



**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CAMPUS CURITIBA**

GERÊNCIA DE PESQUISA E PÓS-GRADUAÇÃO

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
E INFORMÁTICA INDUSTRIAL - CPGEI**

RÚBIA ELIZA DE OLIVEIRA SCHULTZ

**INTELIGÊNCIA COMPUTACIONAL APLICADA À
PREDIÇÃO ESPAÇO-TEMPORAL**

DISSERTAÇÃO DE MESTRADO

**CURITIBA
FEVEREIRO-2007.**

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial

DISSERTAÇÃO
apresentada à UTFPR
para obtenção do grau de

MESTRE EM CIÊNCIAS

por

RÚBIA ELIZA DE OLIVEIRA SCHULTZ

**INTELIGÊNCIA COMPUTACIONAL APLICADA À
PREDIÇÃO ESPAÇO-TEMPORAL**

Banca Examinadora:

Presidente e Orientador:

PROF^a. DR^a. MYRIAM REGATTIERI DELGADO

UTFPR

Examinadores:

PROF. DR. HÉLIO PEDRINI

UFPR

PROF. DR. CELSO KAESTNER

UTFPR

Curitiba, fevereiro de 2007.

RÚBIA ELIZA DE OLIVEIRA SCHULTZ

**INTELIGÊNCIA COMPUTACIONAL APLICADA À PREDIÇÃO
ESPAÇO-TEMPORAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná, como requisito parcial para a obtenção do grau de “Mestre em Ciências” – Área de Concentração: Informática Industrial.

Orientadora: Prof^ª. Dr^ª. Myriam Regattieri Delgado
Co-Orientadora: Prof^ª. Dr^ª. Tania Mezzadri Centeno

Curitiba

2007

Ficha catalográfica elaborada pela Biblioteca da UTFPR – Campus Curitiba

S387i Schultz, Rúbia Eliza de Oliveira
Inteligência computacional aplicada à predição espaço-temporal / Rúbia Eliza de Oliveira Schultz. Curitiba. UTFPR, 2007
XIII, 117 f. : il. ; 30 cm

Orientadora: Profª. Drª. Myriam Regattieri Delgado
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial. Curitiba, 2007
Bibliografia: f. 104 – 117

1. Sensoriamento remoto. 2. Processamento de imagens – Técnicas digitais. 3. Sistemas de recuperação da informação – Geografia. I. Delgado, Myriam Regattieri, orient. II. Universidade Tecnológica Federal do Paraná. Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD: 621.3678

Vencer não é nada, se não se teve muito trabalho;
fracassar não é nada, se se fez o melhor possível.

(Nadia Boulanger)

AGRADECIMENTOS

A Deus, por permitir a realização deste projeto de vida.

À minha orientadora Myriam, que foi um exemplo de caráter e comprometimento. Obrigada pela excelente orientação e confiança.

À minha co-orientadora Tania, por permitir a continuação de sua pesquisa, por incentivar o projeto e prestar todos os esclarecimentos necessários para o desenvolvimento da proposta.

Aos meus pais Rubin e Zélia, que foram meu porto seguro nesta caminhada. Obrigada por todo o apoio e conforto nos momentos difíceis, e principalmente pelo incentivo a nunca desistir.

Ao meu querido irmão Max, que exatamente no mesmo período batalhou por uma conquista semelhante, em seu Mestrado em Ciência da Computação na UFSC. Obrigada pela troca de experiências, conversas virtuais e momentos de desabafo.

Ao meu namorado Rafael Antonio Ascari por compreender minha ausência e respeitar minhas decisões. Obrigada por todo o apoio e carinho.

Aos meus colegas de disciplinas, Margio Klock, Marcos Schneider, Jaqueline Kapke e Mateus Cruz pela troca de conhecimentos. E em especial à Eliane de Bortoli e Marisangela Brittes, que foram verdadeiras companheiras, de disciplinas, moradia, viagens e conversas. Certamente tudo seria mais difícil e solitário sem vocês.

A todos os professores do CPGEI que de uma forma ou outra contribuíram para meu crescimento e aprendizado. Agradeço também aos professores Dr. Alfranci Freitas e Msc. César Janeczko, que no início do Mestrado se dispuseram a nos esclarecer dúvidas, abrindo mão de alguns momentos de seu tempo para compartilhar conosco seus conhecimentos.

À empresa Viasoft Informática Ltda., por dar condições para a realização do Mestrado, sem perda do vínculo empregatício.

Aos membros da banca examinadora pelas interessantes sugestões apresentadas.

SUMÁRIO

LISTA DE FIGURAS	vii
LISTA DE TABELAS	x
LISTA DE ABREVIATURAS E SIGLAS	xi
RESUMO	xii
ABSTRACT	xiii
1 INTRODUÇÃO	1
1.1 MOTIVAÇÕES.....	2
1.2 OBJETIVOS.....	4
1.3 ESTRUTURA DA DISSERTAÇÃO.....	4
2 INTELIGÊNCIA COMPUTACIONAL	6
2.1 SISTEMAS <i>FUZZY</i>	6
2.1.1 Conjuntos <i>Fuzzy</i>	7
2.1.2 Funções de Pertinência.....	8
2.1.3 Definições Básicas em Conjuntos <i>Fuzzy</i>	10
2.1.4 Operações com Conjuntos <i>Fuzzy</i>	10
2.1.5 Relações <i>Fuzzy</i>	13
2.1.6 Raciocínio Aproximado.....	14
2.2 COMPUTAÇÃO EVOLUTIVA.....	22
2.2.1 Origem.....	22
2.2.2 Funcionamento dos Algoritmos Evolutivos.....	24
2.2.3 Representação dos Indivíduos.....	24
2.2.4 População Inicial.....	28
2.2.5 Função de Aptidão.....	30
2.2.6 Métodos de Seleção.....	31
2.2.7 Operadores Genéticos.....	32
2.2.8 Critério de Término.....	35
3 PREDIÇÃO ESPAÇO-TEMPORAL EM UM CONTEXTO AMBIENTAL	37
3.1 GEOMÁTICA.....	37
3.1.1 Análise Espaço-Temporal.....	39
3.1.2 Modelos Espaciais.....	44
3.1.3 Predição Espaço-Temporal.....	47
3.1.4 Principais Conceitos de Sensoriamento Remoto.....	49

3.2 PROCESSAMENTO DIGITAL DE IMAGENS	50
3.2.1 Imagem Digital.....	50
3.2.2 Técnicas de Pré-processamento.....	50
3.2.3 Segmentação de Imagens.....	52
3.2.4 Extração de Atributos	54
3.2.5 Registro de Imagens	56
3.3 MÉTODOS DE PREDIÇÃO ESPAÇO-TEMPORAL	56
4 METODOLOGIA.....	59
4.1 PREDITOR ESPAÇO-TEMPORAL BASEADO EM UM SISTEMA <i>FUZZY</i> GENÉTICO	59
4.1.1 Módulo de Transformação.....	62
4.1.2 Módulo <i>Fuzzificador</i>	62
4.1.3 Módulo de Inferência Principal	65
4.1.4 Módulo de Agregação	68
4.1.5 Módulo <i>Defuzzificador</i>	69
4.1.5.1 Base de Regras <i>Fuzzy</i> para o processo de Multi-Limiarização	69
4.2 TÉCNICAS EVOLUTIVAS	72
4.2.1 Programação Genética para Calcular o Tamanho da Superfície Predita.....	73
4.2.2 Algoritmo Genético para Ajustar a Base de Dados no Módulo de Inferência Principal.....	77
5 SIMULAÇÕES E RESULTADOS	83
5.1 PREDIÇÃO ESPAÇO-TEMPORAL EM REGIÕES FLORESTAIS	83
5.1.1 Conhecimento Obtido Através do Especialista	85
5.1.2 Expressão Simbólica Obtida de Forma Automática.....	86
5.1.3 Base de Dados Obtida de Forma Automática.....	88
5.2 PREDIÇÃO EM OUTROS CONTEXTOS	94
6 DISCUSSÃO E CONCLUSÕES	101
6.1 CONCLUSÕES	101
6.2 TRABALHOS FUTUROS	102
REFERÊNCIAS BIBLIOGRÁFICAS	104

LISTA DE FIGURAS

1. Exemplo de graus de pertinência em conjuntos <i>fuzzy</i>	8
2. Formatos de funções de pertinência	9
3. Representação dos conceitos de Núcleo, Altura, α -Corte, e Suporte dos conjuntos <i>fuzzy</i>	10
4. Operações aplicadas aos conjuntos representativos de Temperatura “Baixa” e “Média”	11
5. Ilustração das principais Normas-t	12
6. Ilustração das principais Normas-s	12
7. Exemplo de Relação <i>Fuzzy</i> no formato matricial	13
8. Exemplos de partição do universo <i>fuzzy</i> :	16
9. Sistema de Inferência <i>Fuzzy</i>	19
10. <i>Defuzzificação</i> pelo método Centro de Gravidade	20
11. Exemplo de aplicação dos modelos Mamdani e Sugeno	21
12. Estrutura de um algoritmo de PG	25
13. Representação de um cromossomo, com seus genes, alelos e locus gênico	26
14. Exemplo de indivíduo em Programação Genética	27
15. Expressões matemáticas em formato de árvore de sintaxe	28
16. Operador de <i>crossover</i> em AG	33
17. Exemplo de cruzamento entre dois programas	33
18. Exemplos de mutação	34
19. Exemplo de mutação em PG.	35
20. Estruturas temporais	41
21. Área desmatada da floresta em dois instantes t e t'	42
22. Tipos de modelos	44
23. Amostragem, quantização e codificação de uma imagem	51
24. Exemplo de aplicação do filtro da mediana	52
25. Histograma e exemplo de limiar (T)	53
26. Exemplos de limiarização	54
27. Exemplo de aplicação da técnica de etiquetagem	55
28. Esquema geral do SIF que representa o preditor espaço-temporal	61
29. Mapas de progressão e regressão	63
30. Exemplo de aplicação do algoritmo de etiquetagem	64

31. Inferência no Modelo Mamdani	68
32. Funções de pertinência das regras <i>fuzzy</i> do processo de multi-limiarização.....	71
33. Exemplo do processo de multi-limiarização	72
34. Esquema do algoritmo de PG desenvolvido.....	74
35. Esquema do algoritmo genético desenvolvido	78
36. Estrutura de um indivíduo na população de conjuntos de partições (base de dados completa)	78
37. Partição interpretável com $\gamma \geq \gamma_{\min}$ e $\kappa \leq \kappa_{\max}$	81
38. Exemplos de correção de partições <i>fuzzy</i> para garantir a interpretabilidade do modelo.	82
39. Dados da Floresta de Ticoporo.....	83
40. Imagens da floresta localizada em La Joyanca.....	83
41. Imagens da floresta de Tabe	84
42. Comparação dos resultados da predição para Ticoporo	85
43. Aproximação da superfície florestal para as três regiões de estudo através de regressão linear definida por um especialista e o algoritmo de PG proposto.....	87
44. Imagens preditas resultantes das simulações com os métodos de predição FuzzySTP, FuzzyGPSTP e SoftCompSTP e comparação com a imagem real da floresta de Ticoporo.....	89
45. Imagens preditas resultantes das simulações com os métodos de predição FuzzySTP, FuzzyGPSTP e SoftCompSTP para a floresta de Tabe	90
46. Imagens preditas resultantes das simulações com os métodos de predição FuzzySTP, FuzzyGPSTP e SoftCompSTP e comparação com a imagem real da região de La Joyanca	90
47. Partição do universo definida por um especialista (FuzzySTP e FuzzyGPSTP.....	91
48. Partição do universo definida pelo algoritmo genético proposto (SoftCompSTP.....	92
49. Predições para a floresta de Ticoporo, utilizando a abordagem SoftCompSTP.....	93
50. Predições para a floresta de La Joyanca, utilizando a abordagem SoftCompSTP	93
51. Predições para a floresta de Tabe, utilizando a abordagem SoftCompSTP	94
52. Imagens tomográficas de um dedo componente da mão humana.	95
53. Imagens referentes ao acompanhamento da evolução de um tumor cerebral.	96
54. Aproximação da superfície para as três regiões de estudo através de regressão linear definida por um especialista e o algoritmo de PG proposto.....	97
55. Partição do universo definida pelo especialista (FuzzySTP e FuzzyGPSTP).....	98

56. Partição do universo definida pelo algoritmo genético proposto (SoftCompSTP)..	98
57. Predições para a seqüência de imagens tomográficas de um dedo	99
58. Predições para a seqüência de imagens referente à evolução de um tumor. cerebral ...	99

LISTA DE TABELAS

1. Operações de União, Intersecção e Complemento	11
2. Condições para normas-t e normas-s.....	12
3. Principais Normas-t e Normas-s.....	12
4. Operações de União, Intersecção e Complemento em Relações <i>Fuzzy</i>	14
5. Formas de Raciocínio	18
6. Regras <i>Fuzzy</i> do Módulo de Inferência Principal.....	66
7. Regras <i>fuzzy</i> do Processo de Multi-Limiarização.....	70
8. Parâmetros absolutos das funções de pertinência.....	79
9. Comparação entre as simulações realizadas para as florestas de Ticoporo e La Joyanca	88
10. Técnicas empregadas em cada abordagem proposta neste trabalho.....	89
11. Diferenciais da Proposta.....	100

LISTA DE ABREVIATURAS E SIGLAS

SIG	Sistemas de Informação Geográfica.....	xii
IC	Inteligência Computacional.....	xii
GIS	<i>Geographic Information System</i>	xiii
CI	<i>Computational Intelligence</i>	xiii
SF	Sistema <i>Fuzzy</i>	1
CE	Computação Evolutiva	1
RN	Redes Neurais	1
SIF	Sistemas de Inferência <i>Fuzzy</i>	2
PDI	Processamento Digital de Imagens	2
PG	Programação Genética.....	2
AG	Algoritmo Genético	2
<i>MP</i>	<i>Modus Ponens</i>	17
EES	Estratégias Evolutivas	22
PE	Programação Evolutiva.....	22
<i>ISO</i>	<i>International Standards Organization</i>	38
<i>GWR</i>	<i>Geographically Weighted Regression</i>	46
<i>GEODES</i>	<i>GEOgraphic Decision Expert System</i>	57
EQM	Erro Quadrático Médio	73
EQMm	Erro Quadrático Médio Modificado	74

RESUMO

Informações geográficas representam uma importante ferramenta para tomada de decisão no planejamento físico-territorial. O termo Sistemas de Informação Geográfica (SIG) caracteriza os sistemas de informação cuja principal característica é possibilitar a realização de análises espaciais envolvendo dados referenciados geograficamente. No entanto, é inevitável a existência de erros e incerteza na informação geográfica incorporada aos SIG. Os sistemas *fuzzy*, por outro lado, apresentam um grande potencial na modelagem de incertezas e aparecem, portanto, como uma alternativa para a representação e o tratamento da informação geográfica. Desta forma, um modelo baseado em sistemas *fuzzy* e apoiado por técnicas evolutivas é proposto neste trabalho a fim de incorporar mecanismos inteligentes ao tratamento destas informações. O objetivo é desenvolver um preditor espaço-temporal da evolução de florestas através de um sistema baseado em Inteligência Computacional (IC), considerando uma seqüência de imagens de sensoriamento remoto de paisagens em diferentes regiões. O sistema *fuzzy* é composto por cinco módulos e recebe como entrada uma seqüência de imagens binárias produzindo ao final uma projeção para o fenômeno temporal em questão. Com o auxílio de técnicas evolutivas como os algoritmos genéticos e a programação genética, a autonomia do sistema pode ser incrementada, liberando o usuário da definição de alguns parâmetros do sistema. Os resultados mostram que o modelo é competitivo com as abordagens tradicionais, e que o uso de técnicas evolutivas pode incrementar o desempenho do sistema, sempre que há informação disponível suficiente. Além disso, o uso de variáveis lingüísticas *fuzzy* torna o sistema mais interpretável, facilitando o seu uso por parte de operadores pouco acostumados com formulações matemáticas.

ABSTRACT

Geographic information is considered an important tool for decision-making in the Territorial-Physical Planning. The term Geographic Information System (GIS) characterizes information systems which turn possible space analyses involving geographically referenced data. However, it is very common the presence of errors and uncertainty at the incorporated geographic information in the GIS. Fuzzy systems, on the other hand, present a great potential for modeling uncertainties. Then they appear as an alternative for geographic information representation and processing. In this way, a fuzzy-based model supported by evolutionary techniques is proposed in this work to incorporate intelligent mechanisms in the final system. The objective is to develop a spatio-temporal predictor of forest evolution through a system based on Computational Intelligence (CI), considering a sequence of remote sensing images of terrains landscape in different regions. The fuzzy system is composed by five modules and it receives as the input a sequence of binary images producing as the output a projection for the associated temporal phenomenon. The system autonomy can be increased by means of evolutionary techniques as genetic algorithms and genetic programming, that it means to free the user of defining some system parameters. The results show that the model is competitive with traditional approaches and that evolutionary techniques can enhance the system performance, whenever there is sufficient available information. Moreover, the use of fuzzy linguistic variables turns the system more interpretable, facilitating its use by operators unfamiliar with mathematical formulation.

CAPÍTULO 1

INTRODUÇÃO

Nos anos sessenta, com o aparecimento dos Sistemas de Informação Geográfica (SIG) em suporte digital, houve um importante avanço nas formas de armazenar, representar e processar a informação geográfica (FONTE, 2003). Segundo Liotte, Macedo e Pedro (2000), técnicas de geoprocessamento são ferramentas essenciais na tomada de decisões no planejamento físico-territorial, pois permitem a integração de diversos dados espaciais de fontes e naturezas diversas, representadas como planos de informações.

Embora o pensamento cartesiano tenha estimulado a evolução tecnológica como a conhecemos hoje, os ecossistemas naturais têm sofrido as conseqüências deste progresso. E esta situação constitui uma das maiores preocupações no domínio de administração de espaços ambientais. Assim, neste âmbito, transfere-se aos SIG o desafio de auxiliar na previsão de impactos ambientais, a fim de diminuir seus efeitos no futuro.

O panorama de evolução de uma região, juntamente com a perspectiva de seu estado futuro levantam uma questão particularmente importante: qual será o efeito causado por impactos ambientais e transformações ocorridas em determinada região com o passar dos anos? Na verdade, o tempo é constituído de eventos hierárquicos (WORBOYS, 1998) e pode produzir transformações sobre uma determinada entidade geográfica como, por exemplo, o seu surgimento, seu desaparecimento ou mesmo a união de entidades espaciais, e essas transformações são chamadas de fenômenos temporais (CLARAMUNT et al., 1994).

Para Marble (1990), o desenvolvimento do conceito principal dos SIG teve sua origem na Cartografia e na Geografia. Porém, segundo Medeiros (1999), não seria possível atingir o atual nível de desenvolvimento sem a contribuição da Computação Gráfica, Processamento de Imagens, Sensoriamento Remoto e Sistemas Gerenciadores de Banco de Dados. Podem ainda ser incluídas às contribuições citadas, as novas técnicas de Classificação Contínua e da Inteligência Computacional (IC), como uma base auxiliar aos procedimentos de análise espacial e de geração de mapas.

Inteligência Computacional pode ser definida como a área de pesquisa que envolve Sistemas *Fuzzy* (SF), Computação Evolutiva (CE), cujos representantes mais famosos são os Algoritmos Genéticos, e por fim as Redes Neurais (RN). Esta área tem atraído cada vez mais a atenção dos pesquisadores e é vista como uma alternativa para a

solução de problemas práticos complexos como aqueles associados à predição espaço-temporal.

O método que está sendo proposto é baseado fundamentalmente em técnicas de Inteligência Computacional (IC), mais especificamente Sistemas de Inferência *Fuzzy* (SIF), Programação Genética (PG) e Algoritmos Genéticos (AG), todos servindo de suporte para o Processamento Digital de Imagens (PDI).

1.1 MOTIVAÇÕES

Os recursos computacionais têm sido cada vez mais empregados por pesquisadores que se preocupam com a análise de fenômenos espaço-temporais. O monitoramento da evolução da paisagem de uma região a partir de séries temporais propicia elementos para apontar as tendências reais e atuantes do dinamismo da região. A existência de trabalhos desenvolvidos na área motiva um estudo mais aprofundado do tema.

Como exemplo de trabalhos que consideram fenômenos espaço-temporais, pode-se citar Peuquet (1994), que trabalha com representações da informação espaço-temporal; Martines (1999), que aplica geoprocessamento para análise espaço-temporal de expansão urbana; Pedrosa (2004), que utiliza um ambiente computacional para modelagem dinâmica espacial; Worboys (1998), que apresenta um modelo genético para informações geográficas espaço-temporais; Rocha, Kaestner e Borges (1997), que utilizam redes bayesianas em fotointerpretação; e os trabalhos que utilizam dados espaço-temporais especialmente para avaliação de impactos ambientais, como Centeno, Saint-Joan e Desachy (1996), Centeno, Selleron e Gonçalves (2003), Centeno e Selleron (2001, 2002), Saint-Joan e Desachy (1995, 1996) e Saint-Joan e Vidal (1997a, 1997b).

Existe atualmente uma grande variedade de tecnologias de processamento de informação sendo utilizadas em diferentes domínios de aplicação, e que vêm produzindo resultados encorajadores na solução de tarefas específicas. Entretanto, torna-se cada vez mais evidente o fato de que muitos problemas não podem ser solucionados através do uso isolado de algumas destas técnicas (SCHERER, 1996). Este fato serve como um dos principais incentivos à criação de sistemas híbridos, que possam suprimir as limitações individuais de cada técnica (COX, 2005; DE CASTRO e VON ZUBEN, 2005).

A Inteligência Computacional (ENGELBRECHT, 2002) aparece como uma área importante para o fornecimento de técnicas e modelos cuja aplicação conjunta resulte em

sistemas híbridos robustos. A Inteligência Computacional permite, por exemplo, a representação do conhecimento através de uma base de regras e tratamento de incertezas, presentes nos sistemas *fuzzy*, assim como a obtenção de soluções por meio de métodos de busca, característica dos algoritmos baseados em computação evolutiva. O exemplo mais comum desta cooperação são os sistemas *fuzzy* genéticos, do inglês *Genetic Fuzzy Systems* (CÓRDON et al., 2001).

Técnicas baseadas em sistemas *fuzzy* podem ser bastante úteis para tratar a complexidade associada aos mapas ambientais (MOURA, 2001), como por exemplo, a heterogeneidade dos dados, dificuldade de segmentar as imagens, etc. Segundo Centeno, Saint-Joan e Desachy (1996), em oposição aos sistemas de mapas algébricos baseados na lógica booleana, os sistemas baseados na teoria dos conjuntos *fuzzy* trabalham com a imprecisão e a incerteza de maneira eficiente, representando uma ferramenta de grande importância para o design de SIG. Conforme citado por Centeno e Góis (2005), autores como Duarte (2000), Silvert (1997), Goudard e Sinay (2001) apresentam uma série de vantagens na utilização de sistemas de inferência *fuzzy* em questões relativas ao meio ambiente, resumidos a seguir:

- permitir a integração balanceada de dados heterogêneos em diversas escalas de magnitude, que podem ser convertidos em termos lingüísticos (por exemplo: alto, médio, baixo), facilitando a utilização e o estabelecimento de regras de integração por parte de especialistas e usuários.
- possibilitar a montagem de um conjunto de variáveis com termos lingüísticos, que facilitam a utilização por parte de especialistas não habituados às terminologias matemáticas.
- permitir a representação de regiões de fronteiras não abruptas onde pequenas variações não produzem salto de uma decisão para outra.

Burrough (1992), por exemplo, trabalha com modelagens booleanas e teoria *fuzzy* para verificar como as incertezas nos valores dos atributos dos mapas causam erros nos resultados das inferências espaciais. Os resultados obtidos por esse autor sugerem que os métodos booleanos estão muito mais sujeitos à propagação de erros do que os equivalentes *fuzzy*, e que a utilização da técnica *fuzzy* pode reduzir a propagação de erros através do tratamento da imprecisão dos dados, fornecendo informações mais confiáveis.

