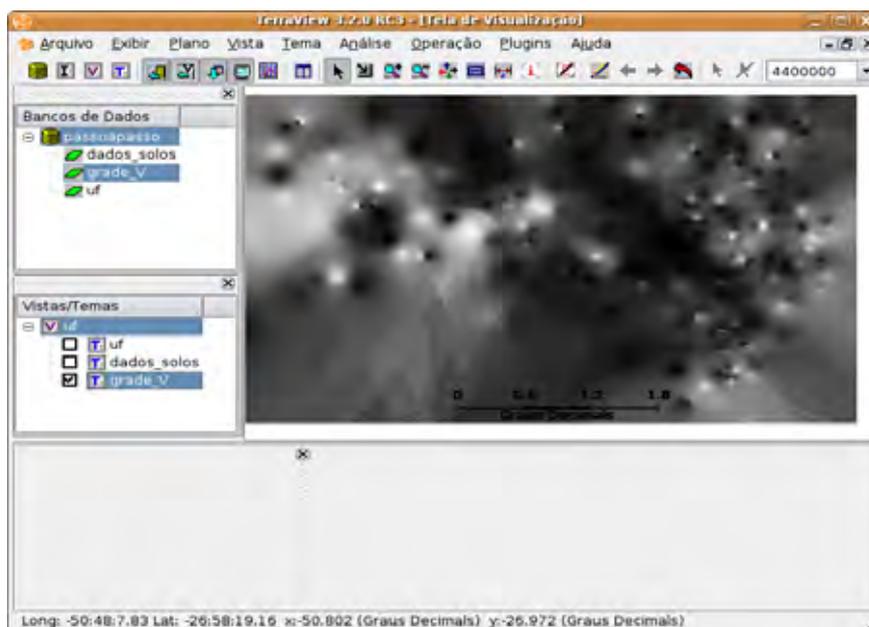
uf

Criar grade Cancelar

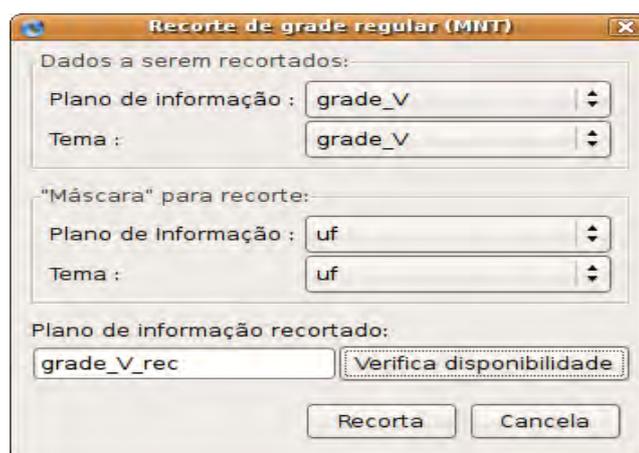
- clique em “criar grade”;

- no TerraView, clique com o botão direito no nome do banco de dados (“passoapasso”), e escolha “reconectar banco de dados”;

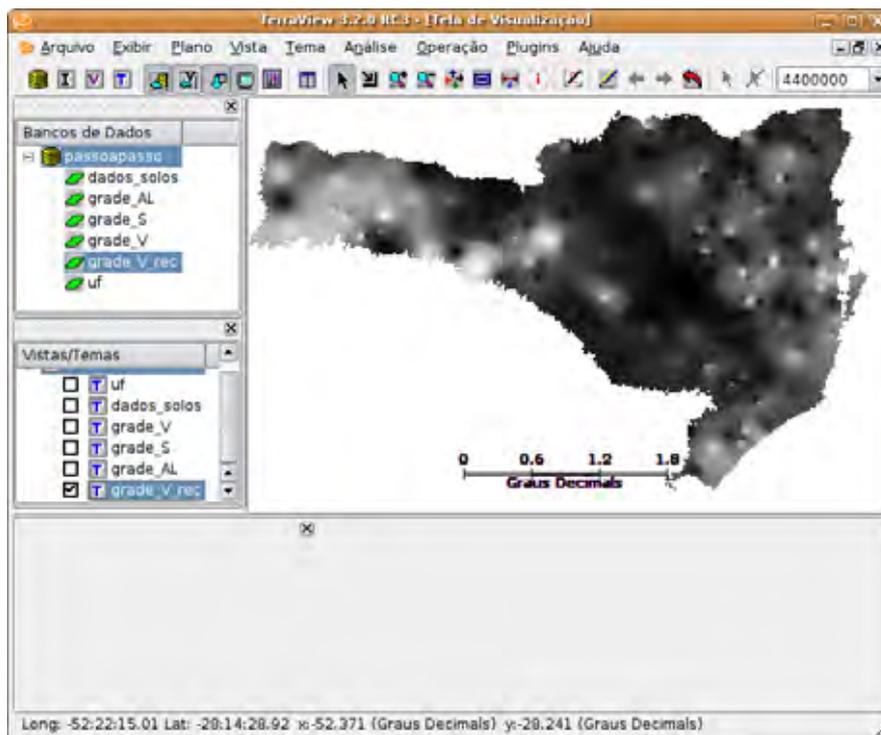
- crie um tema a partir do plano de informações “grade\_v”, criado pelo GAIA;



- repita o procedimento (geração de grade e criação do tema) para os atributos “S” (saturação por bases) e “AL” (alumínio);
- recorte da grade gerada, tomando por base o desenho do estado de Santa Catarina: no GAIA, escolha “recortar grade regular”;
- na seção “dados a serem recortados”, escolha o plano de informação “grade\_V” e o tema “grade\_V”; na seção “máscara para recorte”, escolha o plano de informação “uf” e o tema “uf”; o GAIA sugere o nome “grade\_V\_rec” para o plano de informação que conterà o resultado do recorte. Você pode clicar no botão “verificar disponibilidade” para conferir se este nome realmente pode ser utilizado (isto é, se já não existe um plano de informação com este nome);



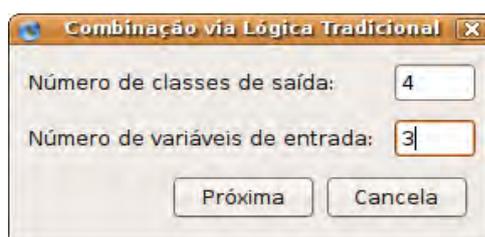
- no TerraView, clique com o botão direito no nome do banco de dados (“passoapasso”), e escolha “reconectar banco de dados”, para que o novo plano de informação “grade\_V\_rec” apareça na lista;
- crie um tema a partir do plano de informações “grade\_V\_rec”, criado pelo GAIA;



- repita o procedimento (recorte de grade e criação do tema) para os planos de informação “grade\_S” e “grade\_AL”;

- COMBINAÇÃO DE TEMAS VIA LÓGICA TRADICIONAL: escolha esta opção no menu inicial do GAIA;