Em Centeno e Selleron (2001, 2002), fórmulas matemáticas associadas a fundamentos de conjuntos *fuzzy* e imagens de satélite foram empregados para gerar mapas

espaço-temporais referentes a paisagens de terrenos em instantes futuros. Os resultados promissores obtidos por esses autores motivaram o desenvolvimento do modelo aqui proposto, o qual é inspirado na metodologia desenvolvida por Centeno e Selleron (2001, 2002). O modelo apresentado nesta dissertação procurou aprimorar o método de modelagem e de predição espaço-temporal, empregando técnicas baseadas em sistemas *fuzzy* de forma mais abrangente e aliadas a técnicas evolutivas como algoritmos genéticos e programação genética.

Assim, buscou-se gerar informações que possam servir de subsídio para que gestores e especialistas ambientais tomem decisões referentes à utilização dos recursos disponíveis para preservação do meio ambiente.

1.2 OBJETIVOS

Os principais objetivos desta dissertação são:

- Apresentar uma abordagem alternativa para efetuar predição espaço-temporal da evolução da paisagem em áreas florestais;
- Propor um método de predição mais interpretável do ponto de vista de um operador humano, através do uso de variáveis lingüísticas e de um sistema de inferência *fuzzy*;
- Empregar técnicas evolutivas como algoritmos genéticos e programação genética, dando origem a um sistema híbrido, a fim de automatizar algumas etapas de geração do modelo;
- Empregar programação genética para realização de um cálculo de regressão como forma de explorar a não-linearidade dos dados analisados.
- Utilizar um algoritmo genético (AG) para a criação de uma base de dados *fuzzy* auto-adaptável. O AG deve possibilitar a definição de partições suaves e não-uniformes, respeitando a interpretabilidade dos dados e a tendência de evolução de cada região analisada.

1.3 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está organizada em seis capítulos:

- Após a introdução apresentada neste capítulo, os Capítulos 2 e 3 trazem a fundamentação teórica deste trabalho, onde vários conceitos necessários à compreensão da proposta são revisados. Além disso, o Capítulo 3 faz uma revisão da literatura sobre os trabalhos já desenvolvidos com o intuito de realizar predição espaço-temporal.
- O Capítulo 4 descreve em detalhes o desenvolvimento da proposta.
- No Capítulo 5 ilustram-se os resultados obtidos. São apresentadas as imagens digitais utilizadas para simulação, e os respectivos mapas temporais preditos obtidos por meio da metodologia proposta.
- O Capítulo 6, por fim, apresenta a discussão geral dos resultados, as conclusões do trabalho e propostas de trabalhos futuros.

CAPÍTULO 2

INTELIGÊNCIA COMPUTACIONAL

A solução de problemas práticos requer muitas vezes a construção de sistemas híbridos, capazes de integrar coerentemente técnicas e metodologias originárias de diferentes linhas de pesquisa (DELGADO, 2002). A Inteligência Computacional (IC) é uma área de pesquisa que engloba três diferentes ramos (ENGELBRECHT, 2002): Computação Evolutiva, Redes Neurais e Sistemas *Fuzzy*, e se apresenta como uma alternativa promissora para a obtenção de sistemas computacionais híbridos. Os diferentes paradigmas que formam a IC permitem, através de sistemas *fuzzy* por exemplo, a representação do conhecimento por meio de uma base de regras, ou ainda a simulação simplificada da capacidade de raciocínio e aprendizado do ser humano em ambientes caracterizados por incerteza e imprecisão. Utilizando técnicas da IC é possível também explorar a capacidade de aprendizado e adaptação associada às redes neurais, e por fim a obtenção de soluções através de métodos de busca presentes em algoritmos baseados em computação evolutiva. Este capítulo apresenta os principais conceitos relacionados à Computação Evolutiva e Sistemas *Fuzzy*, que correspondem às técnicas de Inteligência Computacional empregadas neste trabalho.

2.1 SISTEMAS FUZZY

A utilização de conjuntos *fuzzy* para lidar com conceitos inexatos foi primeiramente introduzida por Zadeh em 1965. A tradução do termo *fuzzy* para português não é consensual, por isso termos diversos, como nebuloso ou difuso são empregados para definir esta teoria em um contexto lógico. Neste trabalho optou-se por utilizar o termo *Fuzzy*, original do inglês.

A motivação de Zadeh (1965, 1975, 1983) baseou-se no fato de que muitas classes de objetos existentes no mundo físico não apresentam critérios de pertinência definidos com precisão. Alguns exemplos destas classes de objetos são “temperatura alta”, “declive elevado” e mesmo os conceitos de “floresta” ou “cidade”. Para este tipo de situações, a lógica clássica (definida inicialmente por Aristóteles, é a ciência dos princípios formais e

normativos do raciocínio) é demasiado rígida, não permitindo a existência de uma transição gradual entre a pertinência completa e a não pertinência.

De um modo geral, a teoria dos sistemas *fuzzy* permite lidar com conceitos imprecisos dependentes da intuição e avaliação humanas, e tem sido aplicada com sucesso em muitas áreas, tais como classificação de padrões, controle industrial, processamento de imagens, sistemas de informação ou instrumentação médica (FONTE, 2003).

A seguir serão apresentados alguns conceitos fundamentais para o entendimento e utilização dos sistemas *fuzzy*.

2.1.1 Conjuntos *Fuzzy*

Na teoria clássica de conjuntos (*crisp sets*), a cada conjunto A está associada uma função característica $c(x)$, definida no universo X , e que pode apenas tomar os valores zero ou um, sendo

$$c(x) = \begin{cases} 0 & \text{se } x \notin A \\ 1 & \text{se } x \in A \end{cases} \quad (1)$$

Na teoria dos conjuntos *fuzzy* é feita uma generalização da função característica, dando origem a uma função de pertinência, que determina com que grau um objeto x pertence a um conjunto A no universo em questão (FONTE, 2003). Nestas condições, seja X um conjunto de objetos representando o universo, então um conjunto A é definido por um conjunto de pares ordenados de um elemento genérico x e sua função de pertinência $\mu_A(x)$. Esta relação pode ser formalizada através da equação 2.

$$A = \{(x, \mu_A(x)) \mid x \in X\}. \quad (2)$$

Ao contrário dos conjuntos clássicos, na teoria dos conjuntos *fuzzy*, a transição entre pertencer e não pertencer a um determinado conjunto é gradual. O conjunto *fuzzy* pode ser entendido como uma espécie de predicado lógico (condição) cujos valores percorrem o intervalo $[0, 1]$.

Como exemplo, considere o conjunto universo $X=[0, 140]$ que representa idades distintas de seres humanos, e os seguintes conjuntos *fuzzy*: $A=\{Jovem\}$, $B=\{Adulto\}$ $C=\{Idoso\}$. A Figura 1 ilustra a partição do universo X , e a atribuição dos graus de pertinência de acordo com a idade das pessoas.

Conforme apresentado na Figura 1, cada idade pode pertencer a mais de um conjunto ao mesmo tempo. Assim, os conjuntos *fuzzy* A , B e C podem ser definidos como

uma coleção de objetos com valores de pertinência variando entre 0 (exclusão completa) e 1 (pertinência completa).

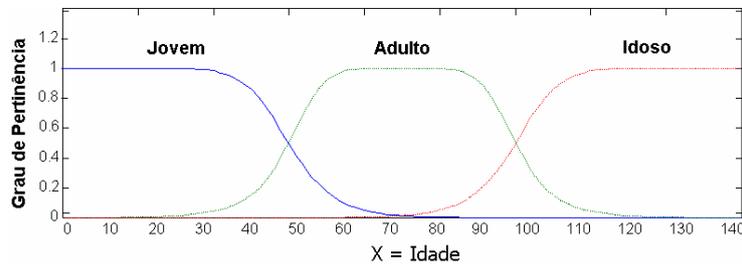


Figura 1: Exemplo de graus de pertinência em conjuntos *fuzzy*.

O conceito de função de pertinência será discutido mais detalhadamente na seção a seguir.

2.1.2 Funções de Pertinência

O conceito de pertinência representa a base de toda a teoria de conjuntos. Os conjuntos clássicos podem ser vistos como um caso particular dos conjuntos *fuzzy*, no qual apenas os limites do intervalo são utilizados na definição da função de pertinência: $\mu_A(x) \in \{0,1\}$, $x \in X$.

Por exemplo, considere o universo contínuo $X \in \mathbb{R}$, onde se pretende identificar os graus de pertinência de cada número próximo ao número 5. Sendo $X = \{1,2,3,4,5,6,7,8,9\}$ e $A = \{(1, 0), (2, 0.4), (3, 0.6), (4, 0.8), (5, 1), (6, 0.8), (7, 0.6), (8, 0.4), (9, 0)\}$, o grau de pertinência para cada x ao conjunto A pode ser expresso de forma diferente dependendo da definição da função de pertinência associada.

- Na concepção clássica:

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq 4.5 \\ 1 & \text{se } 4.5 < x \leq 5.5 \\ 0 & \text{se } x > 5.5 \end{cases} \quad (3)$$

- Na concepção dos conjuntos *fuzzy*:

2.1.3 Definições Básicas em Conjuntos *Fuzzy*

Além da função de pertinência, existem outros elementos que podem ser utilizados para caracterizar conjuntos *fuzzy*. Por exemplo:

- Suporte (S_A): conjunto dos elementos do universo cujos graus de pertinência são maiores que zero: $S_A = \{x \mid \mu_A(x) > 0\}$.
- Núcleo (*core*)(N_A): conjunto dos elementos do universo com grau de pertinência igual a 1: $N_A = \{x \mid \mu_A(x) = 1\}$.
- Altura (H_A): valor máximo da função de pertinência para os elementos do universo pertencentes ao conjunto: $H_A = \sup\{\mu_A(x)\}$.
- α -corte: é o conjunto dos elementos do universo para os quais os graus de pertinência são superiores ou iguais a α : $C_{\alpha A} = \{x \mid \mu_A(x) \geq \alpha\}$.

A Figura 3 ilustra alguns dos conceitos citados.

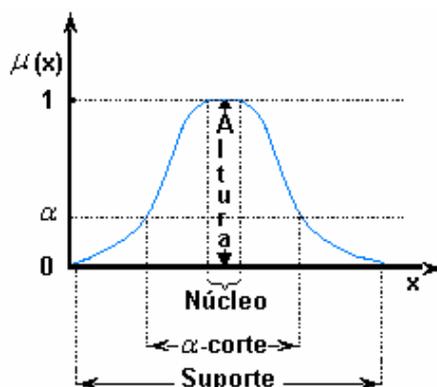


Figura 3: Representação dos conceitos de Núcleo, Altura, α -Corte e Suporte dos conjuntos *fuzzy*.

Um conjunto *fuzzy*, pode ser classificado como conjunto normal quando sua altura é igual a 1, ou seja, $H_A = 1$. Do contrário o conjunto é chamado de subnormal, e seu núcleo (*core*) é um conjunto vazio.

2.1.4 Operações com Conjuntos *Fuzzy*

Similarmente às operações nos conjuntos clássicos, pode-se proceder algumas operações nos conjuntos *fuzzy*, como interseção, união, negação, entre outras.

A) Operações de União, Intersecção e Complemento

Para definição das operações de união, intersecção e complemento, Zadeh (1965) utilizou as funções de máximo e de mínimo, representando-as como funções de pertinência para os conjuntos *fuzzy*.

Considere os conjuntos *fuzzy* A e B , definidos no universo X . As funções de pertinência relativas à união, intersecção e complemento destes conjuntos são apresentadas na Tabela 1.

Tabela 1: Operações de União, Intersecção e Complemento.

União	$\mu_{(A \cup B)}(x) = \max[\mu_A(x), \mu_B(x)] = \mu_A(x) \vee \mu_B(x)$
Intersecção	$\mu_{(A \cap B)}(x) = \min[\mu_A(x), \mu_B(x)] = \mu_A(x) \wedge \mu_B(x)$
Complemento	$\mu_{(A^c)}(x) = 1 - \mu_A(x)$

Devido ao isomorfismo entre a teoria dos conjuntos e a lógica proposicional bivalores (lógica clássica), a intersecção e a união podem ser identificadas pela conjunção (E) e pela disjunção (OU), respectivamente (PEDRYCZ e GOMIDE, 1998).

A Figura 4 ilustra as operações de união, complemento e intersecção, respectivamente, entre conjuntos que representam variação de temperatura.

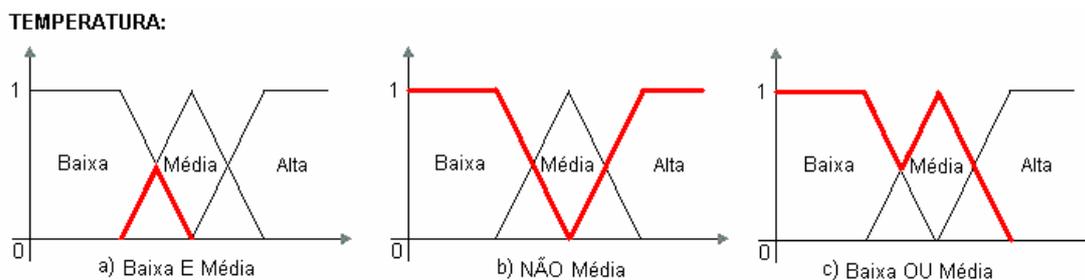


Figura 4: Operações aplicadas aos conjuntos representativos de Temperatura “Baixa” e “Média”. a) Intersecção dos conjuntos Baixa e Média; b) Complemento do conjunto Média; c) União dos conjuntos Baixa e Média.

B) Normas e Co-normas Triangulares

As normas (normas-t) e co-normas (normas-s ou t-conormas) triangulares formam uma classe geral de operadores de união e intersecção, que possui a característica de operar conjuntos em universos distintos (KLEMENT, MESIAR e PAT, 2000).

Esta classe de operadores, dividida em normas-t e normas-s, são formadas por operadores de dois argumentos t ou s : $[0,1]^2 \rightarrow [0,1]$ que satisfazem as condições apresentadas na Tabela 2.

Tabela 2: Condições para normas-t e normas-s.

	Normas-t	Normas-s
Comutatividade	$a \ t \ b = b \ t \ a$;	$a \ s \ b = b \ s \ a$;
Associatividade	$a \ t \ (b \ t \ c) = (a \ t \ b) \ t \ c$;	$a \ s \ (b \ s \ c) = (a \ s \ b) \ s \ c$;
Monotonicidade	Se $a \leq b$ e $c \leq d$ então, $a \ t \ c \leq b \ t \ d$;	se $a \leq b$ e $c \leq d$ então, $a \ s \ c \leq b \ s \ d$;
Condições de Contorno	$0 \ t \ a = 0$; $1 \ t \ a = a$;	$0 \ s \ a = a$; $1 \ s \ a = 1$;

As normas mais comumente utilizadas são apresentadas na Tabela 3.

Tabela 3: Principais Normas-t e Normas-s.

Norma-t	Norma-s	Nome
$\min(a,b)$	$\max(a,b)$	Zadeh
$a \cdot b$	$a + b - ab$	Probabilista
$\max(a + b - 1, 0)$	$\min(a + b, 1)$	Lukasiewicz
$\begin{cases} a, & \text{se } b = 1 \\ b, & \text{se } a = 1 \\ 0, & \text{senão} \end{cases}$	$\begin{cases} a, & \text{se } b = 0 \\ b, & \text{se } a = 0 \\ 1, & \text{senão} \end{cases}$	Weber

As Figuras 5 e 6 apresentam exemplos das normas citadas na Tabela 3.

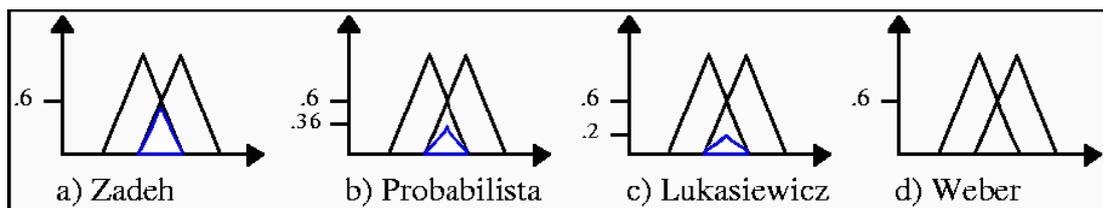


Figura 5: Ilustração das principais Normas-t.

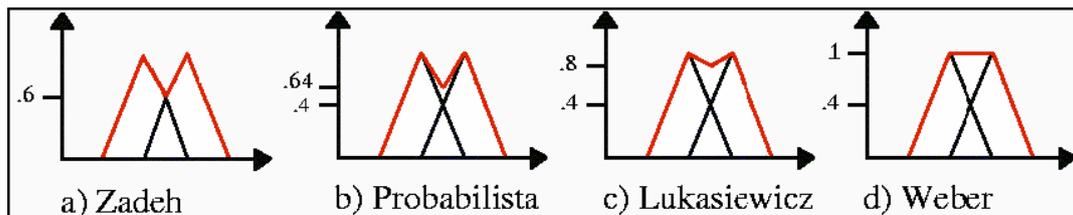


Figura 6: Ilustração das principais Normas-s.

2.1.5 Relações Fuzzy

Considerada uma generalização das relações tradicionais, a relação *fuzzy* representa um conjunto *fuzzy* associando cada elemento do produto cartesiano ou par (x,y) por exemplo, a um grau de pertinência definido no intervalo unitário $[0; 1]$.

Por exemplo, considerando dois universos X e Y quaisquer, uma relação *fuzzy* R vista como uma generalização do produto cartesiano clássico $X \times Y \rightarrow \{0,1\}$. Esta relação *fuzzy* é dada por: $R = \{(x,y), \mu_R(x,y) \mid (x,y) \in X \times Y\}$.

A Figura 7 a seguir apresenta um exemplo de relação *fuzzy* discreta, representada na forma matricial, onde o grau de pertinência é representado como conteúdo da matriz. Neste exemplo, considere $X = \{José, Pedro\}$, $Y = \{Fulano, Ciclano, Beltrano\}$ e a relação *fuzzy* representando a semelhança física entre membros de X e Y . A relação *fuzzy* neste caso pode ser representada por: $Semelhança = 0,7/(José, Fulano) + 0,5/(José, Ciclano) + 0,9/(José, Beltrano) + 0,3/(Pedro, Fulano) + 0,8/(Pedro, Ciclano) + 0,4/(Pedro, Beltrano)$.

	y1	y2	y3
	Fulano	Ciclano	Beltrano
x1 = José	0,7	0,5	0,9
x2 = Pedro	0,3	0,8	0,4

Figura 7: Exemplo de Relação Fuzzy no formato matricial.

No trabalho desenvolvido, as relações *fuzzy* são consideradas no formato matricial, e representam diferentes imagens no contexto das aplicações. O conteúdo das células da matriz representa a pertinência de cada *pixel* da imagem a uma determinada tendência de evolução. São geradas relações *fuzzy* que representam a tendência de cada *pixel* à progressão (variação da cor do *pixel* de tons claros para escuros) ou à regressão (variação da cor do *pixel* de tons escuros para claros). Mais detalhes da geração destas relações *fuzzy* serão apresentados no Capítulo 4.

As relações *fuzzy* definidas em produtos cartesianos idênticos (mesmo domínio) podem ser combinadas através de operadores de União, Intersecção e Complemento. Considerando R_1 e R_2 relações *fuzzy* em $X \times Y$, têm-se as equações apresentadas na Tabela 4.

Tabela 4: Operações de União, Intersecção e Complemento em Relações *Fuzzy*.

União	$\mu_{(R_1 \cup R_2)}(x, y) = \mu_{R_1}(x, y) \ s \ \mu_{R_2}(x, y)$
Intersecção	$\mu_{(R_1 \cap R_2)}(x, y) = \mu_{R_1}(x, y) \ t \ \mu_{R_2}(x, y)$
Complemento	$\mu_{\overline{(R_1)}}(x, y) = 1 - \mu_{R_1}(x, y)$

Já as relações *fuzzy* definidas em espaços distintos, podem ser combinadas utilizando-se diferentes operadores de composição, sendo os mais comuns dados por:

- **Composição *sup-t*.** As mais conhecidas são as que utilizam o *min* e o produto algébrico como normas-t, sendo denominadas de composição *max-min* e *max-prod*, respectivamente. A relação $R=G \circ W$ é obtida através da seguinte equação: $\mu_R(x, y) = \sup_{z \in Z} [\mu_G(x, z) \ t \ \mu_W(z, y)]$.
- **Composição *inf-s*.** A mais conhecida é a composição *min-max*. A relação $R=G \bullet W$ é obtida através da seguinte equação: $\mu_R(x, y) = \inf_{z \in Z} [\mu_G(x, z) \ s \ \mu_W(z, y)]$.

2.1.6 Raciocínio Aproximado

A interpretação das regras *fuzzy* como relações *fuzzy* apropriadas, permite a investigação de diferentes esquemas de raciocínio *fuzzy* (raciocínio aproximado) (PEDRYCZ e GOMIDE, 1998). O raciocínio *fuzzy* corresponde a uma metodologia de inferência que utiliza conceitos e ferramentas da lógica *fuzzy* para chegar a uma conclusão partindo-se de uma dada premissa. Desta forma, de posse de um conjunto de regras de proposições e conclusões (chamadas de regras lingüísticas), combinadas por operadores *fuzzy*, pode-se inferir um conjunto *fuzzy*, do qual é possível extrair um valor numérico que representa o resultado final da análise.

Nesta seção, serão apresentados os conceitos de variáveis lingüísticas e regras de inferência, que permitem a ligação entre as regras *fuzzy* e o raciocínio aproximado.

A) Variáveis Lingüísticas

Uma variável lingüística é uma variável cujos valores são rótulos (*labels*) da linguagem humana. As variáveis lingüísticas *fuzzy* são definidas através de conjuntos *fuzzy* (ZADEH, 1975, 1983). Por exemplo, a temperatura de um dado processo poderia ser uma

variável *fuzzy* assumindo os valores “baixa”, “média”, “alta”, etc. Generalizando, a principal função das variáveis lingüísticas é fornecer uma maneira sistemática para uma caracterização aproximada de fenômenos complexos ou mal definidos. Normalmente, quem quantifica e descreve as variáveis lingüísticas é o especialista.

O conceito de variáveis lingüísticas foi proposto por Zadeh (1975) como uma abordagem alternativa à modelagem do pensamento humano para o tratamento de sistemas complexos. Para Zadeh (1975), uma variável lingüística é dada por uma quintupla: $\langle X, \mathcal{X}, \zeta, M \rangle$,

onde,

X : Nome da variável lingüística;

$\tau(X)$: Conjunto de termos lingüísticos;

\mathcal{X} : Universo de discurso da variável lingüística X ;

ζ : Gramática para geração dos termos ou rótulos;

M : Regra semântica que associa a cada valor lingüístico uma função de pertinência para cada elemento do conjunto de termos.

Para ilustrar, considere a variável lingüística temperatura ($X = \text{temperatura}$), com universo $\mathcal{X} = [0, 100]$ e variável base $x \in \mathcal{X}$. Os valores da variável *fuzzy* temperatura poderiam ser expressos como:

$$\tau(\text{temperatura}) = \{\text{baixa}, \text{alta}, \text{pouco alta}, \text{muito alta}, \text{não muito alta}\}$$

A gramática define como os termos primários (baixa, alta) serão associados aos modificadores (muito, pouco, não) para formar os nomes dos termos não-primários (pouco alta, muito alta, não muito alta).

O universo das variáveis lingüísticas é dividido em partições *fuzzy*, a fim de definir cada termo lingüístico. Estas partições podem ter formato uniforme (com todos os termos iguais e equidistantes) ou não-uniforme. Quanto mais conjuntos *fuzzy* forem utilizados, mais finas as partições se tornam, e do contrário, mais grossas ou esparsas. O número de termos lingüísticos define a granularidade das partições de cada universo (DELGADO, 2002). A Figura 8 ilustra alguns exemplos de partições *fuzzy*.

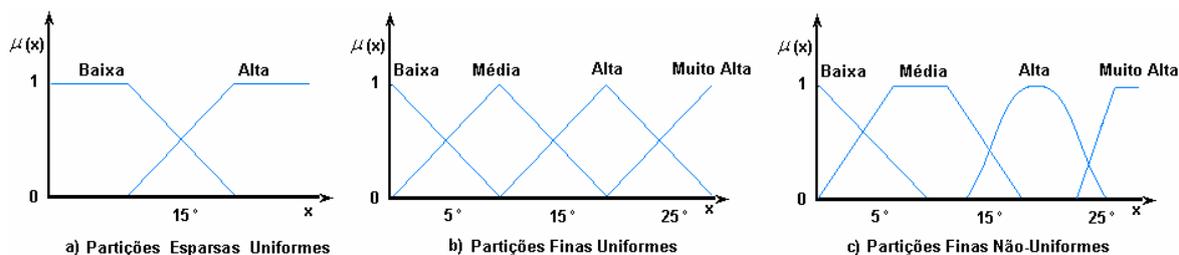


Figura 8: Exemplos de partição do universo *fuzzy*: a) Partições Esparsas Uniformes; b) Partições Finas Uniformes; c) Partições Finas Não-Uniformes.