- número de classes de saída: 4 (fertilidade do solo alta, média, baixa, e muito baixa); número de variáveis de entrada: 3 (as grades nos planos de informação “grade\_V\_rec”, “grade\_S\_rec” e “grade\_AL\_rec”);



- a tabela na próxima janela deverá ser preenchida conforme a tabela apresentada na página 59. Na linha “variáveis de entrada”, deverão ser escolhidos os planos de informação “grade\_V\_rec”, “grade\_S\_rec” e “grade\_AL\_rec”. Conforme vai se escolhendo, o GAIA mostra o menor e o maior valor encontrado em cada grade;

- preencher a coluna “classes de saída” com as classes desejadas para a fertilidade do solo: “alta”, “média”, “baixa”, “muito baixa”; nas demais caixas de texto, deve-se preencher os valores conforme a tabela da página 59;

- definir o nome do plano de informação que conterá o resultado do processamento. Utilizar o botão “verifica disponibilidade” para conferir se este nome está disponível no TerraView; definir também o nome da vista onde será gerado, no TerraView, o tema com o resultado do processamento. (ATENÇÃO: NESTA VERSÃO, NÃO É POSSÍVEL GERAR O TEMA EM UMA VISTA JÁ EXISTENTE);

Variáveis de entrada	Valores	Lim.inf.	Lim.sup.
grade_V_rec	Menor=1.894665 Maior=89.465547	50	90
grade_S_rec	Menor=0.379747 Maior=42.140451	4	43
grade_AL_rec	Menor=0.006369 Maior=13.907011	0	0.3

Classes de saída	Lim.inf.	Lim.sup.
alta	50	90
media	35	50
baixa	10	35
muito_baixa	0	10

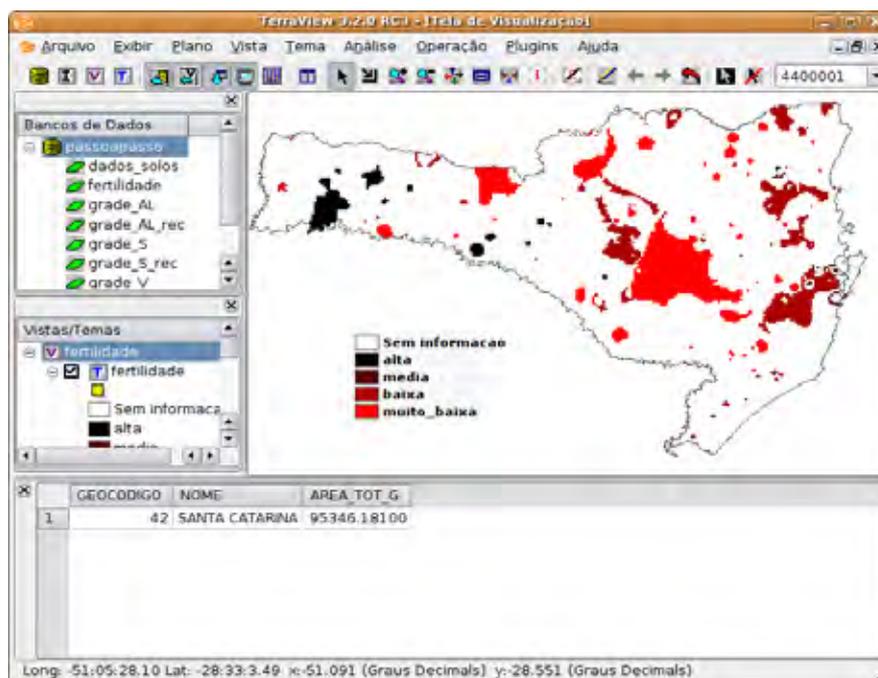
Plano de informação que armazenará a grade resultante:

Vista para criação do tema classificado:

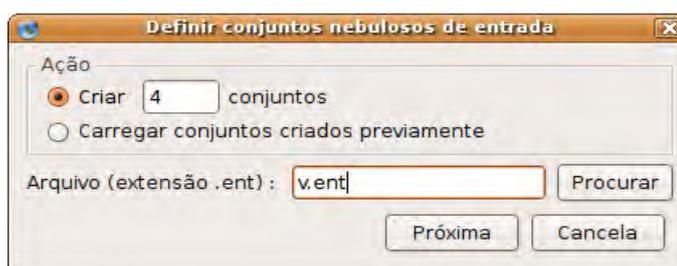
- clicar no botão “processa regras”;

- no TerraView, clique com o botão direito no nome do banco de dados (“passoapasso”), e escolha “reconectar banco de dados”;

- (ATENÇÃO: COMO UMA NOVA VISTA FOI CRIADA, SUGERIMOS CRIAR UM NOVO TEMA NESTA VISTA, COM OS LIMITES DO ESTADO DE SANTA CATARINA, PARA MELHOR VISUALIZAÇÃO DO RESULTADO DO PROCESSAMENTO);



- COMBINAÇÃO DE TEMAS VIA LÓGICA NEBULOSA: precisaremos criar os conjuntos nebulosos de entrada, os conjuntos nebulosos de saída e definir as regras de combinação;
- a entrada relativa à propriedade química “saturação por bases” (V) terá 4 conjuntos nebulosos;
- escolher, no GAIA, a opção “definir conjuntos nebulosos de entrada”;
- na janela seguinte, escolher “4” para o número de conjuntos, e “v.ent” para o nome do arquivo onde serão gravadas as definições dos conjuntos. Clicar no botão próxima;



- preencher: plano de informação com a fonte dos dados: “grade\_V\_rec”;
- através da lista em “configurando conjunto X”, pode-se alternar entre as definições dos diversos conjuntos nebulosos;
- conjunto 1: nome “v\_muito\_pouco”; a=1; b=1; c=10; d=30; (para maiores detalhes sobre os parâmetros a, b, c e d, ver página 67);
- pode-se clicar no botão “visualizar” para desenhar o formato da função de pertinência definida pelos valores em a/b/c/d;

- pode também aproveitar este momento para gerar, no TerraView, uma grade regular (mnt) com os valores de pertinência, conforme a função definida acima. preencher o campo “plano de informação” com o nome desejado, e clicar no botão “verificar disponibilidade”. Clicar em “gerar grade” para efetivamente gerar o novo plano de informação do TerraView;

- definir os demais conjuntos nebulosos relativos a esta entrada:

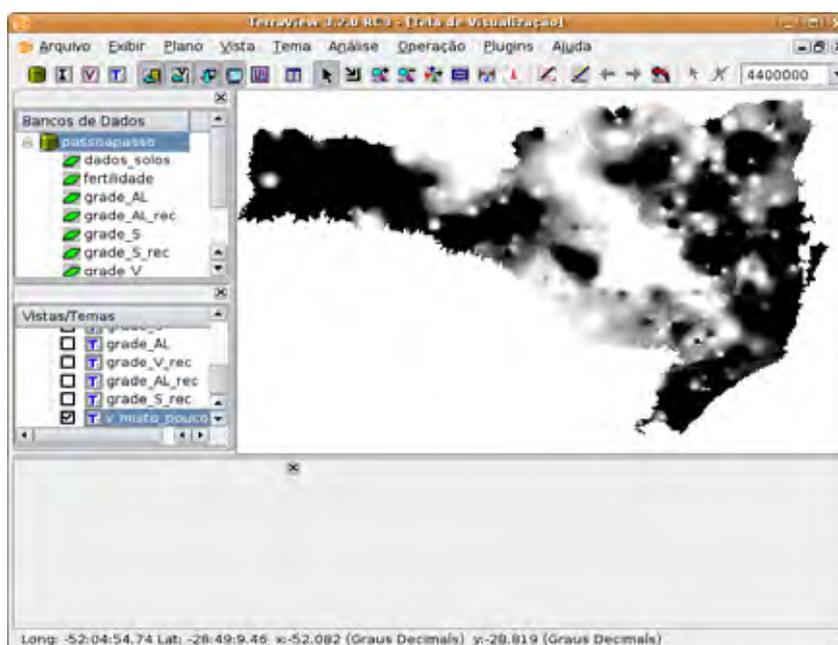
nome: v\_pouco  
 a = 10.000000  
 b = 30.000000  
 c = 35.000000  
 d = 45.000000

nome: v\_medio  
 a = 35.000000  
 b = 45.000000  
 c = 50.000000  
 d = 60.000000

nome: v\_muita  
 a = 50.000000  
 b = 60.000000  
 c = 90.000000  
 d = 90.000000

- clicar em “salva arquivo” para salvar o arquivo “v.ent” com estas definições de conjuntos nebulosos;

- no TerraView, clique com o botão direito no nome do banco de dados (“passoapasso”), e escolha “reconectar banco de dados”, para poder criar os temas relativos aos planos de informação criados com os valores de pertinência;



- repita o procedimento acima para criar os conjuntos nebulosos relativos as outras 2 entradas: planos de informação “grade\_S\_rec” e “grade\_AL\_rec”, gerando os arquivos “s.ent” e “al.ent”:

**Arquivo “s.ent” : 3 conjuntos nebulosos**

nome: s\_pouca

a = 0.300000

b = 0.300000

c = 2.000000

d = 3.000000

nome: s\_media

a = 2.000000

b = 3.000000

c = 3.000000

d = 4.000000

nome: s\_muita

a = 3.000000

b = 4.000000

c = 42.200000

d = 42.200000

**Arquivo “al.ent” : 4 conjuntos nebulosos**

nome: al\_muito\_pouco

a = 0.000000

b = 0.000000

c = 0.300000

d = 0.650000

nome: al\_pouco

a = 0.300000

b = 0.650000

c = 1.000000

d = 2.000000

nome: al\_medio

a = 1.000000

b = 2.000000

c = 3.000000

d = 4.000000

nome: al\_muito

a = 3.000000

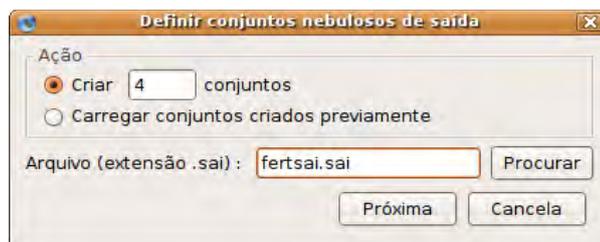
b = 4.000000

c = 14.000000

d = 14.000000

- devemos agora definir os conjuntos nebulosos de saída. O procedimento é bem parecido com o descrito acima, com a diferença de que não precisamos escolher um plano de informação com uma fonte de dados (a fonte de dados será o processamento do sistema). Em compensação, precisaremos indicar qual é o menor e o maior valor de todos os conjuntos. Utilize a opção “definir conjunto nebuloso de saída” no menu principal do GAIA;

- defina criar 4 conjuntos, gerando o arquivo “fertsai.sai”;



- o menor valor será 0, e o maior valor será 10 (estes valores são válidos para todos os 4 conjuntos);

- defina cada conjunto conforme os dados a seguir:

nome: fert\_muito\_baixa

a = 0.000000

b = 0.000000

c = 2.000000

d = 3.000000

nome: fert\_baixa

a = 2.000000

b = 3.000000

c = 4.000000

d = 5.000000

nome: fert\_media

a = 4.000000

b = 5.000000

c = 7.000000

d = 8.000000

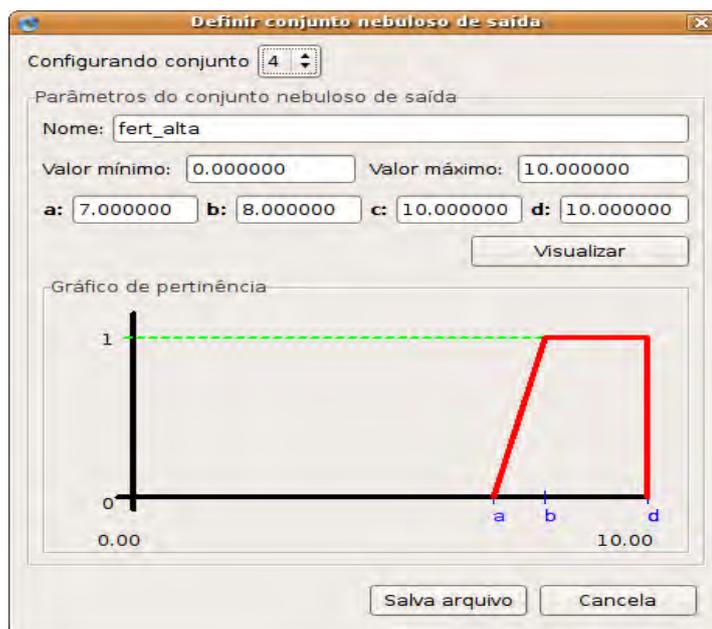
nome: fert\_alta

a = 7.000000

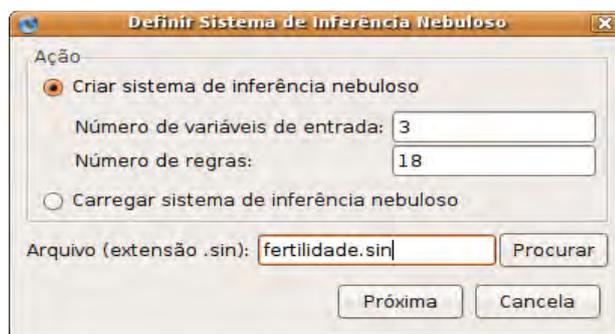
b = 8.000000

c = 10.000000

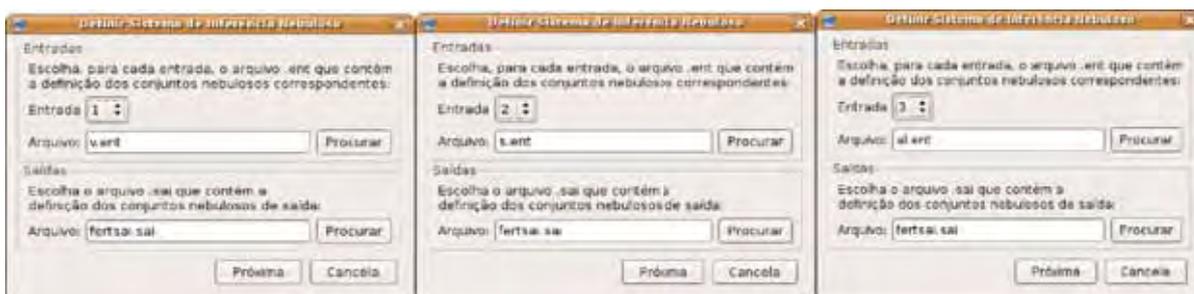
d = 10.000000



- pode-se, com o GAIA, carregar os arquivos gerados (tanto de entrada como de saída) para se realizar uma redefinição dos conjuntos nebulosos;
- Escolher no GAIA a opção “combinação de temas via lógica nebulosa”;
- escolher “criar sistema”, com 3 variáveis de entrada e 18 regras. O nome do arquivo a ser gravado é “fertilidade.sin”;



- na janela seguinte, devemos indicar os 3 arquivos com as definições dos conjuntos nebulosos de entrada, mais o arquivo com a definição dos conjuntos de saída;



- na última tela, devemos combinar os vários conjuntos nebulosos dos planos de informação de entrada, com os conjuntos nebulosos definidos como saída. Deve-se preencher nesta tela as regras de combinação apresentadas na página 72;

- é preciso também indicar o nome do plano de informação que será gerado como resultado do processo. Após verificar a disponibilidade do nome escolhido,

	Entrada 1: Layer grade_V_rec	Entrada 2: Layer grade_S_rec	Entrada 3: Layer grade_AL_rec	Saída
Regra 1:	v_muita	s_muita	al_muito_pouco	fert_alta
Regra 2:	v_medio	s_muita	al_muito_pouco	fert_alta
Regra 3:	v_muita	s_muita	al_pouco	fert_alta
Regra 4:	v_medio	s_muita	al_pouco	fert_media
Regra 5:	v_muita	s_media	al_muito_pouco	fert_alta
Regra 6:	v_muita	s_media	al_pouco	fert_media
Regra 7:	v_medio	s_media	al_muito_pouco	fert_media
Regra 8:	v_medio	s_media	al_pouco	fert_media
Regra 9:	v_pouco	s_media	al_pouco	fert_media

Processar regras e gerar grade no TerraView:

Plano de informação: fertilidade\_fuz

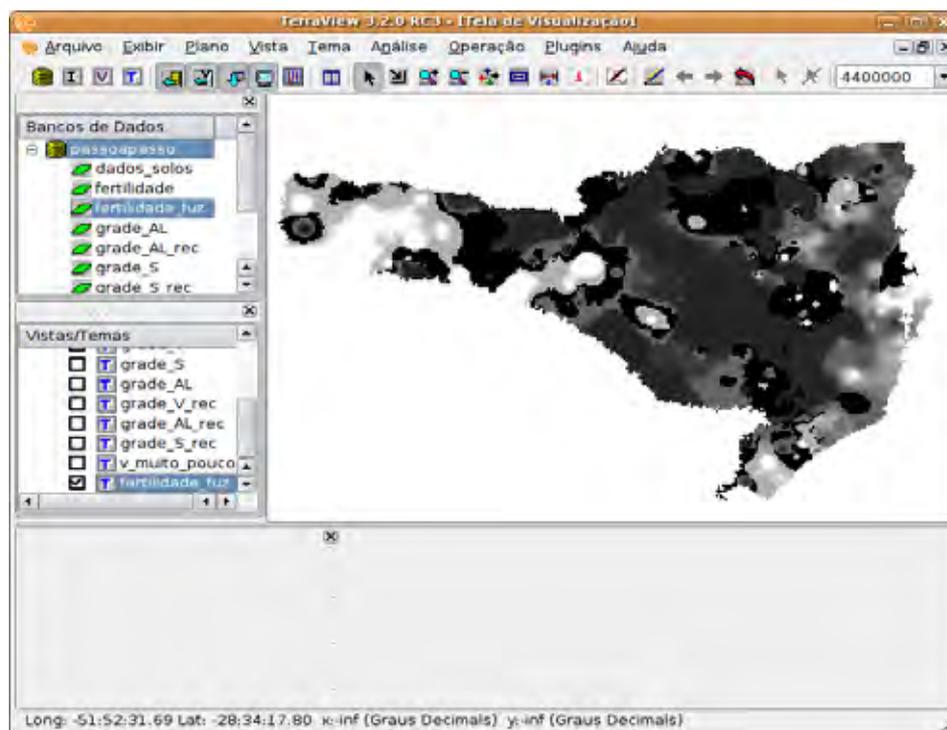
Verificar disponibilidade      Processar Sist. Inferência Nebuloso

Salva arquivo      Cancela

- clicar no botão “processar sistema de inferência nebuloso” para gerar o plano de informação com a saída do sistema;

- depois clicar no botão “salvar arquivo” para salvar o arquivo de regras para permitir reutilização posterior;

- no TerraView, clique com o botão direito no nome do banco de dados (“passoapasso”), e escolha “reconectar banco de dados”, para poder visualizar o plano de informação criado pelo processamento e gerar o tema correspondente;



- ATENÇÃO: os arquivos “s.ent”, “v.ent”, “al.ent”, “fertsai.sai” e “fertilidade.sin” são fornecidos no diretório “... /dados\_tese/fuzzy”;

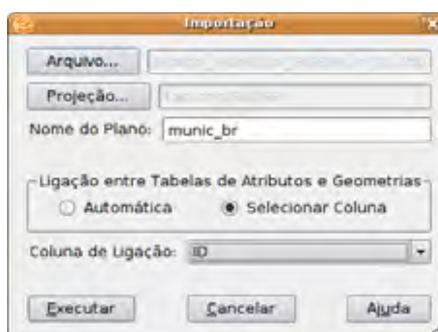
## AGRUPAMENTO DE DADOS VIA REDE NEURAL ARTIFICIAL

SE VOCÊ ESTIVER COMEÇANDO O TUTORIAL AGORA, PULE PARA A LINHA “COMEÇANDO DO ZERO”.