Muitas vezes as partições *fuzzy* são definidas de forma manual por um especialista. Contudo, conforme levantamento feito por Delgado (2002), existem algumas abordagens automáticas que definem, através de dados de entrada-saída, a melhor (ou pelo menos uma próxima da melhor) partição para a aplicação em questão. Na proposta apresentada aqui, o conjunto de partições pode ser ajustado automaticamente por meio de um algoritmo genético.

B) Regras *Fuzzy*

Também conhecidas como implicações *fuzzy* ou declarações condicionais, as regras *fuzzy* expressam relações entre variáveis linguísticas e conjuntos *fuzzy*, podendo apresentar composições por meio de conectivos e transformadores.

Segundo Delgado (2002), as regras *fuzzy* permitem uma maneira formal de representação de diretivas e estratégias e são muito apropriadas quando o conhecimento do domínio resulta de associações empíricas e experiências do operador humano, ou quando se deseja uma representação linguística do conhecimento adquirido.

Normalmente as regras *fuzzy* assumem a forma “se <antecedente> então <consequente>”. Por exemplo, a expressão “Se X é Alto, então Y é baixo” é um exemplo de uma regra *fuzzy* simples que relaciona as variáveis linguísticas X e Y, combinando os conjuntos *fuzzy* associados aos termos linguísticos “Alto” e “Baixo”. Esta declaração condicional *fuzzy* é definida matematicamente pela abreviação $A \rightarrow B$ (onde $A = \text{Alto}$, $B = \text{Baixo}$), representando uma relação *fuzzy* R:

$$R: \text{Se } A \text{ então } B = A \rightarrow B. \quad (5)$$

De uma forma geral, R pode ser descrita por uma função de pertinência, a qual identifica a semântica da regra e pode ser definida no espaço bidimensional como: $\mu_R(x,y) = f(\mu_A(x), \mu_B(y)) = f(a,b)$. Onde $a = \mu_A(x)$ e $b = \mu_B(x)$.

Segundo Pedrycz e Gomide (1998), as relações *fuzzy* induzidas por regras *fuzzy* são derivadas de três classes principais de funções: conjunções, disjunções e implicações *fuzzy*. A seguir serão descritas apenas as conjunções *fuzzy* pois foram estas as escolhidas para a semântica das regras *fuzzy* utilizadas neste trabalho.

- Conjunção *Fuzzy*: Representando a relação $R: A \rightarrow B = A \times B$, a conjunção *fuzzy* corresponde a uma função $f_i: [0,1]^2 \rightarrow [0,1]$ definida por: $f_i(\mu_A(x), \mu_B(y)) = \mu_A(x) \text{ t } \mu_B(y)$.

As normas-t mais comumente utilizadas neste caso são as de Mamdani (MAMDANI e ASSILIAN, 1975) e Larsen (1980) resultando em:

$$\text{a) Regras de Mamdani: } f_m(\mu_A(x), \mu_B(y)) = \mu_A(x) \wedge \mu_B(y). \quad (6)$$

$$\text{b) Regras de Larsen: } f_p(\mu_A(x), \mu_B(y)) = \mu_A(x) \cdot \mu_B(y). \quad (7)$$

Os exemplos apresentados acima, correspondem a regras *fuzzy* com proposições monovariáveis, do tipo “Se X é A então Y é B”. Contudo, é possível trabalhar com regras mais complexas, compostas por proposições multivariáveis através dos seguintes operadores de agregação:

- Conjunção: “Se X_1 é A_1 E X_2 é A_2 E ... X_n é A_n então Y_1 é B_1 E Y_2 é B_2 E ... Y_s é B_s ”.
- Disjunção: “Se X_1 é A_1 OU X_2 é A_2 OU ... X_n é A_n então Y_1 é B_1 OU Y_2 é B_2 OU ... Y_s é B_s ”.

Onde X_1, X_2, \dots, X_n são variáveis lingüísticas do antecedente e Y_1, Y_2, \dots, Y_s variáveis lingüísticas do conseqüente; e A_1, A_2, \dots, A_n e B_1, B_2, \dots, B_s são conjuntos *fuzzy* nos universos X_1, X_2, \dots, X_n e Y_1, Y_2, \dots, Y_s , respectivamente.

C) Inferência de Regras *Fuzzy*

Todo método de raciocínio pode ser definido como um processo de inferência que produz conclusões a partir de um conjunto formado por uma ou mais regras e fatos conhecidos.

Na lógica bi-valores tradicional, o *Modus Ponens* (MP) é a regra básica de inferência utilizada. Contudo, o raciocínio humano é baseado numa aproximação ao *Modus Ponens*, chamada de *Modus Ponens* Generalizado (PEDRYCZ, GOMIDE, 1998). A Tabela 5 apresenta a estrutura básica de cada forma de raciocínio.

Tabela 5: Formas de Raciocínio.

<i>Modus Ponens</i>		<i>Modus Ponens</i> Generalizado	
(Fato)	X é A	(Fato)	X é A'
(Regra)	Se X é A então Y é B	(Regra)	Se X é A então Y é B
(Conclusão)	Y é B.	(Conclusão)	Y é B'.

A inferência de uma única regra *fuzzy* é a continuação da aplicação da composição de uma Relação *Fuzzy*. Por isso se chama regra composicional de inferência.

A inferência composicional da regra diz que perante a regra *fuzzy* citada na Tabela 5, representada pela relação *fuzzy* R , o resultado B' pode ser inferido, sabendo A' , através da composição de A' e R : $B' = A' \circ R = A' \circ (A \rightarrow B)$.

Para que a ICR tenha sentido, a relação *fuzzy* que representa a regra tem que existir, e esta relação pode ser qualquer uma das implicações descritas anteriormente.

No caso de mais de uma regra, o raciocínio *fuzzy* geralmente é realizado sobre um conjunto de m regras *fuzzy* na forma:

$$R_j: \text{Se } X \text{ é } A \text{ então } Y \text{ é } B_j, (j=1\dots m). \quad (8)$$

Cada regra individual R_j pode induzir uma relação *fuzzy* diferente. O conjunto de regras, por sua vez, resulta numa relação *fuzzy* que é obtida pela agregação das relações (ou regras) individuais, ou seja, $R = G_R(R_j) = G_R(A^j \rightarrow B^j)$ (COSTA, 1998).

O operador de agregação G_R é normalmente caracterizado por uma norma- s , mas normas- t e operadores de média também podem ser utilizados.

D) Sistemas de Inferência *Fuzzy*

Considerados uma das mais importantes ferramentas de modelagem baseada na teoria dos conjuntos *fuzzy*, os Sistemas de Inferência *Fuzzy* (SIF) representam uma ponte de ligação entre o processamento simbólico e o numérico.

Segundo Jang, Sun e Mizutani (1997), a estrutura básica de um sistema *fuzzy* possui três componentes conceituais:

- base de regras: define o conjunto de regras *fuzzy*;
- base de dados: define as funções de pertinência usadas nas regras *fuzzy*;
- um mecanismo de raciocínio: realiza um procedimento de inferência (raciocínio *fuzzy*) para obter a saída ou conclusão, baseado nas regras e fatos conhecidos.

A Figura 9 apresenta um modelo de Sistemas de Inferência *Fuzzy*.

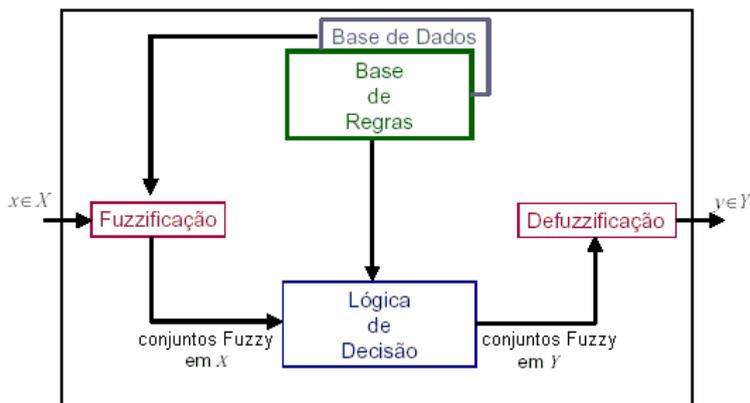


Figura 9: Sistema de Inferência *Fuzzy* (GOMIDE, 2005).

A seguir serão descritos de forma sucinta os processos que ocorrem em um sistema de inferência *fuzzy*.

Fuzzificação

Consideram-se entradas não-*fuzzy*, as entradas numéricas representando os dados resultantes de medições ou observações (conjuntos de dados, por exemplo), que é o caso da maioria das aplicações práticas. Em virtude disto, é necessário efetuar um mapeamento destes dados precisos para os conjuntos *fuzzy* (de entrada) relevantes. Este processo é chamado de *fuzzificação*, e é neste estágio que ocorre também a ativação das regras relevantes para uma dada situação.

Defuzzificação

No estágio de *defuzzificação*, uma vez obtido o conjunto *fuzzy* de saída através do processo de inferência, é efetuada uma interpretação dessa informação. Isto se faz necessário porque em aplicações práticas, geralmente são requeridas saídas numéricas. No caso de um sistema de controle, por exemplo, em que o controle é efetuado por um sistema de inferência *fuzzy* (ou controlador *fuzzy*), este deve fornecer à planta, dados ou sinais numéricos, ao invés de lingüísticos, já que a "apresentação" de um conjunto *fuzzy* à entrada da planta não teria significado algum (TANSHEIT, 2006). Existem vários métodos de *defuzzificação* na literatura. A seguir são apresentados alguns detalhes do método de *defuzzificação* por Centro de Gravidade, que foi o empregado nas bases de regras utilizadas neste trabalho. A Figura 10 ilustra o processo e equações relacionadas ao método.

- Centro de Gravidade (Centro de Massa ou Centróide): A saída é o valor no universo que divide a área sob a curva da função de pertinência em duas

partes iguais, ou seja, seu centro de gravidade. As áreas sobrepostas são contadas apenas uma vez. Neste exemplo, Z é dado por:

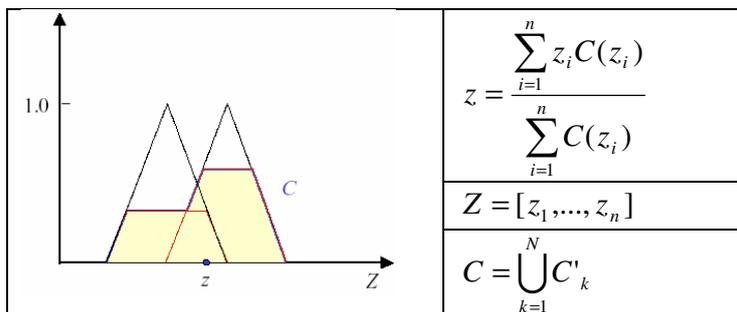


Figura 10: Defuzzificação pelo método Centro de Gravidade, considerando um conjunto fuzzy C , definido no universo Z (GOMIDE, 2005).

Base de Regras

As regras são normalmente fornecidas por especialistas em forma de sentenças lingüísticas, e constituem um aspecto fundamental no desempenho de um sistema de inferência fuzzy. Mas nem sempre estes especialistas estão disponíveis para as aplicações envolvidas. Nestes casos, existem métodos de extração de regras de dados numéricos. (DELGADO, 2002; ESPINOSA e VANDEWALLE, 2000; HOFFMANN e NELLES, 2000; JIN, 2000; SIARRY e GUELY, 1998). Contudo, neste trabalho a base de regras será definida por um especialista e permanecerá fixa ao longo de todo o processamento.

Base de Dados

Na base de dados ficam armazenadas as definições sobre partição e normalização dos universos de discurso, e as definições das funções de pertinência dos termos fuzzy.

Um aspecto importante é a definição das funções de pertinência associadas às variáveis de entrada e às de saída, pois o desempenho do sistema de inferência dependerá do número de conjuntos e de sua forma. Pode-se efetuar uma sintonia "manual" das funções de pertinência dos conjuntos, mas é mais comum empregarem-se métodos automáticos. Neste trabalho, está sendo proposto um mecanismo de definição automática da base de dados baseado em algoritmos genéticos que permite incrementar o nível de autonomia do sistema, conforme detalhado no Capítulo 4.

Lógica de Decisão/Inferência

No estágio de inferência ocorrem as operações com conjuntos fuzzy propriamente ditas: combinação dos antecedentes das regras, implicação e *modus ponens* generalizado.

Este estágio depende portanto da definição dos operadores que realizarão estas tarefas como os operadores de agregação dos antecedentes, semântica das regras, agregação das regras, etc.

E) Modelos de Sistemas *Fuzzy*

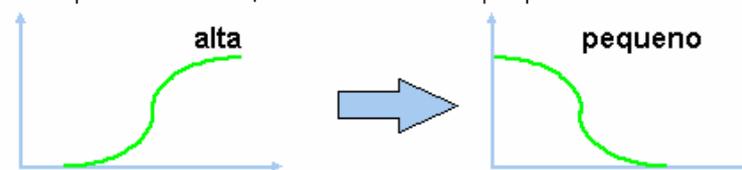
Existem vários modelos de sistemas *fuzzy*, em geral a distinção entre eles ocorre na operação de saída do sistema, ou seja, no conseqüente das regras *fuzzy*. Entre os modelos mais conhecidos destacam-se os listados a seguir, conforme citado em Delgado (2002):

- Modelo de Mamdani (MAMDANI e ASSILIAN, 1975): utiliza conjuntos *fuzzy* também nos conseqüentes das regras *fuzzy*. A saída final é representada por um conjunto *fuzzy* resultante da agregação da saída inferida de cada regra. Para se obter uma saída final não *fuzzy* pode-se aplicar o método de *defuzzificação*.
- Modelo de Takagi-Sugeno (TAKAGI e SUGENO, 1983): o conseqüente é representado por uma função das variáveis de entrada. A saída final é obtida pela média ponderada das saídas inferidas de cada regra. Os coeficientes da ponderação são dados pelos graus de ativação das respectivas regras.

A Figura 11 a seguir apresenta exemplos dos modelos Mamdani e Takagi-Sugeno (também conhecido apenas como Sugeno), a fim de visualizar a diferença entre as saídas de cada modelo.

• Modelo Mamdani

Se a pressão é alta, então o volume é pequeno



• Modelo Takagi-Sugeno

Se a velocidade é média, então a resistência = 5 * velocidade

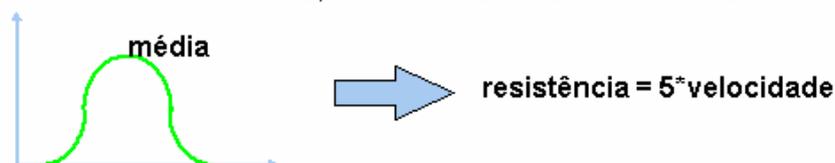


Figura 11: Exemplo dos modelos Mamdani e Takagi-Sugeno.

2.2 COMPUTAÇÃO EVOLUTIVA

Computação Evolutiva (CE) compreende um conjunto de técnicas de busca e otimização inspiradas na evolução natural das espécies (MICHALEWICZ, 1996; DE JONG, 2006). Este capítulo fornece informações sobre a origem, funcionamento e principais componentes dos métodos de otimização baseados em CE empregados neste trabalho.

De acordo com a Teoria da Evolução de Charles Darwin (DARWIN, 1859), o princípio da seleção natural indica que os indivíduos cujas variações se adaptam melhor ao ambiente em que vivem terão maior probabilidade de sobreviver e se reproduzir. Pode-se considerar que os organismos que existem hoje são conseqüências da evolução de outros organismos inferiores que se extinguiram e que sem eles, provavelmente, os organismos atuais não existiriam. A espécie é o beneficiário final do processo evolutivo.

Tomando como base estes conceitos herdados da Biologia, diversas técnicas estão sendo utilizadas para se obter modelos de Inteligência Computacional (IC). As técnicas mais utilizadas são: Programação Evolutiva, Estratégias Evolutivas, Algoritmos Genéticos e Programação Genética (BARRETO, 1997).

Neste trabalho foram empregadas duas técnicas da computação evolutiva: Algoritmos Genéticos (AG) e Programação Genética (PG). Estas duas técnicas compartilham a mesma base teórica, inspirada na competição entre indivíduos pela sobrevivência. A diferença essencial entre AG e PG é que em PG as estruturas manipuladas são um tanto mais complexas, assim como várias das operações realizadas pelo algoritmo.

2.2.1 Origem

A idéia da computação evolutiva foi introduzida nos anos 60 e 70 por Rechenberg (1965, 1973), quando apresentou as chamadas Estratégias Evolutivas (EEs). Em sua concepção original, as EEs podem ser definidas como métodos para otimização de parâmetros com valores reais, propostas com o objetivo de imitar os princípios da evolução natural (variação genética), através de operadores de mutação específicos para produzir pequenas mudanças nestes parâmetros reais (DELGADO, 2002). Schwefel (1981) desenvolveu aprimoramentos posteriores nas EEs, sendo considerado um dos responsáveis pela evolução do método.

Neste mesmo período, Fogel, Owens e Walsh (1966) desenvolveram a Programação Evolutiva (PE), que consiste em uma técnica na qual os candidatos à solução são representados por máquinas de estado finito. Estas máquinas são evoluídas por mutação aleatória de seus diagramas de transição de estado e seleção dos candidatos melhor adaptados.

Também nos anos 60, John Holland, da Universidade de Michigan, começou a definir as bases de algoritmos de otimização de inspiração genética. Seu trabalho culminou na publicação, em 1975, do livro *Adaptation in Natural and Artificial Systems* (Holland, 1975), dando início ao desenvolvimento dos algoritmos genéticos (TANOMARU, 1995).

Ao contrário das EEs e PE, o objetivo inicial dos algoritmos genéticos (AGs) não era a solução de problemas específicos e sim o estudo dos fenômenos de adaptação que ocorrem na natureza. Holland apresentou os AGs como uma abstração da evolução biológica. De seus estudos resultaram não só a possibilidade de simulação dos mecanismos da evolução natural em computadores, mas, principalmente, os fundamentos teóricos do processo de adaptação em AGs, sendo que o operador de recombinação ou *crossover* passou a ter um papel fundamental (DELGADO, 2002).

A representação de programas em árvores e a definição de operadores genéticos foram apresentadas inicialmente por Cramer (1985). Seguindo esta linha de raciocínio, e tomando como base os trabalhos de Holland (1975) em Algoritmos Genéticos (AG), Koza (1989; 1992) introduziu o conceito de programação genética (PG) utilizando-a como meio de conduzir a pesquisa por programas no espaço de soluções.

Em Koza (1994), a PG é aplicada para prover escalabilidade e reuso de programas. Em Koza et al. (1999), são apresentadas resoluções de problemas utilizando PG, e em Koza et al. (2003), a PG é empregada com o objetivo de obter soluções comparáveis a soluções humanas.

Conceitualmente, a Programação Genética representa uma abordagem para a geração automática de programas de computador. Ela pode ser vista como uma extensão dos algoritmos genéticos no domínio dos programas, representando um método sistemático para tornar os computadores aptos a resolver problemas. Entretanto, neste trabalho a PG será empregada para gerar automaticamente expressões simbólicas que serão utilizadas na predição do tamanho de florestas (número de *pixels* pretos na imagem binária final).

A Programação Genética se baseia na combinação de idéias da teoria da evolução (seleção natural), genética (reprodução, cruzamento e mutação), inteligência artificial

(busca heurística) e teoria de compiladores (representação de programas como árvores sintáticas) (KOZA, 1992).

2.2.2 Funcionamento dos algoritmos evolutivos

Segundo Koza (1992), o processo evolutivo ocorre na natureza quando quatro condições básicas são satisfeitas:

- Um indivíduo tem a habilidade de se reproduzir;
- Existe uma população desses indivíduos;
- Existe alguma variedade entre esses indivíduos;
- A variedade influencia de alguma forma na capacidade de sobrevivência dos indivíduos.

O processo de seleção natural que ocorre na natureza pode ser simulado no mundo computacional através de algoritmos evolutivos, onde ao invés de uma população de seres vivos, tem-se uma população de possíveis soluções para um determinado problema.

Tanto em algoritmos genéticos quanto em programação genética, através da evolução da população, pode-se chegar ao indivíduo que apresenta a melhor solução ou pelo menos uma boa aproximação da resolução do problema. Para isso, começa-se com uma população inicial aleatória ou pré-determinada. Os indivíduos da população são avaliados por algum critério que indica o grau de aptidão (*fitness*) de cada um deles ao modelo. Os indivíduos com melhor grau de aptidão são selecionados e modificados através de operadores genéticos, a fim de gerar novos indivíduos para formação de uma nova população, simulando o processo evolutivo que ocorre na natureza. Em seguida, descarta-se a população original e repete-se o ciclo com esta nova população. Cada ciclo é chamado de geração e se repete até que um determinado critério de término seja satisfeito.

A estrutura básica de um algoritmo evolutivo é apresentada na Figura 12. Esta estrutura vale tanto para algoritmos genéticos quanto para programação genética.

2.2.3 Representação dos indivíduos

Algoritmos Genéticos

Em geral, os AGs trabalham sobre uma representação das possíveis soluções. Os indivíduos que compõem a população de um algoritmo genético podem ser representados através de diferentes formas de codificação (genótipo).

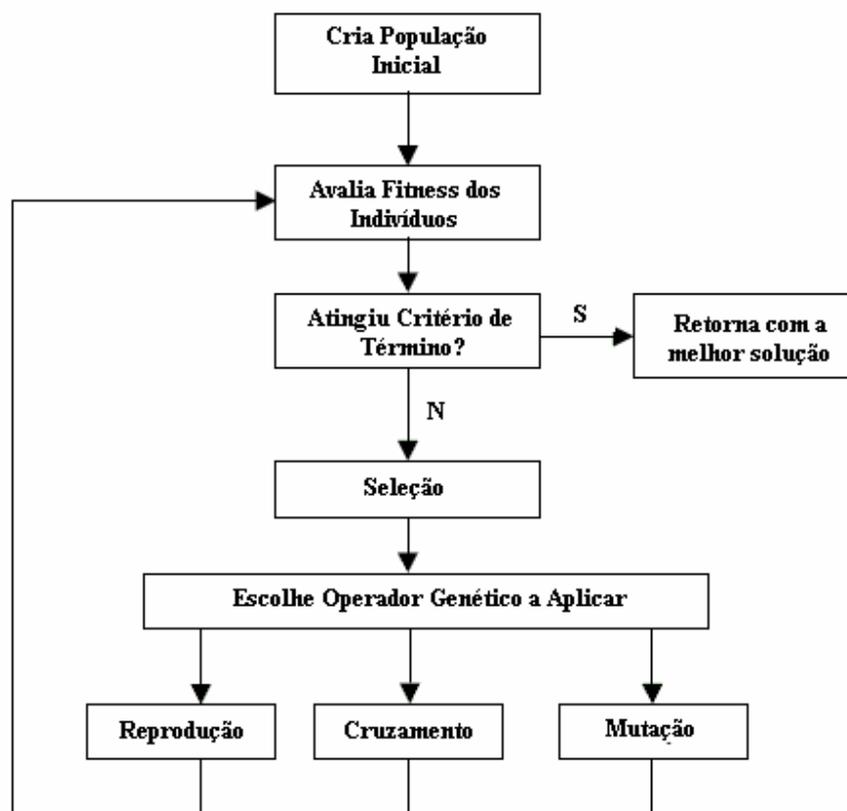


Figura 12: Estrutura de um algoritmo de PG.

A codificação binária foi a proposta original do trabalho de Holland (1975). Nesta forma de representação, os valores que compõem o cromossomo pertencem ao conjunto $\{0,1\}$, onde cada característica do indivíduo corresponde a uma seqüência de bits e o indivíduo a uma concatenação das seqüências de bits de todas as suas características. Outras variações de codificações binárias podem ser encontradas em Holland (1975) e Caruana e Schaffer (1988). Entretanto, segundo Michalewicz (1996) a codificação binária além de restringir o universo de aplicação, pode levar a um desempenho ruim em problemas de otimização numérica.

As propostas mais recentes adotam populações de indivíduos representados por estruturas de dados mais flexíveis, nas quais cada componente pode assumir valores pertencentes a um alfabeto qualquer como letras, códigos, números reais, etc. Alguns exemplos podem ser encontrados em Meyer e Packard (1992) e Kitano (1994).

No algoritmo genético desenvolvido neste trabalho, empregou-se a codificação real, onde cada atributo dos cromossomos é representado por um número real, identificando

os parâmetros das funções de pertinência das partições *fuzzy*. Mais detalhes sobre a codificação empregada serão apresentados no Capítulo 4.

Conforme discutido por Tanomaru (1995), usando algumas das metáforas extremamente simplistas, mas empregadas pelos teóricos e praticantes de AGs com frequência, cada seqüência s corresponde a um cromossomo, e cada elemento de s é equivalente a um gene. Como cada gene pode assumir qualquer valor do alfabeto utilizado, cada elemento do alfabeto é equivalente a um alelo, ou seja, um valor possível para um dado gene. A posição de um gene num cromossomo, ou seja, o índice dentro da seqüência, corresponde a um lócus gênico. A Figura 13 ilustra os conceitos citados acima.

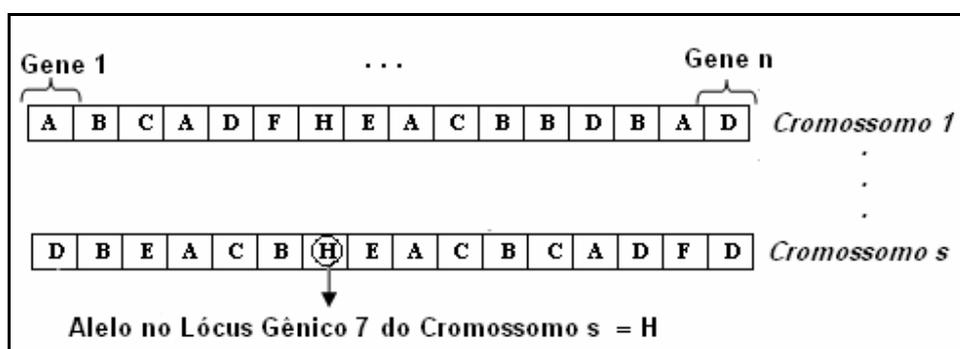


Figura 13: Representação de um cromossomo, com seus genes, alelos e lócus gênico.

Programação Genética

Tradicionalmente, a representação dos indivíduos (programas) em Programação Genética se baseia em árvore de sintaxe abstrata, ao invés de linhas de código. Esta estrutura de dados representa uma árvore de programas semelhante às utilizadas em muitos ambientes de programação e editores baseados em estruturas.

Em PG, a estrutura da árvore é formada pela livre combinação de funções (vértices internos da árvore) e terminais (vértices externos da árvore) adequados ao domínio do problema. Cada função é um ramo (também chamada de nó) e cada terminal uma folha do indivíduo. As funções caracterizam-se por trabalhar com pelo menos um argumento (variável ou constante), e os terminais por representarem variáveis, constantes ou funções que não necessitam de argumentos.

A Figura 14 apresenta um exemplo de indivíduo em PG destacando seus ramos e folhas.

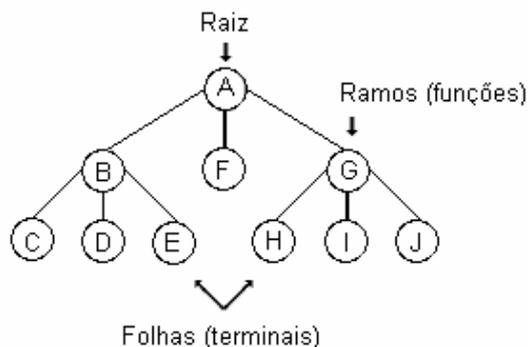


Figura 14: Exemplo de indivíduo em Programação Genética.

Para compor um indivíduo, parte-se de dois conjuntos: F como o conjunto de funções e T como o conjunto de terminais. O conjunto F pode conter operadores aritméticos (+, -, *, etc.), funções matemáticas (seno, log, exp, etc.), operadores lógicos (E, OU etc.) dentre outros. Cada $f \in F$ tem associada uma aridade¹ superior a zero. O conjunto T é composto pelas variáveis, constantes e funções de aridade zero (i.e., funções sem argumentos) (KOZA, 1992).

Desta forma, o espaço de busca é determinado por todas as árvores que puderem ser criadas pela livre combinação de elementos dos conjuntos F e T .

Como exemplo, considere um conjunto $F = \{+, -, *, /\}$ e um conjunto $T = \{x, 5\}$. A partir da combinação dos elementos destes dois conjuntos, pode-se produzir expressões matemáticas diversas, como $(5*(x+(x*x)))$ ou $(5/(x+x))$. Estas duas expressões matemáticas podem ser representadas em formato de árvore de sintaxe conforme apresentado na Figura 15.

Para garantir a viabilidade das árvores de sintaxe abstrata, Koza (1992) definiu a propriedade de fechamento (*closure*). Para satisfazê-la, cada função pertencente ao conjunto de funções deve aceitar como argumentos, qualquer valor e tipo de dado que possa ser retornado por qualquer função ou terminal. O atendimento a esta propriedade permite que o cruzamento efetuado entre dois nós quaisquer da árvore de derivação produza indivíduos sintaticamente corretos.

¹ A aridade é responsável por definir o número n de argumentos de uma função ou expressão.

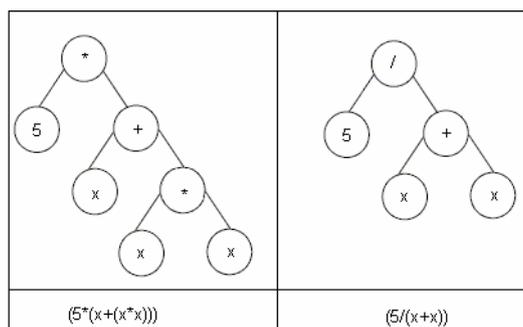


Figura 15: Expressões matemáticas em formato de árvore de sintaxe.

Um exemplo típico de problema de fechamento é a operação de divisão. Afinal, matematicamente não é possível dividir um valor por zero. Para contornar este problema, pode-se utilizar uma função alternativa proposta por Koza (1992): a função de divisão protegida (*protected division*) `%`. Esta função recebe dois argumentos e retorna o valor 1 (um) caso seja feita uma divisão por zero e, caso contrário, retorna o quociente da divisão entre os dois argumentos.

A fim de garantir a convergência para uma solução, Koza (1992) definiu a propriedade de suficiência (*sufficiency*), onde o conjunto de funções (operações) e o conjunto de terminais (variáveis e constantes) devem ser capazes de representar uma solução para o problema. Isto implica na existência de uma forte evidência de que alguma composição das funções e terminais fornecidos para utilização no algoritmo, possam produzir uma solução adequada ao problema em questão. Por exemplo, se o objetivo de um algoritmo de PG é encontrar uma equação que represente determinada curva, dificilmente a utilização de indivíduos que representam funções polinomiais de grau 1 poderão convergir para uma boa solução. Dependendo do problema, esta propriedade pode ser óbvia ou exigir algum conhecimento prévio de como deverá ser a solução (KOZA, 1992). Portanto, o usuário deve saber a priori que a composição de funções e terminais por ele fornecida induz à solução do problema.

2.2.4 População Inicial

A população inicial de um algoritmo evolutivo deve ser uma amostra significativa do espaço de busca, contendo diversidade suficiente de composição nos indivíduos para que o algoritmo possa, através da recombinação de códigos (características), convergir para uma solução.

Nos algoritmos genéticos em geral, a inicialização da população é feita de maneira aleatória. A geração inicial representa normalmente uma “busca cega” pela solução (KOZA, 1992). Entretanto, algum conhecimento disponível pode ser utilizado na geração da população inicial para, por exemplo, gerar somente indivíduos válidos (em problemas envolvendo restrições), ou para gerar alguns indivíduos com características que os aproximem da solução desejada (DELGADO, 2002).

No caso de um algoritmo de programação genética, a população inicial é em geral composta por árvores geradas aleatoriamente a partir de conjuntos de funções (F) e de terminais (T). Usualmente se especifica um limite máximo para a profundidade da árvore para se evitar árvores muito grandes (KOZA, 1992). Vale ressaltar que a profundidade de um nó n em uma árvore é o comprimento do caminho da raiz até n , e que a profundidade de uma árvore é a mesma do seu nó de maior profundidade (TERADA, 1991).

Diversos métodos já foram desenvolvidos com o objetivo de melhorar a qualidade dos programas que irão compor a população inicial dos algoritmos de PG. Conforme apresentado em Luke (2001), os métodos mais comuns são: *Ramped-half-and-half* (KOZA, 1992), *Random-branch* (CHELLAPILLA, 1997), *Uniform* (BOHM e GEYER-SCHULZ, 1996) e, mais recentemente, *Probabilistic tree-creation* (LUKE, 2000). A seguir são apresentadas as principais características do método *Ramped-half-and-half*, empregado neste trabalho.

Ramped-half-and-half

Desenvolvido por Koza (1992), o *Ramped-half-and-half* corresponde a uma combinação de dois métodos simples: *grow* e *full*. O método *grow* envolve a criação de árvores cuja profundidade é variável. A escolha dos nós é feita aleatoriamente entre funções e terminais, respeitando-se uma profundidade máxima. Já o método *full* envolve a criação de árvores completas, isto é, todas as árvores terão a profundidade máxima. Para isso é feita a seleção de funções para os nós cuja profundidade seja inferior a desejada e a seleção de terminais para os nós de profundidade máxima.

O método *Ramped-half-and-half* consiste em gerar um número igual de árvores para cada profundidade, entre dois e a profundidade máxima. Por exemplo, supondo que a profundidade máxima seja seis, serão geradas árvores com profundidades de dois, três, quatro, cinco e seis equitativamente. Isto significa que 20% terão profundidade dois, 20% terão profundidade três e assim sucessivamente. Para cada profundidade, 50% são geradas pelo método *full* e 50% pelo método *grow* (KOZA, 1992).

2.2.5 Função de Aptidão

Na natureza, os indivíduos que apresentam melhor adaptação ao ambiente em que vivem são os que têm maior probabilidade de evoluir. Da mesma forma, na computação evolutiva cada indivíduo da população possui um valor de aptidão (*fitness*). Este valor é calculado através de uma função que mede quão próximo o indivíduo está da solução desejada ou quão boa é a solução que ele representa.

É essencial que esta função seja muito representativa e diferencie na proporção correta as más soluções das boas. Se houver pouca precisão na avaliação, uma ótima solução pode ser posta de lado durante a execução do algoritmo, além de gastar mais tempo explorando soluções pouco promissoras (KOZA, 1992).

Usualmente, o valor de *fitness* é obtido com base em um conjunto de casos de treinamento, denominados *fitness cases*, contendo valores de entrada e saída a serem aprendidos. Cada indivíduo da população trabalha com valores de entrada para chegar a um resultado, que é confrontado com o valor esperado de saída. Quanto mais próximo o resultado apresentado pelo indivíduo estiver do valor de saída, melhor é a solução que ele representa, e conseqüentemente, melhor sua aptidão e tendência à evolução.

Segundo Banzhaf et al. (1998), a avaliação de *fitness* estabelece uma forma de diferenciar os melhores indivíduos dos piores, servindo como a força mestre do processo evolutivo. Ela representa a medida (usada durante a evolução) de quanto o indivíduo aprendeu a prever as saídas dentro de um domínio de aprendizagem.

Um dos métodos de avaliação de *fitness* mais comumente utilizados corresponde ao cálculo da aptidão nata (*raw fitness*) (KOZA, 1992). Este método representa a avaliação pura e simples do indivíduo frente aos *fitness cases*. O método mais comum de aptidão nata é a avaliação do erro cometido, isto é, a soma de todas as diferenças absolutas entre o resultado obtido pelo indivíduo e o seu valor correto. Neste trabalho foi empregado o método de avaliação de aptidão nata através do cálculo de um erro quadrático médio modificado para o algoritmo de PG, e no caso do algoritmo genético, a aptidão nata é empregada através do cálculo de um nível de similaridade identificado entre a imagem resultante da predição e a imagem real registrada no mesmo instante temporal.

2.2.6 Métodos de Seleção

O método de seleção é responsável por escolher quais indivíduos da população irão gerar descendentes, e quantos serão. O objetivo da seleção é privilegiar, em média, os indivíduos melhor adaptados, na esperança de que seus descendentes tenham desempenho ainda melhor. A seleção deve ser tal que produza um balanço adequado entre a pressão seletiva e a variação introduzida pelos operadores genéticos (MITCHELL, 1996).

Métodos de seleção muito fortes tendem a gerar super-indivíduos (indivíduos com medida de desempenho muito superior aos demais), reduzindo a diversidade necessária para alterações e progressos futuros. A geração de super-indivíduos pode levar a uma convergência prematura do processo evolutivo. Por outro lado, métodos de seleção excessivamente fracos (pouca pressão seletiva) tendem a produzir progressos muito lentos na evolução (MICHALEWICZ, 1996).

A seguir, serão descritos os métodos de seleção por torneio e elitismo, os quais serão empregados neste trabalho.

1) Seleção por Torneio (*tournament selection*): Apresentada por Goldberg e Deb (1991) para Algoritmos Genéticos, foi utilizada em vários problemas por Koza (1994) no seu segundo livro. A seleção por torneio pode ser feita da seguinte forma: t indivíduos são selecionados aleatoriamente da população e o melhor deste grupo é o escolhido; este processo é repetido até que se tenha uma nova população; o valor de t é conhecido como o tamanho do torneio. No esquema apresentado acima, a escolha entre os candidatos é determinística, entre uma porcentagem da população. Contudo, existem algumas variações deste algoritmo, em que o retorno da seleção corresponde ao melhor e pior indivíduo do grupo. O método de seleção por torneio é empregado neste trabalho no algoritmo de PG e no algoritmo genético desenvolvidos.

2) Elitismo

O termo elitismo foi introduzido por De Jong (1975), e está associado à adoção de uma operação adicional junto aos métodos de seleção, que força o algoritmo a reter o melhor indivíduo ou um número de melhores indivíduos, a cada geração. O elitismo melhora o desempenho de algoritmos genéticos na maioria dos casos (MITCHELL, 1996), e seguindo a mesma lógica, pode apresentar ganhos também quando aplicado à programação genética. O uso de estratégias elitistas permite manter na população os

melhores indivíduos, pois estes poderiam ser perdidos se não fossem selecionados de forma determinística para compor a próxima geração, ou então se fossem modificados por *crossover* ou mutação. Tanto no algoritmo de PG, quanto no algoritmo genético desenvolvidos neste trabalho, o elitismo é empregado a fim de manter um percentual de melhores indivíduos na população.

2.2.7 Operadores Genéticos

Os operadores genéticos alteram a composição genética dos filhos durante a reprodução. A sua função é criar novos indivíduos a partir dos antigos. Estes operadores trabalham sobre a codificação das possíveis soluções (genótipo) e não sobre as soluções (fenótipos) propriamente ditas.

Os principais operadores genéticos são:

1) Recombinação (*Crossover*): Também conhecido por cruzamento, este operador une informações de dois ou mais genótipos pais a fim de gerar descendentes. Tanto em PG quanto em AG, o ponto de troca da informação depende do tipo de *crossover* a ser adotado. Entre os tipos de *crossover* mais comum estão o *crossover* simples, *crossover* de múltiplos pontos e *crossover* uniforme (DELGADO, 2002).

No *crossover* simples, o ponto de troca (corte) é escolhido de maneira aleatória, definindo qual a proporção de informação dos pais que cada descendente receberá. Já o *crossover* de múltiplos pontos escolhe de forma aleatória mais de uma posição de troca. Finalmente, o *crossover* uniforme, define uma porcentagem de alelos que serão trocados e as posições que serão permutadas são escolhidas aleatoriamente. Neste trabalho o tipo de *crossover* aplicado nos algoritmos genético e de PG desenvolvidos corresponde ao *crossover* simples. A aplicação do operador de *crossover* está relacionada com uma taxa de *crossover*, que define com que probabilidade os indivíduos da população serão cruzados.

A Figura 16 apresenta um exemplo de *crossover* entre indivíduos de um algoritmo genético, e na Figura 17 um exemplo de *crossover* em PG.

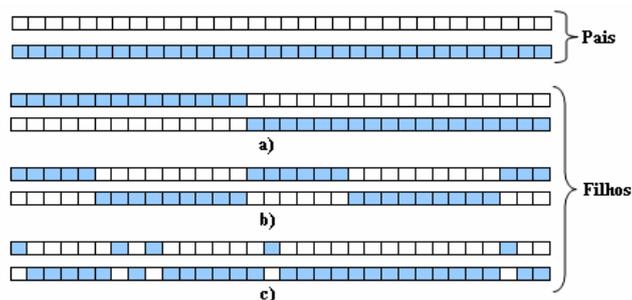


Figura 16: Operador de *crossover* em AG: a) *Crossover* simples; b) *Crossover* de múltiplos pontos; c) *Crossover* uniforme.

A Figura 17 apresenta um exemplo de *crossover* simples entre dois programas. Para que o cruzamento seja sempre possível, o conjunto de funções deve apresentar a propriedade de fechamento (*closure*), caso contrário, critérios de restrição na escolha dos pontos de cruzamento devem ser estabelecidos.

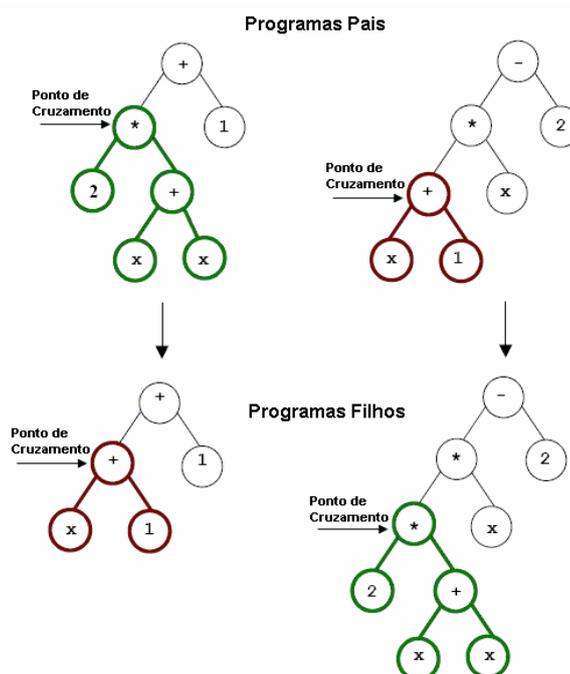


Figura 17: Exemplo de cruzamento simples entre dois programas.

2) *Mutação (Mutation)*: A mutação é um operador que introduz uma pequena mudança na estrutura de um indivíduo selecionado, dando origem a um descendente. Basicamente, seleciona-se uma posição em um cromossomo (indivíduo) e muda-se o valor do gene correspondente aleatoriamente para um outro alelo possível. Este operador genético garante (ou pelo menos torna possível) o surgimento de características novas, inexistentes até então em uma população finita.

A taxa de mutação define com que probabilidade será modificado cada alelo presente no cromossomo. A mutação ocorre normalmente a taxas reduzidas, pois a idéia do operador de mutação é incorporar novas codificações genéticas, sem no entanto, destruir o progresso obtido no processo evolutivo (MICHALEWICZ, 1996; DE JONG, 2006).

Em AG existem três tipos mais comuns de mutação: simples, inteira e real. Na mutação simples (usada na codificação binária), troca-se o valor do bit. Na mutação inteira, a busca é feita sobre um alfabeto de valores inteiros. Na mutação real, o operador pode realizar uma busca ampla sobre um domínio real ao longo de todo o processo evolutivo, como é o caso da mutação uniforme, ou realizar uma busca mais abrangente no início da evolução e mais localizada nas gerações finais, como no caso da mutação não-uniforme (MICHALEWICZ, 1996). Neste trabalho, a mutação aplicada no algoritmo genético desenvolvido corresponde a um misto da mutação inteira e real não-uniformes, cujos detalhes serão fornecidos na Seção 4.2.2 do Capítulo 4.

A Figura 18 ilustra exemplos de cromossomos com diferentes tipos de codificação e a aplicação de operadores de mutação simples, inteira, real uniforme e real não-uniforme, conforme apresentado em Delgado (2002).

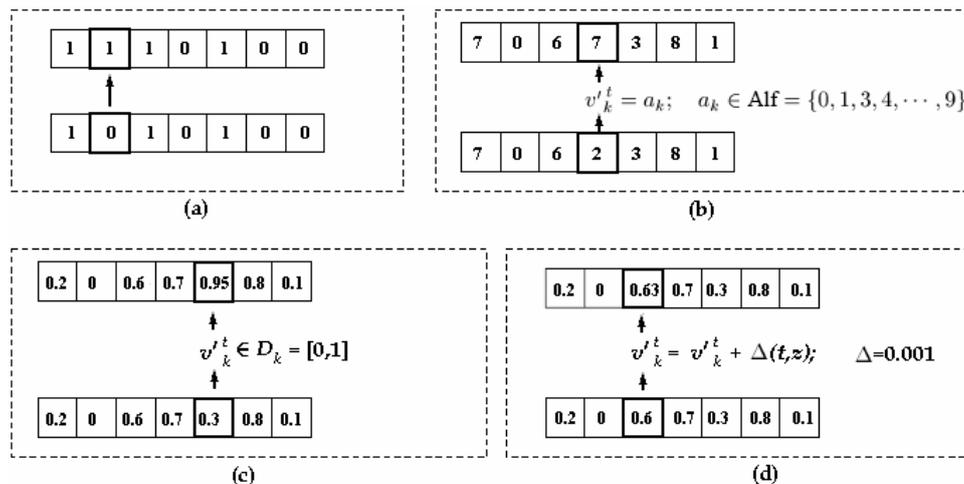


Figura 18: Exemplos de mutação: a) Mutação simples; b) Mutação inteira; c) Mutação real uniforme; d) Mutação real não uniforme (DELGADO, 2002).

Em PG, pequenas alterações nos alelos que compõem um programa já podem gerar resultados bastante diversificados, pois dão origem a programas totalmente novos. No algoritmo de PG desenvolvido, foi aplicada a mutação não-uniforme, possibilitando trabalhar com três formas distintas de alteração das árvores trabalhadas (mais detalhes no Capítulo 4). A Figura 19 apresenta dois exemplos de aplicação do operador genético de mutação em PG.

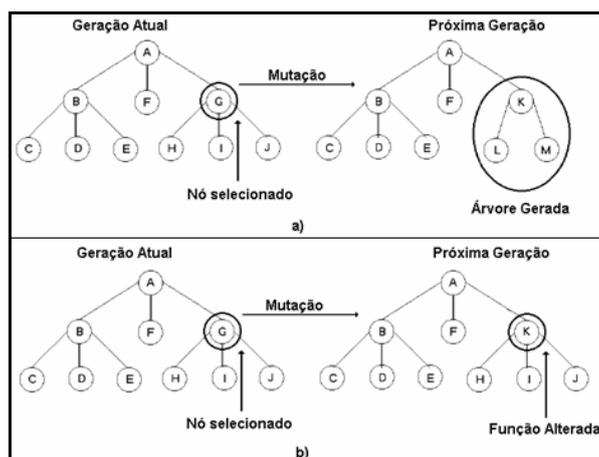


Figura 19: Exemplo de mutação em PG. a) Criação de uma nova sub-árvore. b) Substituição da função existente no nó selecionado.

As novas soluções candidatas geradas a partir do cruzamento e da mutação constituem a próxima geração. Segundo Barreto (2003), não é difícil perceber que os indivíduos desse novo conjunto tendem a ser melhores do que aqueles que lhes deram origem, uma vez que a seleção valoriza os indivíduos mais aptos. Se esse processo for sucessivamente repetido, existe uma boa chance de que a solução ótima (ou satisfatória) seja alcançada. Uma vez encontrada a solução, o processo deve ser interrompido.

2.2.8 Critério de Término

A evolução natural é um processo contínuo que aparentemente não tem data para acabar. Desta forma, não se pode esperar que um algoritmo evolutivo pare espontaneamente quando encontrar a solução ótima. Para isso, define-se um critério de término (condição de parada), que é responsável por interromper o laço de repetição do processo evolutivo que, caso contrário, não teria fim.