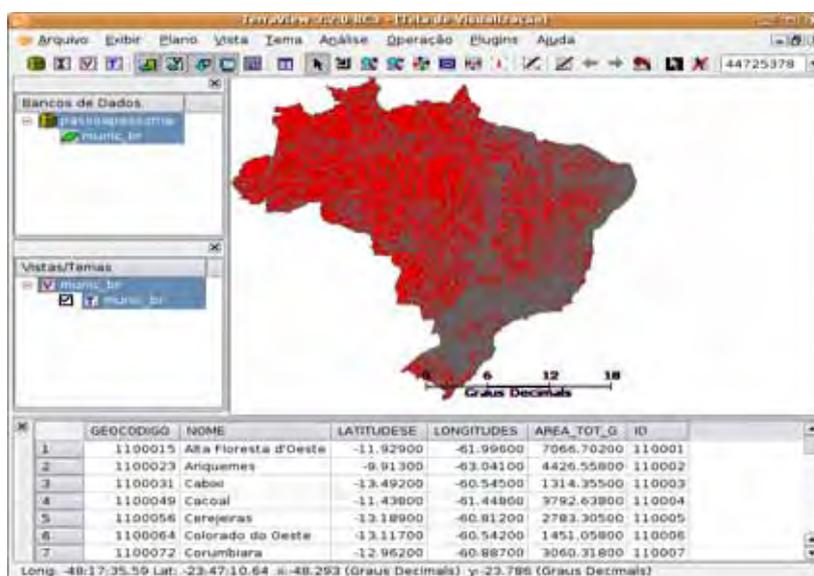
- no GAIA, clique em “desconectar do TerraView”;
- no TerraView, vá no menu arquivo, e escolha “fechar o banco de dados”. Confirme;

### COMEÇANDO DO ZERO:

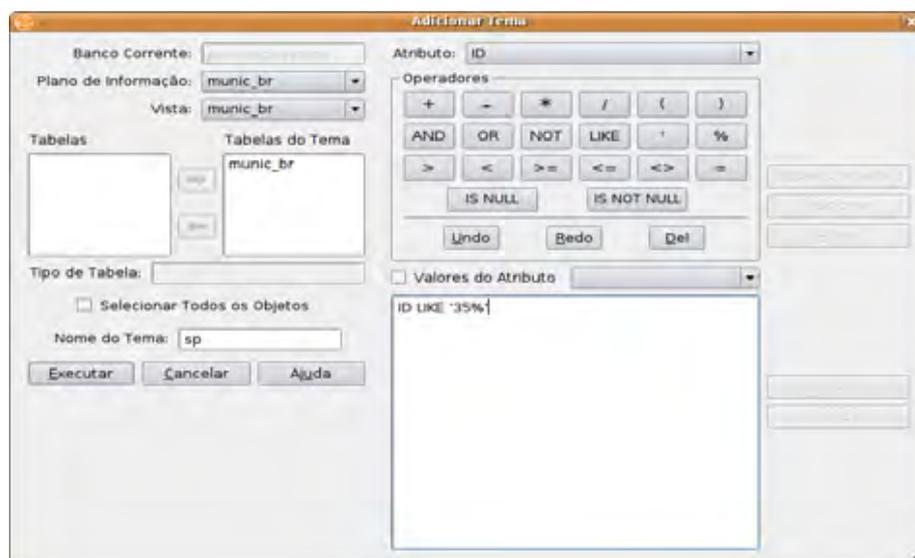
- no TerraView, crie um novo banco de dados chamado “passoapassorna”;
  - no GAIA, faça conexão a este novo banco de dados;
  - no TerraView, faça a importação do shapefile com a malha municipal brasileira, localizado em “.../dados\_tese/rna/malha\_municipal\_IBGE”, projeção latlong, elipsóide SAD69.
- ATENÇÃO, IMPORTANTÍSSIMO!!! no campo “ligação entre tabelas de atributos e geometrias”, ESCOLHER O CAMPO ID. SE ISTO NÃO FOR FEITO, TODO O RESTO NÃO IRÁ FUNCIONAR!!**



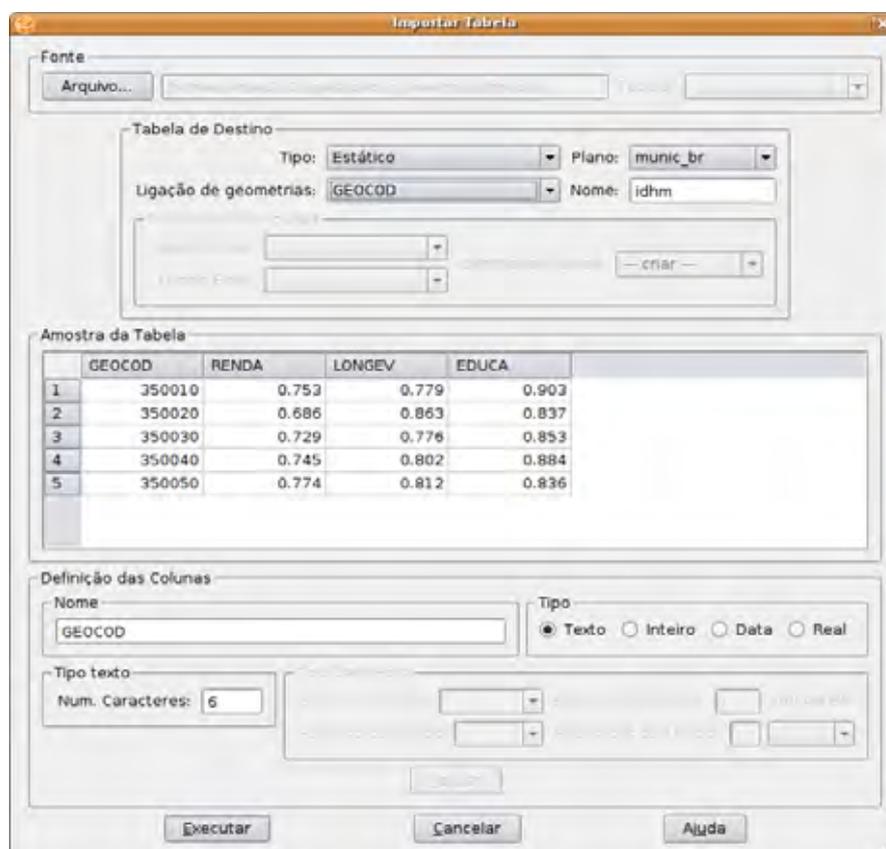
- confirmar visualização dos dados (o TerraView irá criar a vista e o tema automaticamente);



- criar um tema apenas com os municípios de São Paulo;