O critério mais comum é limitar o número máximo de gerações e/ou manter a evolução até que uma solução satisfatória seja encontrada (KOZA, 1992). Existem outras abordagens, como as baseadas no acompanhamento do processo evolutivo, isto é, enquanto houver melhoria na média da população, o processo evolutivo prossegue (KRAMER e ZHANG, 2000). Ou ainda, pode-se trabalhar com a convergência da população, ou seja, quando todos os indivíduos da população já estiverem muito parecidos, o processo é interrompido. Neste trabalho o critério de término para o algoritmo genético corresponde à limitação de um número máximo de gerações, e a adequação de uma solução e um nível de

similaridade máximo considerado satisfatório. No caso do algoritmo de PG, um número máximo de gerações também foi utilizado, juntamente com um valor de Erro Mínimo considerado satisfatório.

CAPÍTULO 3

PREDIÇÃO ESPAÇO-TEMPORAL EM UM CONTEXTO AMBIENTAL

A predição espaço-temporal considera que valores de atributos importantes coletados sistematicamente podem contribuir para um melhor entendimento do estudo de fenômenos complexos na meteorologia, oceanografia, ciência ambiental, agricultura de precisão e outros domínios, propiciando elementos para apontar as tendências reais e atuantes do dinamismo da região em estudo. No presente trabalho, o processo de predição espaço-temporal é aplicado em regiões florestais, a fim de identificar a tendência de evolução da paisagem destas regiões. Este capítulo faz uma revisão dos conceitos relacionados à Geomática e ao Processamento Digital de Imagens, e apresenta uma relação de métodos já existentes para realização de predição espaço-temporal em um contexto ambiental.

3.1 GEOMÁTICA

Com o advento da informática na automação de processos, surgiram várias ferramentas para a captura, armazenamento, processamento e apresentação de informações espaciais geo-referenciadas (ROCHA, 2000). As relações técnicas e conceituais dessas ferramentas levaram ao desenvolvimento da tecnologia de processamento de dados geográficos, denominada geoprocessamento.

Muitos conceitos e definições são diferenciados entre os principais autores de publicações nesta área. Segundo Moura (2001), “geoprocessamento significa implantar um processo que traga um progresso na grafia ou representação da Terra”. Em uma visão mais detalhada, Câmara (1995) apresenta o termo Geoprocessamento como uma disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica. De um modo geral, esta disciplina influencia de maneira crescente as áreas de Cartografia, Análise de Recursos Naturais, Transportes, Comunicações, Energia e Planejamento Urbano e Regional.

Geotecnologia é um conjunto de conhecimentos e recursos empregados para a manipulação da informação geográfica, que é normalmente representada através de mapas e

imagens (fotos aéreas e imagens de satélite) em bancos de dados distribuídos ou não (ALMEIDA, 1999).

A Geomática pode ser vista como uma área mista de conhecimento (Informática e Geociências) que se baseia no estudo das informações geo-referenciadas e de suas aplicações, em métodos de geoprocessamento e de suas tecnologias. Como definida pela ISO (*International Standards Organization*), a geomática consiste em um campo de atividades que, usando uma abordagem sistemática, integra todos os meios utilizados para a aquisição e gerenciamento de dados espaciais. Estes dados são empregados como parte de operações científicas, administrativas, legais e técnicas envolvidas no processo de produção e gerenciamento de informação espacial. Estas áreas de atividade incluem, entre outras, a cartografia, o apoio topográfico, o mapeamento digital, a geodésia, os sistemas de informações geográficas, a hidrografia, o gerenciamento de informações de terra, os levantamentos topográficos, o levantamento de minas, a fotogrametria e áreas que usam o sensoriamento remoto (ALMEIDA, 1999).

O uso do sensoriamento remoto com base na análise de imagens de satélites é um dos meios que se dispõem hoje para acelerar e reduzir custos dos mapeamentos e da detecção de mudanças geoambientais (PACHECO, 2001). As imagens de satélite oferecem possibilidades de geração de informações precisas para a avaliação e evolução de diversas variações temáticas da superfície terrestre.

Ao trabalhar com geomática, deve-se ter em mente que na natureza, todos os processos são essencialmente espaço-temporais. Através da análise de uma região e sua localização no espaço, associado à dinâmica temporal, é possível avaliar e quantificar possíveis áreas de expansão e regressão, e associá-las a alguns fatores determinantes.

Uma proposta de representação da informação espaço-temporal é feita por Peuquet (1994), onde o fenômeno é analisado considerando-se além do objeto geográfico, no caso o próprio fenômeno, a localização e a sua dimensão temporal. Esta metodologia incorpora conceitos da psicologia da percepção, inteligência artificial e campos correlatos (MARTINES, 1999).

Para Martines (1999), qualquer representação espaço-temporal efetiva possui muitas propriedades especiais do espaço e do tempo. A seguir são apresentados alguns conceitos fundamentais para o entendimento destas questões.

3.1.1 Análise Espaço-Temporal

A visão do espaço (do grego *choros*) e do tempo (*chronos*) é uma experiência subjetiva do ser humano (DIAS, CÂMARA e DAVIS., 2005). O espaço e o tempo se misturam ao se descrever uma realidade (KAVOURAS, 2001).

A análise espaço-temporal lida com modelos preditivos que possuem representação espaço-temporal, onde a evolução do fenômeno é expressa através de representação funcional, como por exemplo: uso e ocupação da terra, cadastro urbano e poluição (FOOK, 2005).

Em Martines (1999), três maneiras de analisar o objeto de estudo são apresentadas: a primeira refere-se ao tratamento de objetos espaciais em relação ao espaço e ao tempo. Questões do tipo "esse objeto tem se movimentado nestes últimos anos?" são colocadas com a finalidade de inserir a *variável* tempo nos estudos espaciais. A segunda análise feita diz respeito aos atributos específicos dado ao objeto, buscando-se responder questões do tipo "quais áreas apresentam riscos de desmoronamento por causa da uma tempestade durante uma semana?". A outra maneira de analisar o objeto é verificando a sua localização relativa no tempo, ou seja, responder a questões como "qual foi a distribuição do uso do solo comercial de dada área nos últimos 15 anos?" (LANGRAN, 1989).

Os mapas podem ser empregados para descrever as mudanças ou movimentos, assim como são empregados também para apresentar uma visão estática do mundo (McEARTHEN et al. 1992). A primeira estratégia manipula a simbologia dentro de uma única visão. Estes mapas, ainda que muitas vezes eficazes, mostram a representação visual de muitos tipos específicos de informações e são entendidos para transmitir mensagens específicas (MARTINES, 1999). A segunda estratégia usa uma seqüência de mapas estáticos que representam um único instante e seqüencial momento do tempo (MONMONIER, 1990).

Para a análise espacial conceitos como dependência espacial e auto-correlação espacial são fundamentais. Entende-se por dependência espacial o fato de que a maior parte das ocorrências naturais ou sociais apresenta entre si uma relação que depende da distância (DRUCK et al., 2004). A expressão computacional do conceito de dependência espacial é a auto-correlação espacial. A idéia é verificar como a dependência espacial varia, a partir da comparação entre os valores de uma amostra e de seus vizinhos (localizados a uma pequena distância espacial).

A seguir são descritos alguns componentes principais para análise espaço-temporal.

a) O Espaço Geográfico

O espaço geográfico é o meio físico onde as entidades geográficas coexistem. Uma entidade geográfica é qualquer entidade identificável do mundo real, possuindo características espaciais e relacionamentos espaciais com outras entidades geográficas (GATRELL, 1991). Define-se, portanto, uma entidade geográfica em função das suas coordenadas, sua altitude e sua posição relativa. Sendo um espaço localizável, pode-se cartografar o espaço geográfico (DOLFUS, 1991).

Segundo Pedrosa (2004), “o espaço é o conceito chave na geografia e, por extensão, na Ciência da Informação Espacial. Tradicionalmente, os geógrafos fazem uma distinção entre os conceitos de espaço absoluto e espaço relativo”. Espaço absoluto, também chamado Cartesiano ou Newtoniano, é um *container* de coisas e eventos, uma estrutura para localizar pontos, trajetórias e objetos. Espaço relativo, ou *Leibnitziano*, é o espaço constituído pelas relações espaciais entre coisas e eventos (COUCLELIS, 1997).

Couclelis (1997) propõe a idéia de espaço próximo como uma extensão dos conceitos de espaço absoluto e relativo. No espaço próximo o conceito chave é a vizinhança associada à noção de proximidade, que conduz também ao conceito de proximidade funcional ou influência. O conceito de vizinhança é facilmente visualizado em representações matriciais do espaço. Algumas operações espaciais efetuadas por meio de processamento digital de imagens, como filtros espaciais, por exemplo, utilizam a noção de espaço próximo de forma limitada.

Segundo Pedrosa (2004), a abstração fundamental na maior parte dos SIG atuais é o conceito de mapa, fortemente relacionado com noções cartográficas e, portanto, do espaço absoluto. Em processos dinâmicos a noção de espaço relativo e próximo são fundamentais para estabelecer e representar fluxos e conexões entre entidades do sistema. No trabalho desenvolvido, trabalhou-se com a noção de espaço relativo no sentido de identificar transformações espaciais ocorridas na paisagem de áreas florestais (regiões que progrediram ou regrediram) com o passar do tempo, e o espaço próximo no sentido de verificar a influência dessas transformações nas regiões vizinhas.

b) O Tempo

As técnicas utilizadas para a representação cartográfica do tempo podem ser as oscilações do tempo, seqüências temporais de mapas estáticos e gráficos suplementares. Estas apresentam sucessivas descrições sobre o movimento no tempo, usando unidades de medida de tempo apropriadas (MARTINES, 1999).

Um *chronon* é a menor duração de tempo suportada por um sistema e pode variar em diferentes aplicações (EDELWEISS e OLIVEIRA, 1994).

Segundo Pedrosa (2004), conceitualmente, pode-se representar o tempo através de diferentes estruturas, definidas, principalmente, com base em três aspectos da representação temporal: granularidade, variação e ordem no tempo. Estas estruturas são apresentadas graficamente na Figura 20.



Figura 20: Estruturas temporais (Adaptado de Worboys (1998)).

A ordem temporal refere-se ao modo como o tempo flui, se de forma linear, ramificada ou cíclica. No tempo linear considera-se que o tempo flui seqüencialmente, ou seja, existe uma ordem de precedência entre os pontos no tempo, de tal forma que cada ponto tenha apenas um sucessor e um antecessor. No tempo ramificado, múltiplos pontos podem ser os sucessores ou antecessores imediatos de um mesmo ponto. O tempo cíclico é utilizado para modelar eventos e processos recorrentes (EDELWEISS e OLIVEIRA, 1994). Neste trabalho, o conceito de tempo empregado refere-se ao tempo linear, pois os dados utilizados correspondem à evolução espacial de uma região com o passar dos anos.

Com relação à variação temporal, duas possibilidades podem ser consideradas: tempo contínuo e discreto. Uma variável temporal contínua é usada em processos que demandam medidas de tempo com níveis arbitrários de precisão. Por exemplo, a expansão da área de desmatamento de uma floresta entre dois instantes de tempo pode ser

interpolada, como é o caso do trabalho desenvolvido. Já uma variável temporal discreta é usada quando o tempo é medido em certos pontos ou intervalos e a variação é descontínua entre estes pontos. Uma delimitação de lotes de um cadastro imobiliário pode ocupar uma posição num instante t e outra num instante t' , mas não faz sentido dizer que a delimitação ocupou alguma posição intermediária entre t e t' (PEDROSA, 2004).

As diferentes granularidades de um sistema temporal conduzem à definição de instante e intervalo de tempo. Um instante de tempo representa um ponto particular no tempo, um intervalo é o tempo decorrido entre dois instantes e um período consiste de uma seqüência de intervalos de tempo (PEDROSA, 2004). O instante temporal empregado neste trabalho corresponde ao ano, e o intervalo temporal à distância temporal identificada entre dois anos distintos.

A Figura 21 apresenta mapas de uma área florestal desmatada em dois instantes t e t' . Neste caso como o processo é contínuo no tempo, se necessário, pode-se gerar um mapa que representa o desmatamento ocorrido no intervalo de tempo passado entre os dois instantes.



Figura 21: Área desmatada da floresta em dois instantes t e t' (CÂMARA e MONTEIRO, 2003).

Adicionalmente, existe o conceito de “tempo definido pelo usuário”, consistindo de propriedades definidas explicitamente pelos usuários em um domínio temporal e manipuladas pelo programa de aplicação (EDELWEISS e OLIVEIRA, 1994).

Usando a visão baseada no tempo, mudanças no objeto ocorridas em um intervalo de tempo podem ser armazenadas. Mudanças no fenômeno geográfico sobre o tempo são apresentadas como uma série de imagens instantâneas. Por meio de sensoriamento remoto, estas imagens são instantaneamente armazenadas no formato *raster* (obtidos de *scanners* acoplados a aviões ou plataformas de satélites orbitais), representando o "estado do mundo" em um momento particular. Estes estados podem ser calculados por comparação entre dois estados sucessivos (MARTINES, 1999). No trabalho desenvolvido, a comparação entre dois estados sucessivos de uma região florestal permite a criação de mapas de progressão e

regressão, os quais permitem a identificação de regiões que progrediram ou regrediram entre os dois estados analisados.

c) Dados e Informações Espaciais

Laurini e Thompson (1992) utilizam o termo “espacial” para referenciar dados localizados, objetos posicionados em algum espaço, não necessariamente geográficos.

Dado espacial é qualquer tipo de dado que descreve fenômenos aos quais esteja associada alguma dimensão espacial. Dados geográficos ou geo-referenciados são dados espaciais em que a dimensão espacial está associada à sua localização na superfície da terra, num determinado instante ou período de tempo (CÂMARA et al., 1996).

Conforme apresentado em Dias (2003), as características espaciais dos dados geográficos são a topologia, forma geométrica e localização. A forma geométrica pode ser representada por ponto, linha e polígono (LANGRAN, 1992). A topologia corresponde aos relacionamentos espaciais entre dados de continência (contém e está contido), adjacência (vizinho a, ao lado de) e conectividade (conectado a e relacionado com). Os relacionamentos espaciais básicos são: “igual”, “toca”, “contém”, “sobrepõe” e “disjunto”. A partir deles podem ser obtidos outros operadores, como “adjacente a”, “coincide com”, “em frente a” e “pertence” (EGENHOFER e GOLLEDGE; 1998).

Pode-se considerar que o conjunto formado pelo espaço geográfico e seus componentes (os geo-objetos), possui uma descrição geográfica que inclui desde informações sobre relevo e clima, a informações sobre demografia e economia.

Sintetizando, pode-se dizer que dados espaciais são as representações geograficamente referenciadas de informação, enquanto a informação espacial é derivada de dados e útil na resolução de problemas e tomada de decisão.

Os dados espaciais utilizados neste trabalho correspondem a mapas digitais (imagens digitais) que representam a evolução da paisagem de uma região florestal. A informação espacial obtida a partir destes dados corresponde à identificação de regiões que progrediram ou regrediram com o passar do tempo, e qual a influência dessas regiões em relação a outras localizadas nas proximidades. A partir destas informações, é gerada uma predição do estado futuro da região florestal. O resultado desta predição visa auxiliar gestores ambientais na tomada de decisão.

3.1.2 Modelos Espaciais

Um modelo de dados deve prover uma maneira formal de representar informações, bem como definir as operações de manipulação permitidas. Trata-se de produzir uma visão abstrata da realidade (ALMEIDA, 1999).

Para Moura (2000), o sentido dos estudos geográficos está em caracterizar uma realidade espacial de modo a gerar subsídios para estudos de predições: as alterações e as implicações dessas intervenções. Uma metodologia para a realização desses estudos está na construção de modelos que, devidamente calibrados, podem chegar bem próximos da representação da realidade.

Modelos espaço-temporais reúnem dois aspectos distintos: a escolha de conceitos adequados do espaço e do tempo e a construção de representações computacionais apropriadas correspondentes a esses conceitos (DIAS et al., 2005).

Modelos espaciais dinâmicos descrevem a evolução de padrões espaciais de um sistema ao longo do tempo (PEDROSA, 2004). Segundo (PEDROSA, 2004), os modelos podem ser classificados em empíricos e sistêmicos, conforme apresentado na Figura 22. Modelos empíricos focalizam os relacionamentos entre as variáveis do modelo, a partir da suposição de que os relacionamentos observados no passado continuarão no futuro. Modelos sistêmicos são descrições matemáticas de processos complexos que interagem entre si, enfatizando as interações entre todos os componentes de um sistema (LAMBIN, 1994).

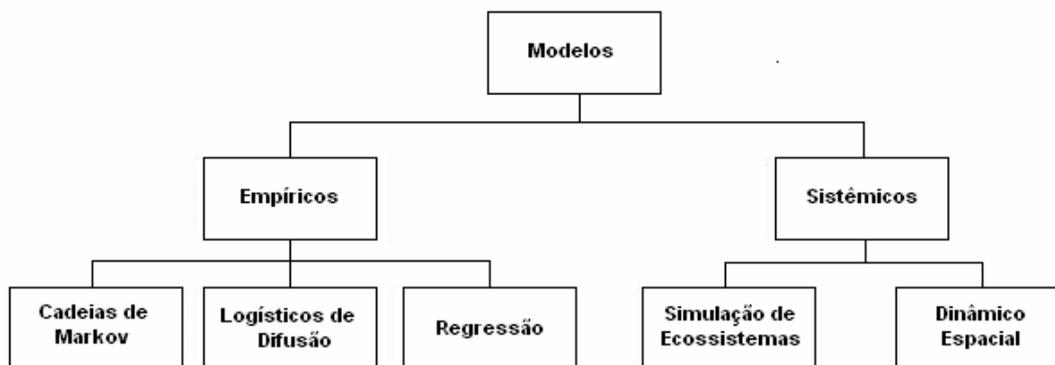


Figura 22: Tipos de modelos. Fonte: PEDROSA (2004) adaptado de LAMBIN (1994).

Segundo (DIAS, CÂMARA e DAVIS, 2005), “ainda não existe um consenso sobre as técnicas de modelagem de dados espaço-temporais, ou mesmo sobre extensões das técnicas de modelagem de dados geográficos atualmente existentes para refletir as necessidades de aplicações que envolvam simultaneamente tempo e espaço”.

Desta forma, optou-se neste trabalho por conceituar apenas os modelos espaço-temporais envolvidos na resolução do problema proposto. Tais modelos são apresentados a seguir.

a) Modelos Empíricos

Os modelos empíricos, em sua dimensão procedimental, possuem três componentes chaves: uma configuração inicial, uma função de mudança e uma configuração de saída. A configuração inicial de um modelo dinâmico pode ser obtida através de dados históricos do fenômeno em estudo, chamados de séries temporais (PEDROSA, 2004). Como exemplo pode-se citar o uso de equações diferenciais (totais ou parciais) que incluem pelo menos um termo derivado no tempo para representar o modelo. Neste caso, o processo é classificado como determinístico. Quando se utilizam variáveis aleatórias para explicar um sistema, o processo é classificado como estocástico-probabilístico.

Modelos empíricos são caracterizados pela simplicidade dos modelos matemáticos empregados e pelo número reduzido de variáveis envolvidas. Estes modelos são eficientes em fazer previsões, embora apresentem limitações em abordar a evolução espacial e identificar os aspectos causais do sistema (PEDROSA, 2004). Modelos empíricos podem corresponder a cadeias de Markov, modelos logísticos de difusão e modelos de regressão.

Dentre os modelos caracterizados como empíricos, pode-se citar os Modelos de Regressão, utilizados em uma das propostas deste trabalho, e também em trabalhos que serviram como base para este. Estes modelos visam estabelecer relações estatísticas entre um fenômeno em estudo e as variáveis independentes envolvidas, chamadas forças direcionadoras, as quais exercem influência sobre ele. Matematicamente, o modelo estabelece um relacionamento linear entre as variáveis dependentes e independentes através da expressão (PEDROSA, 2004):

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_ix_i + E \quad (9)$$

onde:

- y = Mudança ocorrida em um determinado tempo
- x_i = Variáveis independentes (forças direcionadoras)
- a_i = Coeficientes de regressão dos relacionamentos

- E = Componente de erro, representa o distúrbio aleatório que pode se originar devido a diversas circunstâncias, tais como a ausência de fatores influentes no modelo e distúrbios causados por erros de medidas.

Em modelos de regressão a dimensão temporal é considerada, mas a distribuição espacial do fenômeno não é abordada, limitação esta que pode ser superada se o modelo for combinado com SIG (PEDROSA, 2004).

Esses modelos buscam estabelecer relações entre duas ou mais variáveis quantitativas, de modo que uma variável possa ser prevista a partir de outra, no caso de modelos univariados, ou a partir de outras, no caso de modelos multivariados (NETER e WASSERMAN apud (ALMEIDA, 2003)). O *GWR – Geographically Weighted Regression* é um exemplo de técnica de análise exploratória que busca ajustar um modelo de regressão a cada ponto observado, ponderando todas as demais observações como função da distância a este ponto (DRUCK et al., 2004; FOTHERINGHAM, BRUNSDON e CHARLTON, 2002).

No modelo apresentado neste trabalho, supõe-se que o padrão espacial de evolução de uma floresta (progredir, regredir ou estagnar) irá se manter no futuro. Tomando como base as mudanças ocorridas sobre a paisagem de uma região florestal em instantes do passado, gera-se uma predição do número de *pixels* que representarão a superfície da floresta em determinado instante do futuro. Em uma das propostas apresentadas neste trabalho (nomeada FuzzySTP), este resultado é obtido por meio de um modelo de regressão, e em outras duas que apresentam maior nível de autonomia (nomeadas FuzzyGPSTP e SoftCompSTP), um algoritmo de programação genética é empregado em substituição ao cálculo de regressão simbólica.

b) Modelos Sistêmicos

Modelos sistêmicos procuram descrever o sistema como um todo, representando as interações entre todos os seus componentes. Uma característica chave destes modelos é a eficiência com que abordam a dimensão espacial implementando conceitos como as relações de vizinhança e suportando o uso combinado de múltiplas escalas. A seguir, são descritas as características gerais do modelo sistêmico de simulação dinâmica espacial (PEDROSA, 2004).

Dentre os modelos sistêmicos, destacam-se os modelos de simulação dinâmica espacial, que se baseiam em modelos de ecossistemas com extensões para acomodar a heterogeneidade espacial e processos humanos de tomada de decisão.

Uma abordagem para desenvolver modelos de simulação dinâmica espacial é representar o espaço como uma matriz de células. Cada célula do modelo está conectada com suas células vizinhas, de tal forma que é possível estabelecer um fluxo entre células adjacentes. Desta forma simplifica-se sobremaneira o mecanismo de predições do sistema. Por exemplo, se uma célula tem três vizinhos com estado x , é bastante provável que o estado desta célula venha a ser x também. Entretanto, este raciocínio simplista pode ser aperfeiçoado através do uso de regras de transição (PEDROSA, 2004).

O modelo de simulação dinâmica espacial também possibilita incorporação de processos de tomada de decisões. Modelos que incorporam este mecanismo são chamados modelos baseados em regras. As regras de tomada de decisão são representadas através de abstrações muito semelhantes àquelas que ocorrem na mente humana.

Uma opção para incorporar processos de tomada de decisões neste modelo é a utilização de Sistemas de Inferência *Fuzzy*. Estes sistemas permitem a integração balanceada de dados heterogêneos em diversas escalas de magnitude, facilitando a utilização e o estabelecimento de regras de integração por parte de especialistas e usuários. Sistemas *Fuzzy* foram empregados no preditor desenvolvido, cujos conceitos foram apresentados na Seção 2.1 do Capítulo 2.

3.1.3 Predição Espaço-Temporal

Diversos autores conceituam os termos previsão, predição e projeção ora como equivalentes, ora como distintos. Segundo Boland (1985) apud (SILVA e BARBOSA, 2002): “De uma forma geral, a previsão é uma afirmação sobre o futuro. Entretanto, ao contrário da ‘predição’, a previsão é condicional sobre o que é esperado para acontecer, caso uma série de hipóteses admitidas venham a se tornar válidas. Portanto, a previsão pode ser entendida como uma projeção ou extrapolação das tendências do passado“. Para Takashina (2004), entende-se que “previsão = projeção + predição”, onde: a projeção é baseada nos resultados passados e a predição é baseada na capacidade de obter os recursos para um novo contexto.

Segundo Laurini e Thompson (1992), os modelos espaciais preditivos incluem atividades como responder a questões do tipo “O que aconteceria se?”, ou empreender simulações de processos conhecidos para produzir saídas diferentes.

Considerando as definições acima, optou-se no presente trabalho por utilizar o termo predição no sentido de criar uma visualização do estado futuro de uma região, com base nas tendências de seu passado, visto que segundo Teixeira (1969), a predição, quando científica, importa em certeza ou alta probabilidade.

Conforme apresentado em Centeno, Saint-Joan e Desachy (1996), o tempo é um fenômeno relacionado a conceitos históricos e à noção de predição. O conceito conduz a uma representação mais dinâmica de fenômenos geográficos e permite uma melhor análise e compreensão dos fatores de mudança que podem agir sobre a paisagem em estudo. Fenômenos geográficos são observados e registrados em um conjunto multi-dimensional que inclui dimensões espacial e temporal.

Conforme Pokrajac e Obradovic (2000), a modelagem espaço-temporal corresponde muitas vezes a uma difícil tarefa devido a vários fatores, incluindo:

- Número pequeno de camadas de tempo disponíveis;
- Baixa resolução de amostragem espacial e erros devido à interpolação de dados;
- Alta influência de atributos não observados;
- Dinamismo do espaço e tempo;
- Dependência não linear em atributos importantes;

Além disso, o problema de predição espaço-temporal requer que um ou mais valores futuros sejam preditos para dados de entrada de séries temporais obtidas de sensores em posições físicas múltiplas. Exemplos desse tipo de problema incluem predição do tempo, predição de enchentes, fluxo de rede tráfego, etc. (MANOLOPOULOS, PAPADOPOULOS, e VASSILAKOPOULOS, 2004).

Apesar das dificuldades acima citadas, a predição espaço-temporal tem sido amplamente utilizada no sentido de auxiliar na tomada de decisão em um âmbito físico-territorial.

3.1.4 Principais Conceitos de Sensoriamento Remoto

Em um sentido amplo, Sensoriamento Remoto corresponde à mensuração ou aquisição de informação de alguma propriedade de um objeto ou fenômeno, por um dispositivo de gravação que não está em contato físico ou íntimo com o objeto ou fenômeno em estudo.

Existem diversos sistemas de aquisição de dados sensoriados remotamente que servem como fontes de dados para os SIGs, como satélites, câmaras fotográficas aerotransportadas, sistemas de radar, sistemas de *sonar* e microondas (CÂMARA et al., 1996). Entretanto, os principais dados sensoriados remotamente utilizados em sistemas de informação geográfica concentram-se em dados digitais coletados através de sensores a bordo de satélites, também chamados de imagens de satélite.

A principal vantagem em se utilizar imagens de satélite é que as mesmas podem ser obtidas em intervalos de tempo regulares sobre uma mesma extensão geográfica, tornando possível o acompanhamento de mudanças de temperatura, vegetação, etc. (PRETO, 1999). Segundo Novo (1989), as principais vantagens que justificam os programas de sensoriamento remoto orbital são as seguintes: estímulo às pesquisas multidisciplinares; informações de áreas de difícil acesso; universalização dos dados e das técnicas de tratamento e análise de dados digitais; facilidade do recobrimento de grandes áreas (visão sinóptica); cobertura repetitiva com mesma hora local; grande quantidade de dados pontuais sobre uma mesma área; transferência de dados Satélite/Terra em tempo real; e o aspecto multiespectral, isto é, a capacidade dos sistemas sensores gerarem produtos em diferentes faixas espectrais, tornando possível o estudo e análise de diferentes elementos, os quais são identificados em determinadas faixas do espectro.

Este trabalho utiliza imagens de sensoriamento remoto para realizar predição espaço-temporal em um contexto ambiental. As imagens utilizadas foram obtidas por meio de satélites e aerofotogrametria³, e representam a evolução da paisagem de regiões florestais com o passar do tempo.

³ Geotecnologia que permite a transformação de fotografias aéreas verticais em mapas digitais.

3.2 PROCESSAMENTO DIGITAL DE IMAGENS

Para tornar possível a utilização de informações captadas do mundo real, é necessário estruturá-las previamente. Esta estruturação de informações corresponde à formatação computacional para representação de uma informação do mundo real. Sendo assim, a seguir serão revisados alguns conceitos de imagem digital, registro de imagem, e segmentação, necessários para compreensão do trabalho desenvolvido.

3.2.1 Imagem Digital

No sentido comum, imagem é uma representação gráfica de objetos que nos cercam ou que criamos. No contexto deste trabalho, as imagens utilizadas são produzidas por computador e se assemelham a uma foto – ou seja, formam uma região retangular do espaço na qual em cada ponto percebemos uma cor ou uma intensidade de cinza.

O processo de digitalização de uma imagem não-digital (imagem contínua) corresponde a uma discretização (processo de amostragem) da cena em observação. Esta discretização é obtida através da superposição de uma grade hipotética, e uma atribuição de valores inteiros (os níveis de cinza) a cada ponto dessa grade (processo chamado de quantização). Quanto mais fina a grade de amostragem e a quantização, melhor é a aproximação da imagem original. Basicamente, a codificação da imagem corresponde a representar cores no formato de código. A Figura 23 apresenta um exemplo deste processo.

O modelo matricial (*raster*) é utilizado para estruturar as informações, onde uma matriz de dados armazena a informação de cor em cada ponto da imagem. Cada elemento que compõe a matriz bidimensional que representa uma imagem digital é chamado de *pixel* (*picture element*).

3.2.2 Técnicas de Pré-processamento

As técnicas de pré-processamento têm como principal função adequar a qualidade da imagem, como forma de tentar melhorar os resultados das etapas de processamento posteriores. Estas técnicas envolvem duas categorias principais: métodos que operam no domínio espacial e métodos que operam no domínio da frequência.

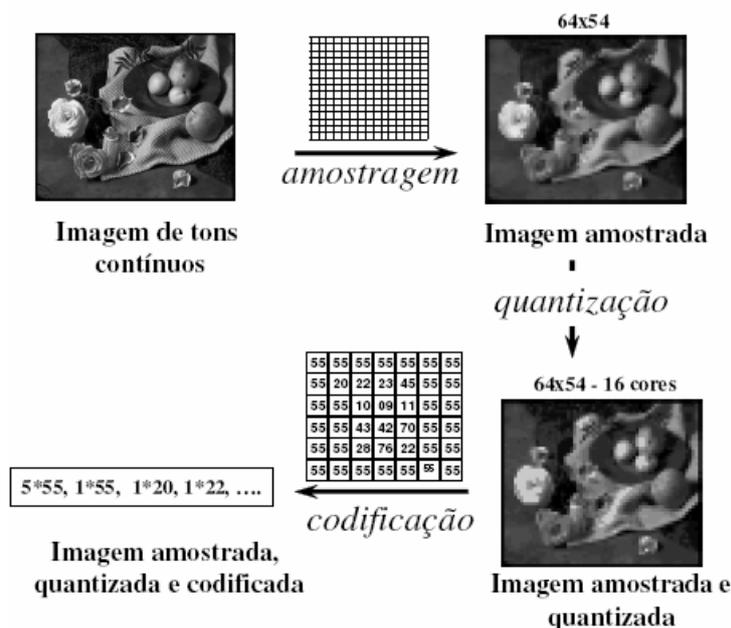


Figura 23: Amostragem, quantização e codificação de uma imagem. (GATTASS, 2005)

Técnicas de processamento no domínio espacial baseiam-se em filtros que manipulam o plano da imagem, enquanto que as técnicas de processamento no domínio da frequência se baseiam em filtros que agem sobre o espectro da imagem. É comum combinar vários métodos que estejam baseados nestas duas categorias para realçar determinadas características de uma imagem (GONZALEZ, 1992).

Este trabalho utiliza como pré-processamento, a aplicação de um filtro da mediana nas imagens. Este filtro atua no domínio espacial e foi empregado com o objetivo de remover possíveis ruídos existentes nas imagens (mais detalhes no Capítulo 4).

Nas técnicas de filtragem no domínio espacial, manipula-se diretamente a matriz de níveis de cinza da imagem digital e os processamentos executados são matematicamente descritos por uma transformação: $Im_p(i,j)=T[Im(i,j)]$, onde $Im(i,j)$ é a imagem original, $Im_p(i,j)$ é a imagem processada e T é um operador que atua na vizinhança em torno de cada *pixel* (i,j) em $Im(i,j)$. Esta vizinhança é definida, em geral como regiões (máscaras) de tamanho 3x3, 5x5, ... NxN, centradas no *pixel* de referência.

No caso do filtro da mediana, o valor do *pixel* central da máscara é transformado pela mediana dos *pixels* da vizinhança. A Figura 24 apresenta um exemplo esquemático de aplicação do filtro de mediana: o *pixel* em análise tem o valor de nível de cinza 240 sendo modificado para o valor 40. Neste caso a máscara utilizada trabalha com uma vizinhança de 3x3.

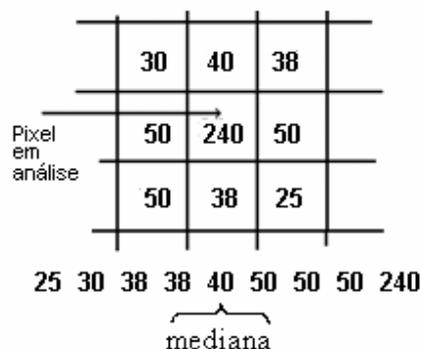


Figura 24: Exemplo de aplicação do filtro da mediana.

3.2.3 Segmentação de Imagens

Um dos primeiros passos do processo de análise de uma imagem digital consiste em particioná-la em seus elementos constituintes. Isto porque muitas vezes não é suficiente representar uma imagem com diferentes graduações de níveis de cinza. Em alguns casos é necessário identificar regiões e estabelecer subdivisões na imagem em sua unidade básica (*pixel*) para que possa ser interpretada de acordo com uma finalidade específica. Tal processo é denominado de segmentação e representa o menor nível descritivo no qual o entendimento de uma imagem possa ser baseado (CAVES, QUEGAN e WHITE, 1996).

A segmentação depende do tipo de aplicação e também do tipo de sensor empregado para aquisição dos dados, uma vez que duas imagens de uma mesma cena tomadas com diferentes resoluções, ou diferentes bandas espectrais, produzirão segmentações diferentes. Existem muitas formas de segmentar uma imagem, uma das mais utilizadas é a segmentação por limiarização, cujos detalhes são apresentados a seguir.

Limiarização

A limiarização corresponde a uma das mais importantes abordagens para a segmentação de imagens, e seu princípio consiste em separar as regiões de uma imagem em duas classes: o fundo e o objeto (GONZALEZ e WOODS, 1992). As demais regiões são classificadas como não interessantes.

Também conhecida como binarização, nesta técnica têm-se, em geral, objetos pretos (0) sobre fundo branco (255). É fornecido um valor de limiar T onde todos os *pixels* com tons de cinza inferior a este valor são transformados na cor preta e os *pixels* com valor superior ou igual a T são transformados na cor branca (GONZALEZ e WOODS, 1992). A

representação do objeto na cor branca e fundo na cor preta também é válida, porém, neste caso, os *pixels* com tons de cinza menor que o limiar são transformados em branco e os demais em preto.

Uma característica que permite um melhor entendimento da distribuição de tons em uma imagem digital é o seu histograma, que representa a base para o processo de limiarização. O histograma de uma imagem é uma função que, para cada valor possível de cor, associa o número de *pixels* em que ela ocorre ou a sua frequência na imagem (GATTASS, 2005). A Figura 25 apresenta um exemplo de histograma e limiar empregado.

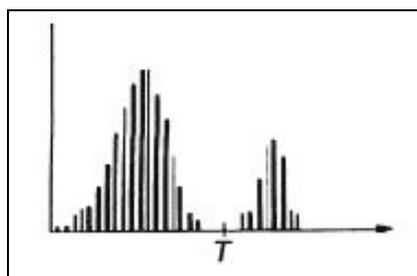


Figura 25: Histograma e exemplo de limiar (T) (DUARTE, 2006).

Matematicamente, a limiarização pode ser definida como:

$$g(x, y) = \begin{cases} \text{objeto} & \text{se } f(x, y) < T \\ \text{fundo} & \text{se } f(x, y) \geq T \end{cases} \quad (10)$$

Onde $f(x, y)$ é a imagem de entrada, T é o valor do limiar e $g(x, y)$ é a imagem de saída (limiarizada).

A Figura 26 apresenta os resultados da aplicação de limiarização em uma mesma imagem, com limiares distintos. Neste exemplo considera-se que o objeto será representado na cor branca e o fundo na cor preta.

O método de limiarização apresentado acima corresponde a uma abordagem global (um único limiar T para toda imagem). É possível ainda, trabalhar com uma abordagem local, a limiarização multiníveis, cujo princípio é dividir a imagem em sub-regiões, onde cada sub-região tem seu limiar específico (GONZALEZ e WOODS, 1992).

Neste trabalho, o processo de limiarização é empregado em dois momentos: no início da abordagem, de forma global para extração de informações a respeito da existência de floresta nos mapas digitais; e na fase final, de forma local, utilizando dois limiares, para auxiliar na geração da imagem final referente à predição espaço-temporal da região em estudo. Mais detalhes deste processo são apresentados no Capítulo 4.

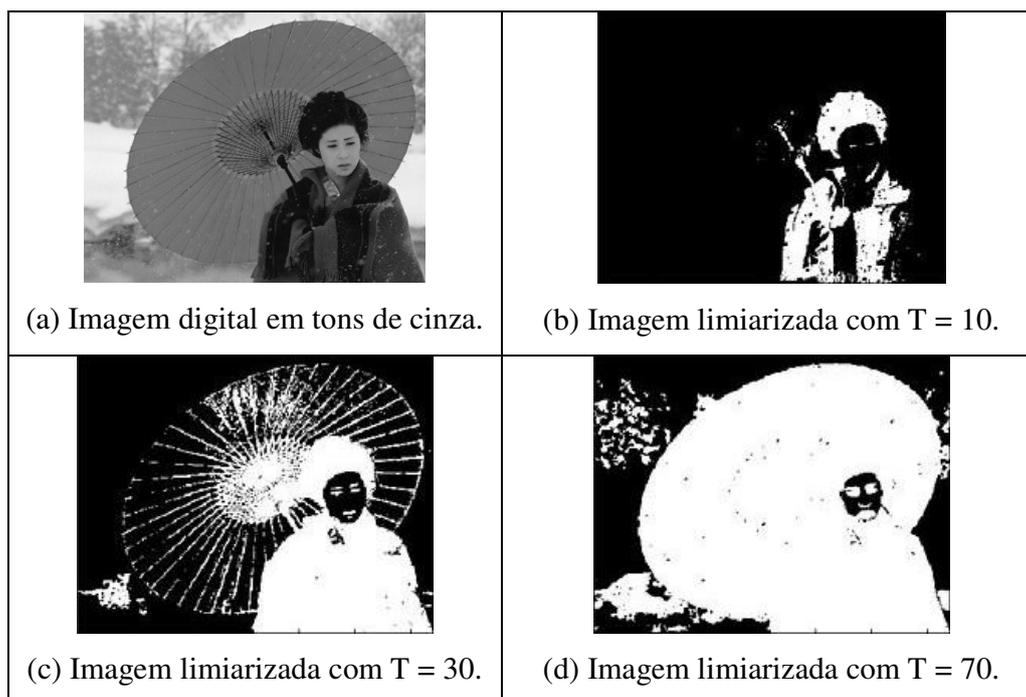


Figura 26: Exemplos de limiarização (DUARTE, 2006).

3.2.4 Extração de Atributos

A etapa final do processamento de imagens digitais é aquela em que se extraem as informações úteis da imagem processada. Quando o objetivo do processamento é obter informações numéricas, realiza-se a extração de atributos da imagem (ESQUEUF, 2002).

Em imagens binárias, como as utilizadas neste trabalho, é muito simples obter dados relevantes, ou atributos das regiões segmentadas como:

- Número total de objetos;
- Propriedades geométricas, do tipo: Área, Perímetro, Centro de Gravidade, Largura Máxima e Mínima;
- Atributos relacionados à forma, como: Circularidade, Concavidade;
- Propriedades de luminância, tais como: Nível de cinza médio de cada região (1º momento da distribuição), Desvio padrão do nível de cinza (2º momento da distribuição), e outros momentos estatísticos da distribuição de cada região;
- Propriedades associadas à textura;
- Identificação de regiões conectadas.

Os atributos extraídos das imagens utilizadas neste trabalho correspondem às regiões conectadas (através da técnica de etiquetagem) e ao cálculo do centro de gravidade (centro de massa) de cada uma destas regiões.

O cálculo do centro de massa (JAIN, KASTURI e SCHUNK, 1995) de determinada região em uma imagem pode ser obtido através das equações (11) e (12), descritas a seguir:

$$x = \frac{\sum_{i=1}^n \sum_{j=1}^m jB_{(i,j)}}{A}$$

$$y = \frac{\sum_{i=1}^n \sum_{j=1}^m iB_{(i,j)}}{A}$$

Onde

i = linha i na imagem etiquetada;

j = coluna j na imagem etiquetada;

n = número total de linhas;

m = número total de colunas;

$B_{(i,j)}$ = valor do *pixel* na posição (i,j) da imagem binária;

A = número total de *pixels* da região etiquetada;

.

(11)

(12)

A etapa chamada de Etiquetagem ou Rotulação é uma etapa intermediária na extração de atributos. Após a etapa de segmentação obtemos uma imagem onde as regiões correspondentes aos “objetos” estão separadas daquelas correspondentes ao “fundo” da imagem. Neste ponto do sistema de processamento, as regiões de interesse estão contiguamente agrupadas por *pixels* que se tocam.

O próximo passo é dar um rótulo (ou *label*) para cada um desses grupos de *pixels*. Esta identificação permitirá posteriormente parametrizar os objetos segmentados calculando para cada região de *pixels* contíguos um parâmetro específico, como área ou perímetro por exemplo. A Figura 27 apresenta um exemplo desta técnica para uma imagem binária, considerando a existência de três regiões de *pixels* conectados. O processo de segmentação separa as regiões pertencentes às células daquelas pertencentes às regiões entre células (fundo), criando um delimitador entre elas. A etapa de etiquetagem cria um rótulo que identifica cada uma dessas regiões para que os processos seguintes de tratamento da informação sejam concentrados em cada uma das regiões que receberam um rótulo (ESQUEF, 2002).

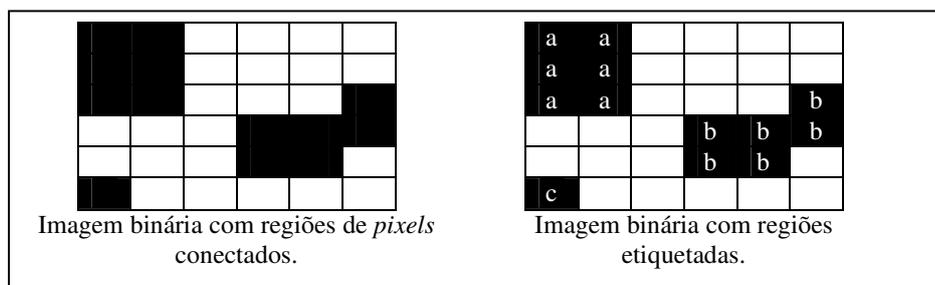


Figura 27: Exemplo de aplicação da técnica de etiquetagem.

3.2.5 Registro de Imagens

O registro de uma imagem compreende uma transformação geométrica que relaciona coordenadas de imagem (linha e coluna) com coordenadas geográficas (latitude e longitude) de um mapa. Esta transformação elimina distorções geométricas sistemáticas introduzidas na etapa de formação de imagem pelo sistema sensor e por imprecisão dos dados na plataforma (aeronave ou satélite) (CASTANHO e TOZZI, 1996).

As ferramentas de registro ou correção geométrica possibilitam a referência de imagens tanto a um sistema de coordenadas geográficas ou de projeção, quanto a outras imagens (FEDEROV, 2002).

O registro é importante para combinar imagens de sensores diferentes sobre uma mesma área ou para a realização de estudos multi-temporais. Nestes casos, é importante que se consiga um bom geo-referenciamento das imagens, pois os *pixels* correspondentes às mesmas localizações terrestres são comparados uns com os outros (SOARES, BRITES e RIBEIRO, 1998).

As imagens utilizadas neste trabalho foram geo-referenciadas previamente por um especialista, a fim de garantir a precisão da localização geográfica de cada *pixel* que influenciará no processo de predição proposto.

3.3 MÉTODOS DE PREDIÇÃO ESPAÇO-TEMPORAL

Diversos trabalhos têm sido desenvolvidos com o objetivo de estudar as mudanças espaciais ocorridas em uma região com o passar do tempo. Langran (1989, 1992), foi o precursor do estudo temporal no domínio dos SIGs (CENTENO et al., 1996).

Existem na literatura abordagens que focam na análise e na evolução espaço-temporal da paisagem de um terreno. Em Centeno, Saint-Joan e Desachy (1996), o método de predição foi realizado a partir de dados geográficos vetoriais e está fundamentado no estudo da posição e forma das entidades espaciais em cada mapa. No entanto, este método assume uma variação uniforme das regiões e não leva em consideração as diferentes características do terreno. Desta forma, este método não representa uma evolução real, pois considerando estas características pode-se constatar a existência de zonas com diferentes tipos de evolução dentro de uma mesma região.

Em Centeno, Selleron e Gonçalves (2003), o processo de predição de florestas foi realizado por meio de *autômatos* celulares. *Autômato* celular é um conceito matemático

criado por Von Neumann para designar um sistema de elementos conjugados que mudam de comportamento por meio de interações locais guiadas por regras. O método empregado baseia-se em um mapa de situação obtido de uma seqüência temporal de imagens de satélite, o qual descreve a situação da floresta conforme zonas de crescimento, regressão e estabilidade. Por meio de regras de transição de estado entre células vizinhas, foram geradas predições referentes à floresta de Ticoporo, na Venezuela, e à floresta de Tabe, na região de Ariège (França). Um inconveniente deste método corresponde à grande sensibilidade dos resultados com relação a alguns fatores como: número de estados escolhidos, vizinhança escolhida e principalmente escolha de regras de transição.

Considerando as abordagens que visam efetuar predição espaço-temporal utilizando técnicas *fuzzy*, pode-se citar Saint-Joan e Desachy (1996), que desenvolveram o sistema *GEODES* (*GEOgraphic Decision Expert System*) e o aplicaram no estudo de regiões do sul da França e da Índia, a fim de modelar a evolução florestal destas regiões, utilizando diversos mapas e integrando informações por meio de uma base de regras *fuzzy* configurável. Para o estudo destas regiões, as informações utilizadas correspondem à frequência de focos de fogo na região, distância destes focos e altitude da mesma. Com estas informações, o sistema estima a dinâmica da floresta, e como resultado, apresenta as regiões da floresta com tendência a crescer.

Em (SAINT-JOAN e VIDAL, 1997a, 1997b), foi apresentado um método que aplica morfologia matemática sobre zonas de progressão e regressão florestais associada a um sistema *fuzzy*. Trabalhando com técnicas de dilatação, erosão, abertura e fechamento (GONZALEZ e WOODS, 1992), a forma das regiões identificadas é alterada em função do tempo. Este método foi aplicado na floresta de Tabe, na região de Ariège (França). As informações trabalhadas pela base de regras do sistema de inferência *fuzzy* foram as mesmas utilizadas no trabalho de Saint-Joan e Desachy (1996): frequência de focos de fogo na região, distância destes focos e altitude. No entanto, ao empregar morfologia matemática, este método apenas considerou a forma das superfícies e a tarefa de predição foi realizada sem considerar fatores importantes relacionados à evolução florestal. Este método pode se mostrar ineficiente em situações cujo formato da região estudada não é uniforme ou pouco definido.