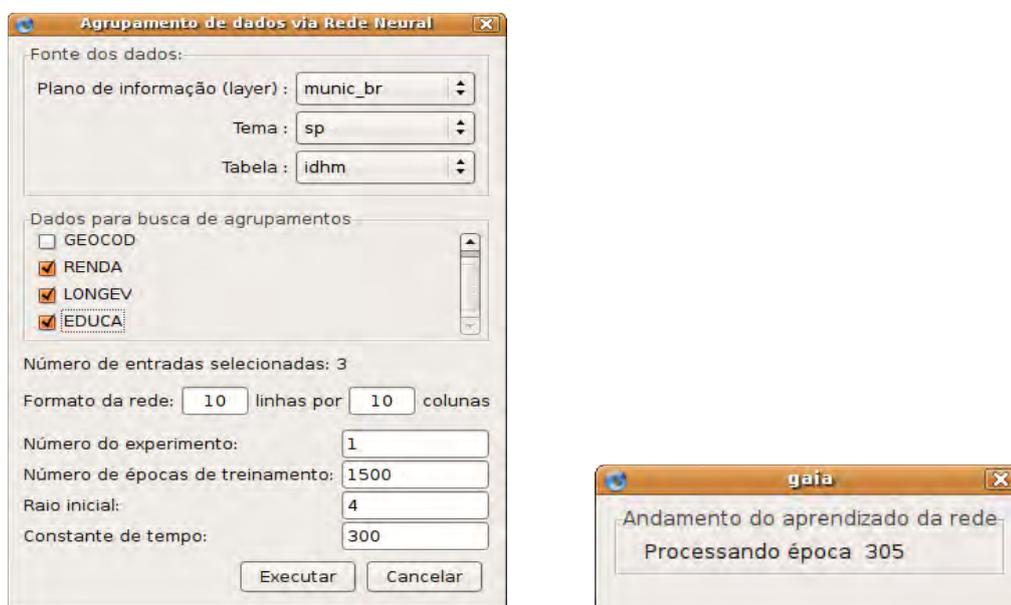


- importar o arquivo DBF (em ... /dados\_tese/ma/idhm.dbf ) com os valores das componentes do IDHM (longevidade, educação e renda) para os municípios do estado de São Paulo;  
**ATENÇÃO!! O CAMPO QUE FAZ A LIGAÇÃO COM OS OBJETOS GRÁFICOS É O CAMPO GEOCOD!!!**



- escolha, no GAIA, a opção “agrupamento espacial via rede neural artificial”;

- plano de informação: “munic\_br”; tema: “sp”; tabela: a recém importada “idhm”;
- marque os campos RENDA, LONGEV e EDUCA;
- clique em “executar”. Uma pequena janela irá se abrir, mostrando o andamento do aprendizado da rede neural;

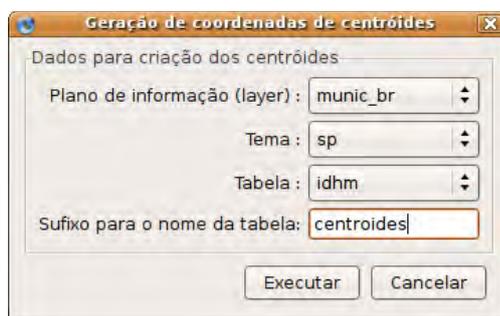


- ao final do aprendizado da rede, o GAIA irá exibir um relatório com as características dos grupos identificados, com relação as variáveis de entrada (ver página 99);

Campos	RENDA	LONGEV	EDUCA
Media geral:	-0.332702	0.458417	-0.119875
Desvio padrao:	0.442609	0.465313	0.502369
Grupo 0	0.379259 (+1.6)	0.435493 (-0.0)	-0.542099 (-0.8)
Grupo 1	-0.445319 (-0.3)	0.780744 (+0.7)	-0.307661 (-0.4)
Grupo 2	-0.632109 (-0.7)	0.284185 (-0.4)	-0.642934 (-1.0)
Grupo 3	-0.076828 (+0.6)	0.887433 (+0.9)	0.220238 (+0.7)
Grupo 4	-0.904549 (-1.3)	0.181400 (-0.6)	0.024861 (+0.3)
Grupo 5	0.485020 (+1.8)	0.540889 (+0.2)	0.614438 (+1.5)
Grupo 6	-0.679882 (-0.8)	-0.522504 (-2.1)	-0.413400 (-0.6)
Grupo 7	-0.001496 (+0.7)	0.049610 (-0.9)	0.894549 (+2.0)

- além deste relatório na tela, o mesmo é gravado em disco em um arquivo de nome “resultadogaiaxx.txt”, onde xx é o valor inserido no campo “número do experimento”. O processo também gerou a tabela “resultadogaiaxx” diretamente no banco de dados do TerraView;

- no TerraView, clique com o botão direito em cima do nome do banco de dados “passoapassorna” e escolha “reconectar banco de dados”, para que se possa exibir a tabela “resultadogaia1” e realizar o mapeamento dos grupos identificados no relatório apresentado anteriormente;
- pode-se gerar os centróides dos objetos gráficos para inserir as coordenadas junto com as variáveis para aprendizado da rede neural. Utilize a opção “geração de centróides” do menu principal do GAIA;
- preencha os dados necessários: plano de informação = “munic\_br”; tema = “sp”; tabela que vamos copiar para gerar uma nova, com os valores das coordenadas = “idhm”; sufixo para o nome da nova tabela = “01” (isto vai causar a geração da tabela “idhm\_centroides01”);



- no TerraView, clique com o botão direito em cima do nome do banco de dados “passoapassorna” e escolha “reconectar banco de dados”, para que se possa exibir a tabela “idhm\_centroides01”;
- para realizar a identificação de agrupamentos utilizando os centróides, basta realizar o procedimento descrito acima na nova tabela “idhm\_centroides01”, marcando-se junto com LONGEV, RENDA e EDUCA os campos “longitude” e “latitude”;

## Anexo B

### DESCRIÇÃO DAS VARIÁVEIS DA FUNDAÇÃO SEADE

- Grau de Urbanização

Definição: Percentual da população urbana em relação à população total. É calculado, geralmente, a partir de dados censitários, segundo a fórmula:

$$\text{Grau de urbanização} = ( \text{Pop. urbana} / \text{Pop. total} ) \times 100$$

Fonte: Instituto Brasileiro de Geografia e Estatística – IBGE e Fundação Seade.

- Média de Anos de Estudos da População de 15 a 64 Anos

Definição: Número médio de anos de estudo da população na faixa etária.

A informação de anos de estudo é obtida em função da série e grau mais elevado concluído com aprovação.

Fonte: Instituto Brasileiro de Geografia e Estatística – IBGE. Censo Demográfico.

- Taxa de Analfabetismo da População de 15 Anos e Mais

Definição: Consideraram-se como analfabetas as pessoas maiores de 15 anos que declararam não serem capazes de ler e escrever um bilhete simples ou que apenas assinam o próprio nome, incluindo as que aprenderam a ler e escrever, mas esqueceram.

Fonte: Instituto Brasileiro de Geografia e Estatística – IBGE. Censo Demográfico e Fundação Seade.

- Domicílios com Infra-estrutura Interna Urbana Adequada

Definição: Proporção de domicílios que dispõem de ligação às redes públicas de abastecimento (água e energia elétrica) e de coleta (lixo e esgoto), sendo a fossa séptica a única exceção aceita no lugar do esgoto, sobre o total de domicílios permanentes urbanos.

Fonte: Instituto Brasileiro de Geografia e Estatística – IBGE. Censo Demográfico, e Fundação Seade.

- Médicos Atuando na Área da Saúde Municipal

Definição: Profissionais municipais, municipalizados e comissionados, sob a gerência da prefeitura.

Fonte: Fundação Seade. Pesquisa Municipal Unificada – PMU.

Nota: Inclui os profissionais alocados na área administrativa.

- População de 18 a 24 Anos com Ensino Médio Completo

Definição: População de 18 a 24 anos de idade que concluíram o ensino médio em relação ao total da população na mesma faixa etária.

Fonte: Instituto Brasileiro de Geografia e Estatística – IBGE. Censo Demográfico.

## Anexo C APRENDIZADO DE UM NEURÔNIO ARTIFICIAL

O exemplo a seguir mostrará o processamento completo de um neurônio artificial para aprender o funcionamento da função lógica “E”. Esta função combina duas proposições que podem ser verdadeiras ou falsas. O resultado, porém, só é verdadeiro se ambas as proposições forem verdadeiras. Tomemos como exemplo ilustrativo a seguinte frase:

“se fizer sol **E** fizer calor ENTÃO vou a praia”

A primeira proposição — fazer sol — pode ter dois resultados possíveis: ser verdadeira ou falsa. O mesmo acontece com a segunda proposição. Desta forma temos quatro combinações possíveis de eventos:

- |                      |                      |
|----------------------|----------------------|
| ● fazer sol: VERDADE | fazer calor: VERDADE |
| ● fazer sol: VERDADE | fazer calor: FALSO   |
| ● fazer sol: FALSO   | fazer calor: VERDADE |
| ● fazer sol: FALSO   | fazer calor: FALSO   |

A função lógica **E** só vai gerar um resultado verdadeiro (ir a praia: VERDADE) apenas se ambas as proposições forem verdadeiras. Se ambas forem falsas, ou mesmo apenas uma delas for falsa, o resultado final será falso, conforme apresentado a seguir:

- |   |                       |
|---|-----------------------|
| ● fazer sol: VERDADE , fazer calor: VERDADE | → ir a praia: VERDADE |
| ● fazer sol: VERDADE , fazer calor: FALSO   | → ir a praia: FALSO   |
| ● fazer sol: FALSO , fazer calor: VERDADE   | → ir a praia: FALSO   |
| ● fazer sol: FALSO , fazer calor: FALSO     | → ir a praia: FALSO   |

Se atribuirmos o valor 1 para VERDADE, e o valor 0 para FALSO, teremos o que é denominado a tabela-verdade da função **E**:

entrada 1	entrada 2	resultado
1	1	1
1	0	0
0	1	0
0	0	0

Podemos treinar uma RNA para aprender a calcular o resultado acima a partir das entradas informadas. Na verdade, para este problema simples, precisamos de apenas um único neurônio artificial. Este neurônio terá três entradas, sendo uma delas sempre com o valor 1. A saída deste neurônio (isto é, o resultado de sua função de ativação) será igual a 1 caso a soma ponderada das entradas seja maior que zero, e será igual a 0 caso a soma ponderada seja menor ou igual a 0. Esta arquitetura é apresentada na figura A1. Podemos identificar neste figura as três entradas do neurônio (uma delas sempre com valor 1, as outras são identificadas por  $x_1$  e  $x_2$ ), as três conexões entre as entradas e o neurônio, juntamente com os valores dos pesos dessas conexões (representadas pelas letras  $b$ ,  $w_1$  e  $w_2$ ). A letra  $v$  representa o resultado da soma ponderada que o neurônio realizará sobre as entradas ( $1 \times b + x_1 \times w_1 + x_2 \times w_2$ ). Finalmente, a saída do neurônio é o resultado da aplicação da função de ativação sobre o valor da soma ponderada, representado por  $f(v)$ .

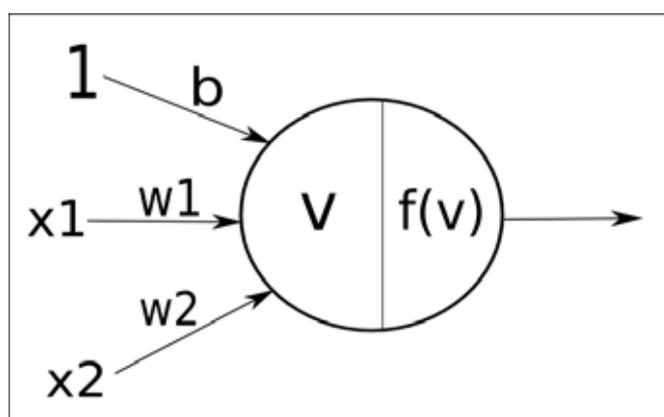


Figura A1: Um neurônio artificial para a função lógica “E”.  
Elaboração: Carlos José de Almeida Pereira.

Antes de iniciarmos o treinamento deste neurônio artificial, precisamos atribuir valores iniciais para os pesos das conexões ( $b$ ,  $w_1$  e  $w_2$ ). Para simplificar, iniciaremos todos os pesos com o valor zero.

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
				0	0	0							

Iniciando o treinamento, apresentamos à rede o primeiro conjunto de valores, isto é, a primeira linha da tabela verdade definida anteriormente (lembramos que uma das entradas — cujo peso de conexão é identificado pela letra “b” — terá sempre o valor 1, independente do valor das outras entradas):

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0		1					

Calcula-se o valor de  $v$ , que é a soma ponderada das entradas pelos seus respectivos pesos:

$$v = (1 \times b) + (x_1 \times w_1) + (x_2 \times w_2) = 1 \times 0 + 1 \times 0 + 1 \times 0 = 0$$

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1					

Utiliza-se a função de ativação para calcular o valor de saída do neurônio correspondente as entradas apresentadas:

$$f(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v \leq 0 \end{cases}$$

Como  $v$  é igual a 0, podemos ver pela definição acima que  $f(v) = 0$ . Ou seja, a saída deste neurônio, para as entradas apresentadas e com os valores de pesos iguais a 0, é igual a 0. Isto é um erro, pois a saída correta para as entradas apresentadas deveria ser igual a 1. Logo, precisamos corrigir os valores dos pesos para evitar a repetição deste erro no futuro. Calculamos então este erro, que é o valor da saída esperada MENOS o valor gerado pela rede.

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1			

Os novos valores dos pesos das conexões são calculados através da seguinte fórmula:

$$peso_{novo} = peso_{antigo} + (erro \times entrada_{respectiva})$$

Os novos pesos serão:

$$b_{novo} = b_{antigo} + erro \times entrada = 0 + -1 \times 1 = -1$$

$$w1_{novo} = w1_{antigo} + erro \times entrada = 0 + -1 \times 1 = -1$$

$$w2_{novo} = w2_{antigo} + erro \times entrada = 0 + -1 \times 1 = -1$$

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1

Apresenta-se agora o segundo conjunto de dados de treino (juntamente com sua saída esperada):

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1
	1	0	1	1	1	1		0					

Repete-se então todos os procedimentos. Calcula-se a soma ponderada das entradas, lembrando que os valores dos pesos foram alterados pela iteração anterior:

$$v = (1 \times b) + (x1 \times w1) + (x2 \times w2) = 1 \times 1 + 0 \times 1 + 1 \times 1 = 2$$

Com o valor da soma ponderada, calculamos a saída da rede:

$$v = 2, \text{ logo } f(v) = 1$$

A saída esperada era 0, logo calculamos o erro:

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1
	1	0	1	1	1	1	2	0	1	-1			

Como houve erro, devemos novamente calcular os novos pesos das conexões:

$$b_{\text{novo}} = b_{\text{antigo}} + \text{erro} \times \text{entrada} = 1 + (-1) \times 1 = 0$$

$$w1_{\text{novo}} = w1_{\text{antigo}} + \text{erro} \times \text{entrada} = 1 + (-1) \times 0 = 1$$

$$w2_{\text{novo}} = w2_{\text{antigo}} + \text{erro} \times \text{entrada} = 1 + (-1) \times 1 = 0$$

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1
	1	0	1	1	1	1	2	0	1	-1	0	1	0

Apresentamos o terceiro conjunto de dados de treinamento:

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1
	1	0	1	1	1	1	2	0	1	-1	0	1	0
	1	1	0	0	1	0		0					

Soma ponderada das entradas:

$$v = (1 \times b) + (x1 \times w1) + (x2 \times w2) = 1 \times 0 + 1 \times 1 + 0 \times 0 = 1$$

Saída da rede:

$$v = 1, \text{ logo } f(v) = 1$$

Como a saída esperada era 0, o erro é igual a -1.

Novos pesos das conexões:

$$b_{\text{novo}} = b_{\text{antigo}} + \text{erro} \times \text{entrada} = 0 + (-1) \times 1 = -1$$

$$w1_{\text{novo}} = w1_{\text{antigo}} + \text{erro} \times \text{entrada} = 1 + (-1) \times 1 = 0$$

$$w2_{\text{novo}} = w2_{\text{antigo}} + \text{erro} \times \text{entrada} = 0 + (-1) \times 0 = 0$$

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1
	1	0	1	1	1	1	2	0	1	-1	0	1	0
	1	1	0	0	1	0	1	0	1	-1	-1	0	0

Finalmente, apresentamos ao neurônio artificial o quarto conjunto de valores de treino. Como para este conjunto a rede gera na saída o valor correto esperado, não há alteração nos valores dos pesos

	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
	1	1	1	0	0	0	0	1	0	-1	1	1	1
	1	0	1	1	1	1	2	0	1	-1	0	1	0
	1	1	0	0	1	0	1	0	1	-1	-1	0	0
	1	0	0	-1	0	0	-1	0	0	0	-1	0	0

Neste momento, quando apresentamos todos os conjuntos de treinamento, chegamos ao final da primeira **ÉPOCA** de treinamento. Enquanto houver erros em uma época, o treinamento continua, repetindo-se todos os cálculos para todos os conjuntos de treinamento novamente, configurando assim uma nova época de treinamento.

Continuando o treinamento em uma segunda época:

época	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
<b>1</b>	1	1	1	0	0	0	0	1	0	-1	1	1	1
<b>1</b>	1	0	1	1	1	1	2	0	1	-1	0	1	0
<b>1</b>	1	1	0	0	1	0	1	0	1	-1	-1	0	0
<b>1</b>	1	0	0	-1	0	0	-1	0	0	0	-1	0	0
<b>2</b>	1	1	1	-1	0	0	-1	1	0	1	0	1	1
<b>2</b>	1	0	1	0	1	1	1	0	1	-1	-1	1	0
<b>2</b>	1	1	0	-1	1	0	0	0	0	0	-1	1	0
<b>2</b>	1	0	0	-1	1	0	-1	0	0	0	-1	1	0

Novamente encontramos erros durante o treinamento da rede nesta segunda época, o que ocasiona a continuação do treinamento em uma terceira época, e assim por diante.

A rede será totalmente treinada na 5ª época, sendo a 6ª época utilizada apenas para a confirmação. O resultado completo do treinamento da rede para a tabela verdade “E” é apresentada a seguir. Notem que em todos os passos relativos à 6ª época a coluna erro é igual a zero:

época	entradas			pesos			v - soma ponderada	saída esperada	saída gerada pela rede	erro	novos pesos		
	1	x1	x2	b	w1	w2					b	w1	w2
1	1	1	1	0	0	0	0	1	0	-1	1	1	1
1	1	0	1	1	1	1	2	0	1	-1	0	1	0
1	1	1	0	0	1	0	1	0	1	-1	-1	0	0
1	1	0	0	-1	0	0	-1	0	0	0	-1	0	0
2	1	1	1	-1	0	0	-1	1	0	1	0	1	1
2	1	0	1	0	1	1	1	0	1	-1	-1	1	0
2	1	1	0	-1	1	0	0	0	0	0	-1	1	0
2	1	0	0	-1	1	0	-1	0	0	0	-1	1	0
3	1	1	1	-1	1	0	0	1	0	1	0	2	1
3	1	0	1	0	2	1	1	0	1	-1	-1	2	0
3	1	1	0	-1	2	0	1	0	1	-1	-2	1	0
3	1	0	0	-2	1	0	-2	0	0	0	-2	1	0
4	1	1	1	-2	1	0	-1	1	0	1	-1	2	1
4	1	0	1	-1	2	1	0	0	0	0	-1	2	1
4	1	1	0	-1	2	1	1	0	1	-1	-2	1	1
4	1	0	0	-2	1	1	-2	0	0	0	-2	1	1
5	1	1	1	-2	1	1	0	1	0	1	-1	2	2
5	1	0	1	-1	2	2	1	0	1	-1	-2	2	1
5	1	1	0	-2	2	1	0	0	0	0	-2	2	1
5	1	0	0	-2	2	1	-2	0	0	0	-2	2	1
6	1	1	1	-2	2	1	1	1	1	0	-2	2	1
6	1	0	1	-2	2	1	-1	0	0	0	-2	2	1
6	1	1	0	-2	2	1	0	0	0	0	-2	2	1
6	1	0	0	-2	2	1	-2	0	0	0	-2	2	1

Neste momento, uma reflexão se faz necessária: qual a vantagem de um programa tão complexo como este para resolver um problema tão simples? Um programa convencional (isto é, não baseado em computação inteligente), para resolver o mesmo problema, teria este algoritmo bem simples:

```

se ( x1 for verdade ),
então
    se ( x2 for verdade ),    então resultado é verdade
                                senão, resultado é falso.
senão, resultado é falso.

```

A grande vantagem do neurônio artificial perante o programa acima é que aquele tem a capacidade de se adaptar para resolver novas classes de problemas, enquanto o programa acima serve única e exclusivamente para resolver o problema específico para o qual ele foi projetado. Por exemplo, se desejarmos não mais trabalhar com a tabela verdade da função lógica **E**, mas sim com a da função lógica **OU** (para um resultado verdadeiro, basta que apenas uma das entradas seja verdadeira):

entrada 1	entrada 2	resultado
1	1	1
1	0	1
0	1	1
0	0	0

O programa convencional apresentado acima é completamente inútil para resolver este problema. Já o programa que implementa o neurônio artificial é exatamente o mesmo, bastando apenas que realizemos um novo treinamento com os dados apresentados acima. Ou seja, ele é capaz de aprender e se adaptar aos novos dados.