No trabalho apresentado em Centeno e Selleron (2001, 2002), utilizou-se também a definição de zonas de progressão e regressão, porém, ao invés de morfologia matemática, outros conceitos básicos relacionados a conjuntos *fuzzy* foram adotados. Primeiramente, efetuou-se uma projeção do tamanho da superfície da floresta em função das superfícies das

imagens existentes e a distância temporal entre cada uma delas por meio de cálculos baseados em regressão linear para o instante a ser predito (t_{n+1}). Em seguida, calculou-se um coeficiente de evolução para cada *pixel* da imagem analisada. Os coeficientes obtidos são normalizados, representando um conjunto *fuzzy* onde cada ponto tem um valor de pertinência à função de evolução. Tal conjunto pode ser convertido para níveis de cinza, mostrando visualmente como varia a tendência à progressão ou à regressão das diversas áreas da região total. O mapa predito é obtido a partir de sucessivas aplicações de limiares, com variação gradual fina, sobre a tabela final de coeficientes de evolução até que a superfície seja o mais próximo possível da superfície predita. O resultado é uma imagem binária na qual os *pixels* pretos representam a floresta.

A abordagem apresentada acima pode ser considerada eficiente para o que se propõe, contudo, pode-se dizer que nem todo o potencial associado às técnicas *fuzzy* foi utilizado. Além disso, a equação empregada no cálculo de regressão linear é obtida através de um ajuste manual para cada grupo de imagens trabalhado, tornando o método pouco automatizado.

A proposta do presente trabalho consiste em seguir as técnicas já existentes de predição espaço-temporal, porém, fazendo uso de técnicas evolutivas e sistemas de inferência *fuzzy*. O modelo proposto baseia-se em regras fundamentadas no conhecimento já descrito em trabalhos publicados, a fim de verificar possíveis melhorias que o emprego de técnicas *fuzzy* pode proporcionar, quando aplicadas de forma mais abrangente ao processo de predição. Programação genética e algoritmos genéticos são empregados como forma de automatizar parte do método desenvolvido.

CAPÍTULO 4

METODOLOGIA

Este capítulo descreve o modelo proposto para realizar a predição espaço-temporal da evolução de regiões florestais, o qual é baseado em conceitos de Inteligência Computacional e pode ser classificado como uma extensão da técnica usada por Centeno e Selleron (2001, 2002). O método proposto baseia-se na comparação de uma seqüência de imagens de sensoriamento remoto obtidas de regiões florestais em diferentes instantes de tempo. Um sistema *fuzzy* aliado a técnicas evolucionárias é aplicado sobre estas imagens para analisar e prever o estado futuro da paisagem destas regiões. O modelo proposto pretende gerar informações úteis para o estudo e análise do comportamento dinâmico de uma região permitindo prever possíveis mudanças na paisagem de uma floresta. Estas informações podem ser utilizadas principalmente com o propósito de auxiliar no monitoramento ambiental, pois apesar da maior acessibilidade dos SIG e dados de sensoriamento remoto por parte de gestores ambientais, o grande volume e diversidade de informações dificultam a análise e tomada de decisões.

4.1 PREDITOR ESPAÇO-TEMPORAL BASEADO EM INTELIGÊNCIA COMPUTACIONAL

Através de informações geográficas referentes ao histórico de evolução da paisagem de determinada região florestal, pretende-se realizar a predição do estado futuro desta região, em uma data específica. Para isso, uma seqüência de imagens de sensoriamento remoto registradas em diferentes instantes de tempo é utilizada. Os dados geográficos espaciais em geral são disponibilizados em formato *raster*, por ser a estrutura de dados tipicamente derivada de *scanners* montados em aviões ou plataformas de satélite (SAINT-JOAN e DESACHY, 1995). As imagens fornecidas e autorizadas para utilização neste trabalho são procedentes do laboratório GEODE localizado na *Université de Toulouse Le Mirail* na França, e correspondem a imagens obtidas por meio de satélites artificiais e aerofotogrametria.

Neste trabalho, os conceitos referentes a relações e raciocínio *fuzzy* são explorados em um projeto de sistema apoiado por técnicas evolutivas. Propõe-se um modelo de inferência geral baseado em um Sistema de Inferência *Fuzzy* (SIF), o qual processa um conjunto de relações *fuzzy* e produz como saída final uma relação *crisp*, representando a imagem predita em uma data pré-determinada.

O processo de predição, quando percebido sob um nível macro (processamento sob o ponto de vista da imagem ao invés do *pixel*), é realizado por um preditor espaço-temporal, baseado em um SIF composto por cinco módulos:

- Módulo de Transformação;
- Módulo *Fuzzificador*;
- Módulo de Inferência Principal;
- Módulo de Agregação;
- Módulo *Defuzzificador*.

A Figura 28 apresenta o mecanismo geral de inferência do SIF proposto.

O processo de predição é iniciado no módulo de transformação, onde os mapas de progressão e regressão são calculados a partir da seqüência de imagens binárias registradas em diferentes instantes de tempo. Depois disso, cada par de relações *crisp* que representam estes mapas é processado no módulo *fuzzificador* dando origem a um par de relações *fuzzy*, as quais representarão os mapas de influência. Estes mapas de influência são apresentados como entradas ao módulo de inferência principal, que produz como saída relações *fuzzy* representadas por matrizes cujos elementos identificam os coeficientes de evolução das diferentes regiões. No caso de existirem imagens binárias suficientes para descrever o fenômeno temporal, a base de dados (ou conjunto de partições) do módulo de inferência principal pode ser otimizada por meio de um algoritmo genético.

Na seqüência, as matrizes de coeficientes de evolução são combinadas através de um operador de média no módulo de agregação, dando origem a uma única relação *fuzzy*. Finalmente, esta relação *fuzzy* pode ser transformada em uma imagem *fuzzy* que descreve todo o fenômeno temporal e será a base para o módulo *defuzzificador*, o qual aplica um mecanismo de limiarização para encontrar a imagem binária predita. Os valores dos limiares são definidos com base em um segundo conjunto de regras *fuzzy* e uma expressão de predição, que calcula o tamanho final da superfície florestal. Esta expressão de predição pode ser obtida de forma automática por meio de um algoritmo de programação genética.

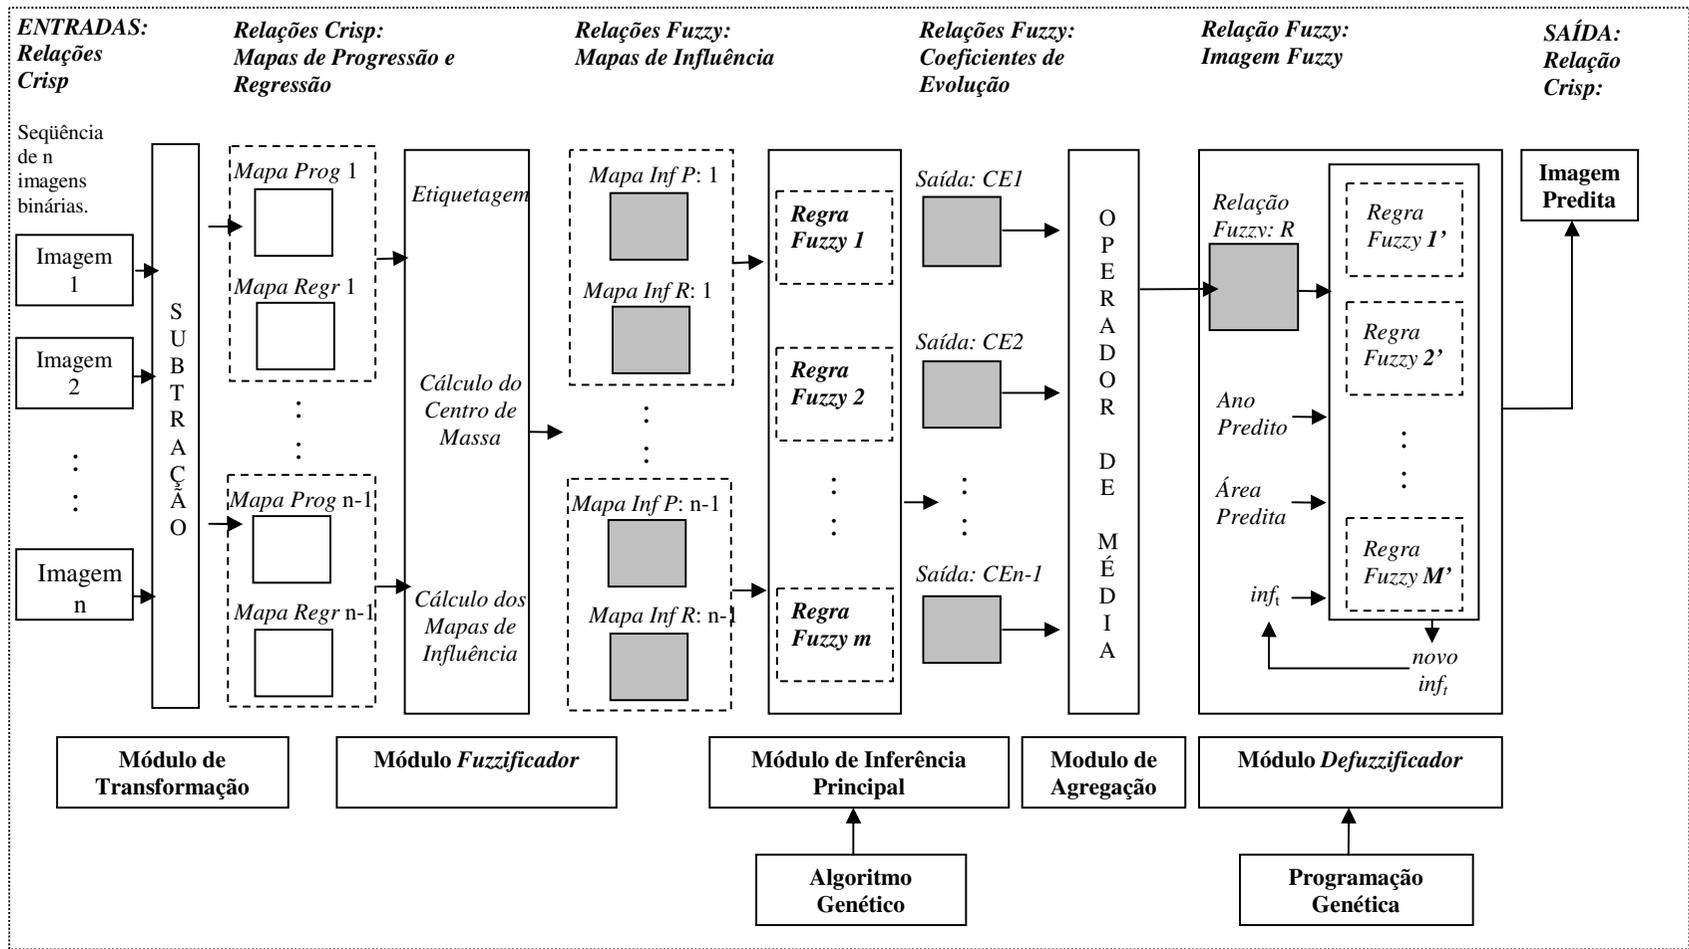


Figura 28: Esquema geral do SIF que representa o preditor espaço-temporal.

Conforme dito anteriormente, o esquema geral de inferência apresentado na Figura 28 pode ser entendido num nível macro (imagem). Entretanto, este processamento geral depende de uma série de manipulações e processos de inferência específicos executados em um nível micro (processamento sob o ponto de vista de cada *pixel* da imagem) como detalhado a seguir.

4.1.1 Módulo de Transformação

No módulo de transformação, uma etapa de pré-processamento é executada através da aplicação de um filtro da mediana. É utilizada uma janela de vizinhança 3x3 e esse procedimento tem como finalidade melhorar a qualidade das imagens, amenizando a presença de ruídos.

Em seguida são calculados os mapas de progressão e regressão. O mapa de regressão corresponde à subtração *pixel a pixel* das imagens tomadas nos instantes t_i e t_{i+1} , e o mapa de progressão à subtração das imagens tomadas em t_{i+1} e t_i . Desta forma, para n instantes de tempo, existirão $n-1$ mapas de progressão e $n-1$ mapas de regressão. Exemplos de alguns mapas com zonas de progressão e regressão são apresentados na Figura 29.

4.1.2 Módulo *Fuzzificador*

Como o próprio nome sugere, o módulo *fuzzificador* é responsável pela transformação das relações *crisp* (mapas de progressão/regressão) em relações *fuzzy* (mapas de influência à progressão/regressão). Três etapas são executadas neste módulo: etiquetagem, cálculo do centro de massa e definição dos mapas de influência.

Etiquetagem

A primeira etapa corresponde à fase de etiquetagem. Depois de definir os mapas de progressão e regressão no módulo de transformação, um algoritmo de etiquetagem (*labeling*) (ROSENFELD e PFALTZ, 1966) é aplicado para identificar regiões conectadas nestes mapas, utilizando uma janela de vizinhança de 8x8. A Figura 30 apresenta um exemplo de aplicação do algoritmo de etiquetagem nos mapas de progressão/regressão apresentados na Figura 29.

É importante salientar que n representa o total de imagens usadas na etapa de treinamento, sendo que para a validação do modelo serão necessárias ainda algumas imagens para teste. O processamento descrito nesta subseção é totalmente baseado na técnica usada por Centeno e Selleron (2001, 2002)

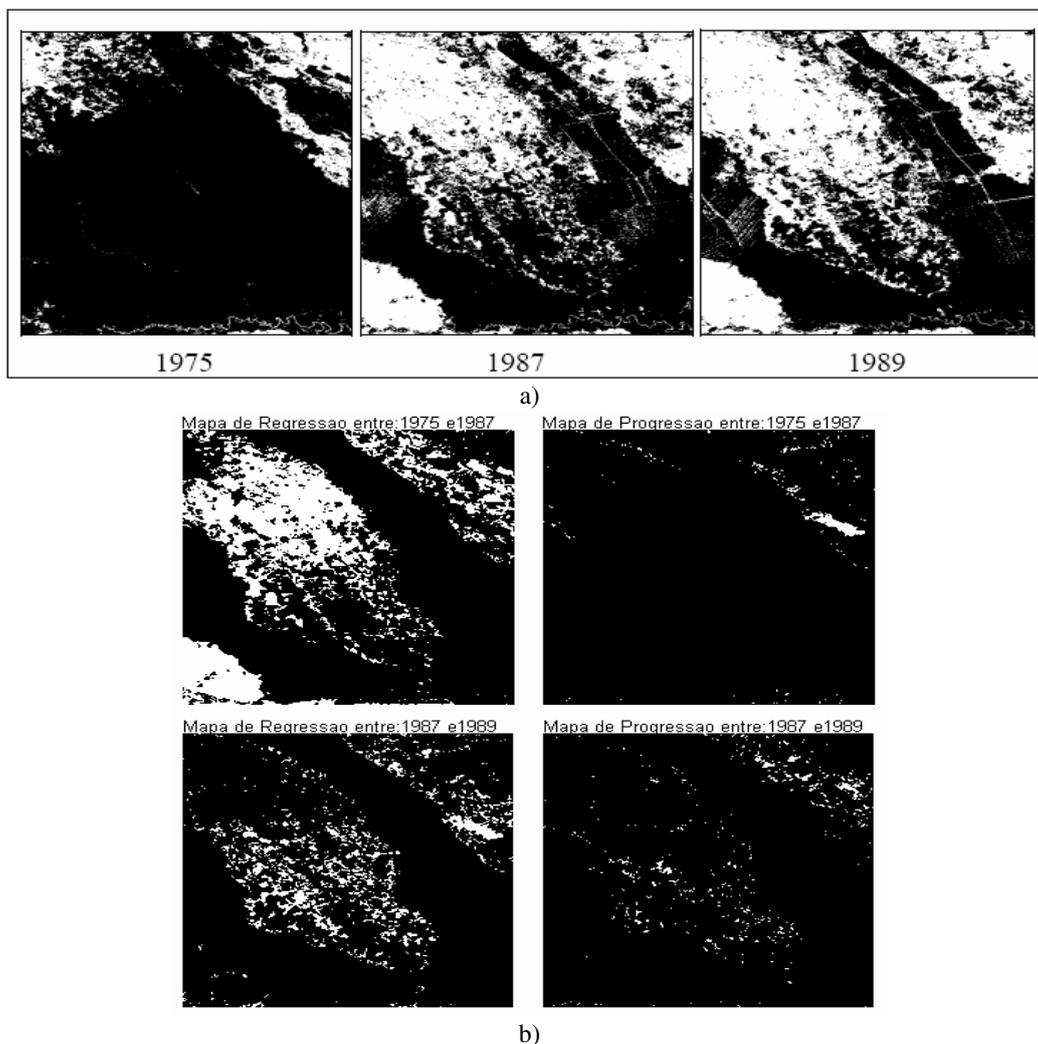


Figura 29: Mapas de progressão e regressão: a) seqüência de imagens registradas em: 1975, 1987 e 1989; b) na primeira linha têm-se os mapas de regressão e progressão gerados com base nos anos de 1975 e 1987, e na segunda linha, com base nos anos de 1987 e 1989.

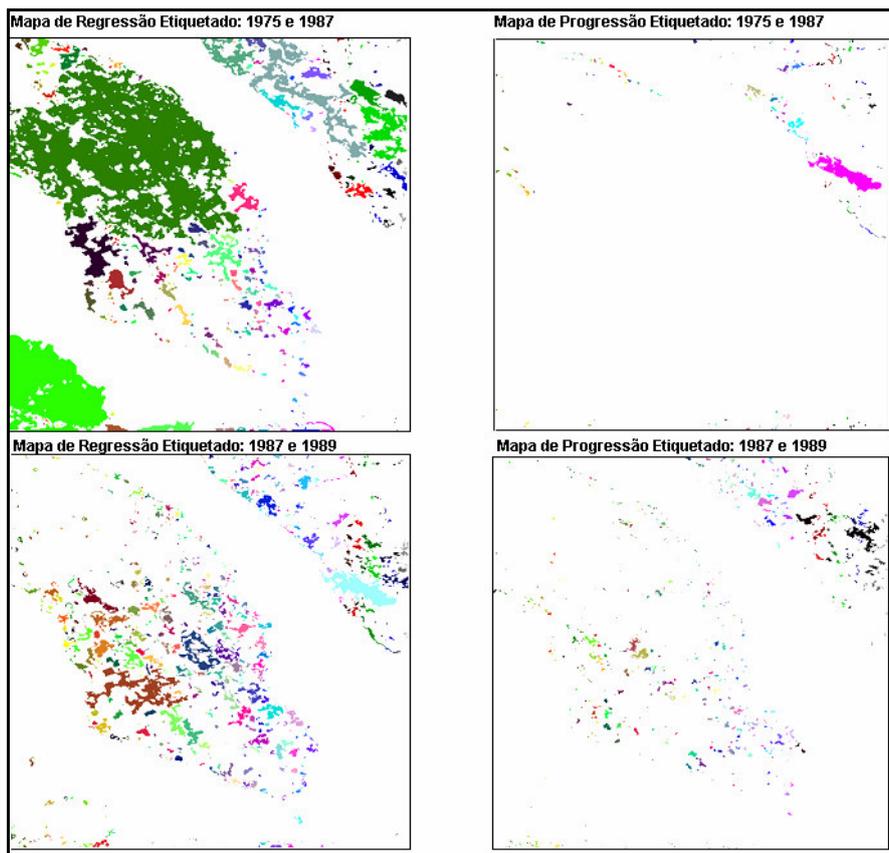


Figura 30: Exemplo de aplicação do algoritmo de etiquetagem.

Cálculo do centro de massa

A próxima etapa do Módulo *fuzzificador* envolve o cálculo do centro de massa (JAIN et al., 1995) de cada região etiquetada nos mapas. Este passo é executado através das equações apresentadas na Seção 3.2.4 do Capítulo 3.

Definição dos mapas de influência

A etapa final deste módulo calcula os mapas de influência. Depois de computar os centros de massa, os mapas de influência à progressão e regressão são gerados através da aplicação (em cada *pixel* dos mapas de progressão e regressão) da equação 13 (adaptada de Centeno e Selleron (2002)). Esta equação leva em consideração a forma de cada região etiquetada, a distância temporal do *pixel* em questão a cada uma destas regiões, e também a distância temporal entre o último ano utilizado para gerar os mapas de progressão e regressão, e o ano a ser predito.

$$Inf_{(i,j)} = \frac{\sum_{k=1}^n \left(\frac{R_k}{D_k} \right)}{T} \quad (13)$$

Onde

i = linha i da imagem etiquetada;

j = coluna j da imagem etiquetada;

n = número de regiões etiquetadas no mapa;

D = distância Euclidiana ao *pixel* mais próximo da região etiquetada.

R = distância Euclidiana entre o *pixel* mais próximo na borda da região etiquetada e o centro de massa da região (equivalente ao raio da região);

T = distância temporal entre o instante t_{n+1} e o instante em que a última imagem usada para gerar os mapas foi registrada.

Portanto, dados $n-1$ pares de mapas de progressão/regressão este módulo infere $n-1$ pares de mapas de influência à progressão/regressão. Estes últimos por sua vez serão usados para definir regiões com maior/menor tendência a aumentar (progredir) ou diminuir (regredir), como detalhado na próxima seção.

4.1.3 Módulo de Inferência Principal

O princípio básico do mecanismo de raciocínio adotado neste módulo considera que uma área próxima a uma região de progressão tem maior tendência de aumentar que outra área que esteja mais afastada desta região. O mesmo princípio é aplicado para as regiões de regressão, ou seja, uma área próxima a uma região de regressão tem maior tendência a diminuir do que outra mais distante. O tamanho das regiões também deve ser levado em consideração, pois regiões maiores têm maior influência sobre seus *pixels* vizinhos do que regiões menores.

A base de regras fixa utilizada para permitir o processo de tomada de decisão neste módulo é composta pelas regras *fuzzy* apresentadas na Tabela 6, as quais foram definidas por um especialista. Todas as regras *fuzzy* consideram duas variáveis de entrada (mapa de influência à progressão e mapa de influência à regressão, ambos calculados no módulo *fuzzificador*) e uma variável de saída que corresponde à tendência do *pixel* regredir, estabilizar ou progredir. Todas as regras *fuzzy* utilizadas são do tipo Mamdani (PEDRYCZ e GOMIDE, 1998).

A base de dados (conjunto de funções de pertinência) deste módulo pode ser definida por um especialista ou por meio de um mecanismo de ajuste automático baseado em algoritmo genético (AG) que distribui as partições nos universos de todas as variáveis envolvidas. O sistema resultante do uso do algoritmo genético para ajuste de parâmetros *fuzzy* é chamado de sistema *fuzzy* genético conforme Cordón et al.(2004), e pode ser considerado quando houver uma seqüência com uma quantidade suficiente de imagens para

	<u>Então</u>	<i>Coefficiente_Evolução</i>	é		
				<i>Progridir_Pouco.</i>	
R2:	<u>Se</u>	<i>Influência_Progressão</i>	é	<i>Média</i>	<u>E</u>
		<i>Influência_Regressão</i>	é	<i>Grande</i>	
	<u>Então</u>	<i>Coefficiente_Evolução</i>	é	<i>Regredir_Muito.</i>	
Fato:	<u>Se</u>	<i>Influência_Progressão</i>	é	u^1	E
		<i>Influência_Regressão</i>	é	u^2	
	<u>Então</u>	<i>Coefficiente_Evolução</i>	é	$B(y)$	

Onde *Influência_Progressão* e *Influência_Regressão* são variáveis lingüísticas e *Pequena*, *Média*, *Grande*, *Regredir_Muito* e *Progridir_Pouco* são termos lingüísticos representados por conjuntos *fuzzy* nos universos $X1$ e $X2$, respectivamente.

A Figura 31 ilustra o processo de inferência escalonada (PEDRYCZ e GOMIDE, 1998) considerando as duas regras *fuzzy* (R1 e R2) mostradas anteriormente. Neste caso, assume-se que o fato é dado por duas entradas *crisp* (representadas por valores em posições arbitrárias u^1 e u^2).

Neste sistema *fuzzy*, considera-se que:

- a agregação dos antecedentes é dada pelo produto algébrico;
- a semântica das regras é definida pelo operador de mínimo;
- a agregação das regras *fuzzy* é realizada pelo operador de máximo;
- e a defuzzificação é baseada no método centróide.

Portanto, cada *pixel* de um dos mapas de influência, combina com seu correspondente antecedente k na i -ésima regra *fuzzy* (*matching* fato/regra dado por μ^i_{mk}). A agregação dos antecedentes por sua vez define, através de um operador específico (operador de agregação que neste caso é o produto), o nível de ativação μ^i da regra *fuzzy*, a qual infere, com base na semântica da regra e em μ^i , um conjunto *fuzzy* subnormal B^{i*} . Este conjunto *fuzzy* inferido será combinado com outros (produzidos pelas demais regras) através do operador de agregação de regras (que neste caso é o máximo) resultando num conjunto *fuzzy* geral $B(y)$ também subnormal. Ao final, este conjunto *fuzzy* é submetido à operação de defuzzificação dando origem ao coeficiente de evolução do *pixel*.

Este processo é repetido para cada *pixel* da imagem, resultando num conjunto de *pixels* que forma a matriz de coeficientes de evolução inferida da base de regras a partir

daquele par de mapas fornecidos como entrada.

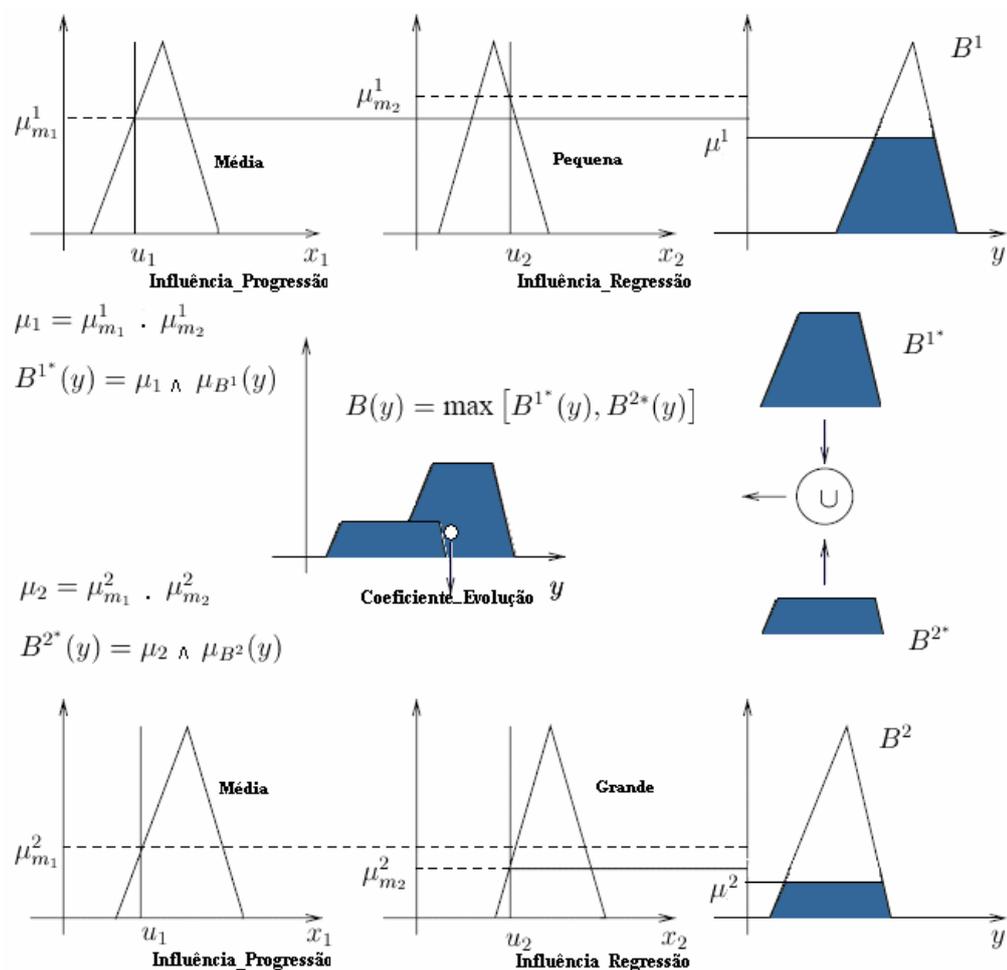


Figura 31: Inferência no Modelo Mamdani.

4.1.4 Módulo de Agregação

A agregação de $n-1$ relações *fuzzy* obtidas do módulo anterior é realizada com base nos operadores de média descritos em Pedrycz e Gomide (1998). O operador adotado neste trabalho considera a média ponderada entre todas as relações *fuzzy*. Os coeficientes dos pesos são empregados para contemplar a diferença temporal entre as relações analisadas (imagens), como descrito na equação 14 a seguir:

$$E_{(i,j)} = \frac{\sum_{m=1}^n (X_{(i,j,m)} / (p - Y_m))}{\sum_{m=1}^n (p - Y_m)} \quad (14)$$

Onde

$E_{(i,j)}$ = Tendência final de evolução para o $pixel(i,j)$.

i = linha i da imagem etiquetada;

j = linha j da imagem etiquetada;

m = índice do mapa de evolução analisado;

n = Número de relações *fuzzy*.

p = ano a ser predito;

$X_{(i,j,m)}$ = $pixel_{(i,j)}$ da relação *fuzzy* m ;

Y_m = Ano da imagem mais recente usada para gerar o mapa de evolução analisado;

O modulo de agregação produz uma única matriz (relação *fuzzy*) cujos elementos variam no intervalo [0; 1], representando a tendência à evolução de todas as regiões da imagem. Finalmente, esta relação *fuzzy* é transformada em uma imagem em tons de cinza com *pixels* cujos valores estão entre [0, 255]. A imagem gerada é chamada de imagem *fuzzy* e permite a visualização do fenômeno temporal que está ocorrendo na região. Nesta imagem *fuzzy*, os tons claros correspondem à alta tendência à regressão, enquanto os tons escuros, à alta tendência à progressão. A imagem *fuzzy* resultante do exemplo apresentado nos módulos anteriores é ilustrada na Figura 33 (a).

4.1.5 Módulo Defuzzificador

Uma imagem binária predita é produzida neste módulo com base em um método de multi-limiarização que considera o número de *pixels* em cada nível de cinza da imagem *fuzzy* (histograma). Para chegar à imagem binária, aplicam-se limiares inferiores e superiores na matriz de coeficientes de evolução (relação *fuzzy*) associada com a imagem *fuzzy* resultante do módulo de agregação.

Neste contexto, todos os *pixels* na relação *fuzzy* com coeficientes de evolução (no intervalo [0; 1]) maiores que o limiar superior (sup_i) são representados por 1. Os *pixels* cujo coeficiente de evolução é menor que o limiar inferior (inf_i) são representados por 0. Os demais *pixels* mantêm seus valores binários de acordo com a imagem mais recente que se tem da região. Desta forma, o intervalo $[0; inf_i] \cup [sup_i; 1]$ define a influência da imagem *fuzzy*, enquanto o intervalo $[inf_i, sup_i]$ define a influência da imagem mais recente no resultado final.

Testes com diferentes valores de limiares são realizados, até se chegar ao tamanho de superfície final mais próximo possível do valor de superfície obtido pelo método de regressão para o instante t_{n+1} (este valor de superfície pode ser obtido através do algoritmo de PG como descrito na Seção 4.2.1). Portanto, a imagem binária final obtida com o emprego dos melhores limiares corresponde à imagem predita para o instante t_{n+1} .

4.1.5.1 Base de Regras *Fuzzy* para o processo de Multi-Limiarização

Um segundo conjunto de regras *fuzzy* está sendo proposto, para auxiliar e acelerar o processo de limiarização no módulo *defuzzificador* (ver Figura 28). Neste módulo, as regras *fuzzy* consideram três variáveis de entrada (Limiar Inferior, Diferença entre a Superfície Obtida e a Superfície Esperada, e Distância Temporal entre o ano a ser predito e o último ano utilizado para treinamento), e uma variável de saída (Novo Limiar Inferior), como apresentado na Tabela 7.

Tabela 7: Regras *fuzzy* do Processo de Multi-Limiarização.

Limiar Inferior	Diferença Superfícies	Dist. Predição	Novo Limiar Inferior
Mínimo	Pequena	Pequena	Muito Pequeno
Muito Pequeno	Pequena	Pequena	Pequeno
Pequeno	Pequena	Pequena	Médio
Médio	Pequena	Pequena	Médio
Mínimo	Grande	Pequena	Pequeno
Muito Pequeno	Grande	Pequena	Médio
Pequeno	Grande	Pequena	Médio
Médio	Grande	Pequena	Médio
Médio	Pequena	Grande	Pequeno
Pequeno	Pequena	Grande	Muito Pequeno
Muito Pequeno	Pequena	Grande	Mínimo
Mínimo	Pequena	Grande	Mínimo
Médio	Grande	Grande	Muito Pequeno
Muito Pequeno	Grande	Grande	Mínimo
Pequeno	Grande	Grande	Mínimo
Mínimo	Grande	Grande	Mínimo

Diferente do módulo principal que permite um ajuste automático, neste trabalho as partições do universo do módulo *fuzzificador* são sempre fixas e definidas por um especialista. Todas as simulações realizadas consideraram funções Gaussianas uniformemente distribuídas ao longo do universo de cada variável, como apresentado na Figura 32.

Neste módulo todo o processamento é realizado no nível micro, ou seja, há um processo de inferência completo que considera a agregação dos antecedentes dada pelo operador de mínimo; a semântica das regras é definida pelo operador de mínimo; a agregação das regras *fuzzy* é realizada pelo operador de máximo e a defuzzificação é baseada no método centróide.

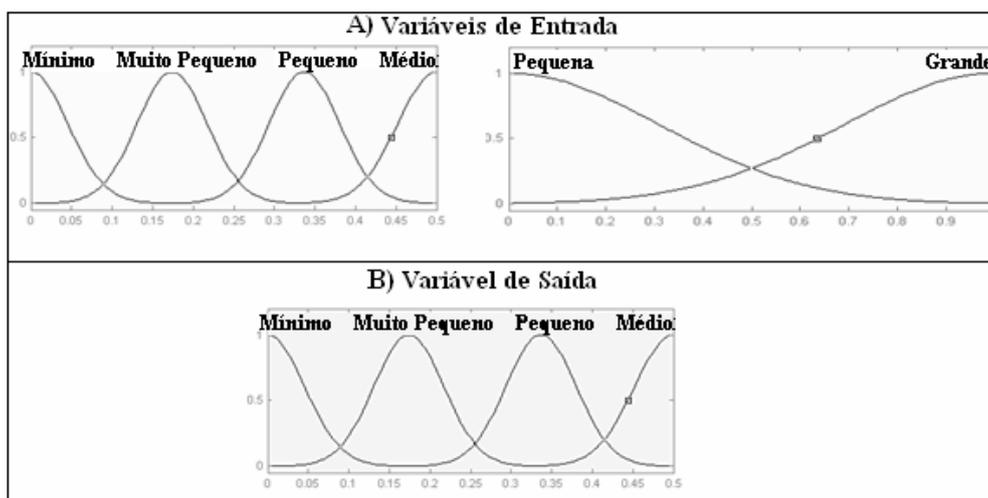


Figura 32: Funções de pertinência das regras *fuzzy* do processo de multi-limiarização: em a) as variáveis de entrada e em b) a variável de saída.

O mecanismo de raciocínio baseia-se nas seguintes questões:

- O limiar inferior é sugerido por este segundo conjunto de regras *fuzzy*. Enquanto a superfície obtida através dos limiares atuais não alcançar a superfície predita, as regras *fuzzy* sugerem um novo valor para o limiar inferior.
- Um novo limiar superior pode ser calculado baseado na negação do primeiro valor. Neste trabalho assume-se que eles são complementares, ou seja, $(new_{sup} = 1 - new_{inf})$;
- A diferença entre a superfície predita (definida pela expressão de regressão) e a superfície obtida com os limiares atuais é usada para decidir por aumentar o limiar inferior e diminuir o superior, ou vice-versa;
- A distância temporal entre o ano a ser predito e o último ano de treinamento pode ser utilizada para definir o tamanho do passo para as atualizações dos valores dos limiares.

Depois de definir o par de limiares adequados através da base de regras *fuzzy* apresentada (este processo é chamado de procedimento de busca global), uma busca local (ou ajuste fino) é feita para otimizar estes valores. Esta busca local atualiza os valores atuais por meio de um passo de tamanho fixo = 0.001 como em Centeno e Selleron (2001, 2002). Portanto, temos:

$$new_{inf} = inf_t + 0.001$$

$$new_{sup} = sup_t - 0.001$$

Desta forma, na busca local o limiar inferior vai sendo incrementado enquanto o limiar superior é decrementado na mesma proporção. Este processo é repetido até que a superfície florestal (total de *pixels* pretos) identificada com os limiares atuais alcance o valor predito pelo algoritmo de GP ou cálculo de regressão linear.

Através do processo de multi-limiarização, é possível calcular quais *pixels* se tornarão pretos ou brancos na imagem binária final. Considerando os exemplos ilustrados nos módulos anteriores, através da imagem *fuzzy* apresentada na Figura 33 (a) pode-se gerar a imagem binária ilustrada na Figura 33 (b).

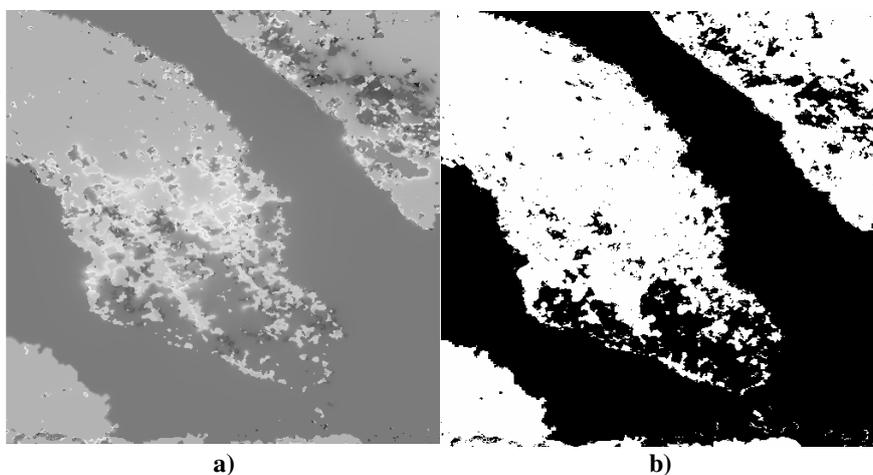


Figura 33: Exemplo do processo de multi-limiarização: a) Imagem *Fuzzy*; b) Imagem Binária Predita.

4.2 TÉCNICAS EVOLUTIVAS

Neste trabalho, duas técnicas inspiradas na computação evolutiva podem ser adotadas para aumentar a autonomia do sistema. No primeiro caso, um algoritmo de programação genética pode ser utilizado para automatizar o ajuste dos parâmetros do modelo de regressão empregado no módulo *defuzzificador*. No segundo caso, um algoritmo genético pode ser utilizado para ajustar automaticamente as funções de pertinência do primeiro conjunto de regras *fuzzy* (ou seja, a base de dados do módulo de inferência principal). A seguir são apresentados detalhes sobre o emprego destes dois métodos evolutivos no preditor espaço-temporal desenvolvido.

4.2.1 Programação Genética para Calcular o Tamanho da Superfície Preditada

Esta seção descreve o algoritmo de programação genética (PG) usado para prever o número de *pixels* floresta na região analisada (ou seja, *pixels* que supostamente serão pretos na imagem predita final). A solução apresentada pela abordagem de PG determina a classe e os coeficientes da função a ser adotada no modelo de regressão. A saída deste modelo de regressão define o tamanho da superfície predita e esta será utilizada como entrada para o segundo conjunto de regras *fuzzy* (regras do módulo *defuzzificador*, como ilustrado na Figura 28).

O algoritmo de PG proposto está focado na indução de expressões matemáticas baseadas nos dados de estudo, ou seja, executa o processo chamado de regressão simbólica (KOZA, 1992). O objetivo principal da regressão simbólica é encontrar uma função que se aproxime ao máximo de outra função desconhecida através de um determinado conjunto de dados. No algoritmo desenvolvido, o algoritmo de PG busca por expressões matemáticas que apresentem uma boa aproximação à curva de evolução da superfície florestal da região em estudo. Ele considera o tamanho das superfícies das imagens existentes e a diferença temporal entre esses instantes. Então, para um conjunto de imagens registradas em n instantes de tempo, o número de *pixels* floresta (*pixels* pretos) será predito para o instante t_{n+1} , com base na melhor solução apresentada pelo algoritmo de PG. A melhor solução neste caso será uma expressão cujos valores de saída resultem no menor erro de aproximação que neste caso é uma modificação do erro quadrático médio (EQM). O método leva em consideração todos os pontos do fenômeno temporal destinados para treinamento, assumindo que os pontos finais têm maior influência.

Basicamente, o algoritmo de PG gera uma população de expressões matemáticas (indivíduos), avalia cada indivíduo com base na expressão que ele representa, usa métodos de seleção para definir quais expressões irão sobreviver, aplica operadores genéticos para modificar expressões existentes e gerar novas, a fim de convergir para uma boa solução.

A Figura 34 ilustra o esquema geral do algoritmo de PG proposto.

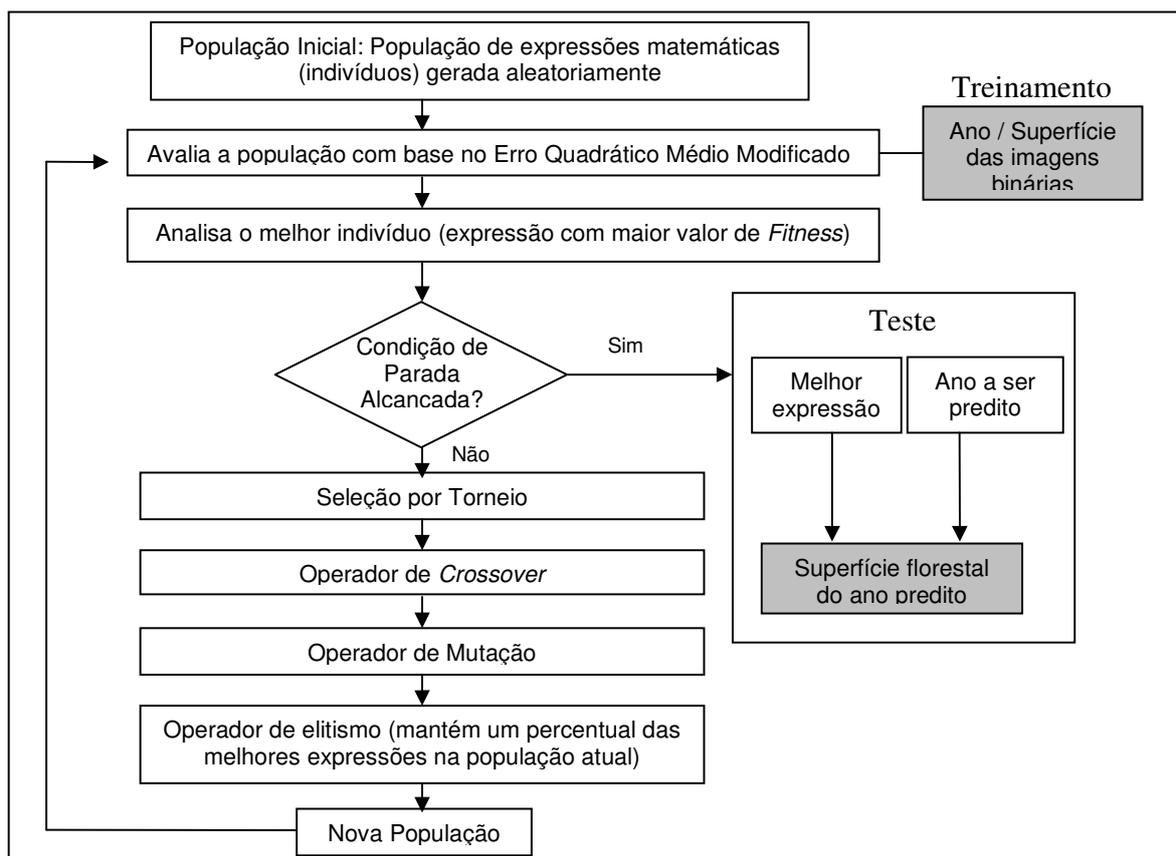


Figura 34: Esquema do algoritmo de PG desenvolvido.

Na seqüência serão descritas algumas das principais características relacionadas ao algoritmo de PG desenvolvido.

Parâmetros de Entrada

- Vetor com todos os instantes temporais (anos) usados no processo de treinamento e seus respectivos tamanhos de superfície florestal;
- Profundidade máxima das árvores de sintaxe abstrata que representarão os indivíduos (expressões);
- Número total de indivíduos que irão compor a população;
- Condições de parada: número máximo de gerações ou valor de erro quadrático médio modificado (EQMm) aceitável.

Codificação

Os indivíduos são representados por árvores de sintaxe abstrata, compostas pela livre combinação de funções e terminais, os quais são descritos a seguir:

- Conjunto de Funções: +, -, /, *, ^, exp, log, sqrt, pow2 (potência de base 2).
- Conjunto de Terminais: t (Variável dependente que representa a unidade temporal), 1, 2, 3, 4, 5, 6, 7, 8, 9.

Para garantir somente soluções factíveis é imposta a condição de que a variável t deve estar presente em pelo menos um dos nós que compõem a árvore de sintaxe abstrata.

População Inicial

A população é iniciada com base no método *Ramped-half-and-half* (KOZA, 1992), apresentado na Seção 2.2.4 do Capítulo 2. A profundidade máxima das árvores geradas é definida pelo usuário.

Avaliação da População (*Fitness*)

Para cada indivíduo (equação ou expressão matemática), o valor de t é substituído pelo ano desejado e o resultado obtido corresponde à superfície florestal (total de *pixels* pretos) para este ano específico. Este processo é repetido com todos os anos destinados para treinamento. Um erro quadrático médio modificado (EQMm) é calculado considerando as saídas geradas pela expressão sugerida pela programação genética e os valores reais, onde há maior influência do erro identificado no ano mais recente considerado para treinamento. A equação utilizada para calcular o Erro Quadrático Médio neste ponto corresponde à equação 15.

$$EQMm = \frac{\sqrt{\left(\sum_{k=1}^n (Y_k - S_k)^2 \right) + (Y_n - S_n)^2}}{n} \quad (15)$$

Onde
 k = Ano que está sendo analisado;
 Y = resultado da expressão (indivíduo) para o ano em questão;
 S = Superfície real para o ano em questão;
 n = número de anos analisados;

Para contemplar a propriedade de fechamento (Ex.: divisão por 0), é imposta uma penalidade na função de avaliação como forma de tratar algumas das soluções infactíveis.

Processo de Seleção

O método aplicado corresponde ao torneio (GOLDBERG e DEB, 1991). Assim, um conjunto composto por 30% dos indivíduos (selecionados aleatoriamente) da população é criado. O indivíduo deste grupo que possuir o melhor *fitness* (ou menor EQMm) é selecionado para representar um possível pai.

Crossover

O *crossover* é baseado na escolha aleatória de um ponto de corte (nó) em cada pai selecionado (árvore). Depois de selecionado o ponto de corte, todos os componentes (funções e terminais) dos nós posteriores a este ponto de corte são trocados, conforme ilustrado na Figura 17 do Capítulo 2.

Mutação

Diferente do operador de mutação padrão, a mutação considerada aqui está associada a um indivíduo ao invés de um gene. Portanto, a taxa de mutação adotada na fase de simulações teve que ser aumentada em relação aos valores comumente utilizados nestes algoritmos. Três diferentes tipos de mutação podem ser aplicados:

- Mutação Tipo 1: Cria uma nova sub-árvore para substituir a sub-árvore do nó selecionado.
- Mutação Tipo 2: Altera todas as constantes que compõem a sub-árvore do nó selecionado.
- Mutação Tipo 3: Altera o valor do nó selecionado. Se o nó é um terminal, este será substituído por outro terminal. Se o nó é uma função, será substituído por outra função de mesma aridade.

Estas três formas de mutação mostram-se mais interessantes em diferentes estágios da evolução. Isto porque nas gerações iniciais, é importante explorar todo o espaço de busca para encontrar regiões promissoras. Assim, modificações maiores devem ser mais comuns nesta fase. Contudo, nas gerações finais, esperam-se modificações menores a fim de otimizar as possíveis soluções já encontradas.

Desta forma, inicialmente, mutações dos tipos 1, 2 e 3 são aplicadas com probabilidades de 0,5, 0,3 e 0,2, respectivamente. Ao longo da evolução, a taxa de mutação do tipo 1 diminui enquanto as taxas dos tipos 2 e 3 aumentam. Assim, no estágio final do processo evolutivo, a probabilidade do tipo 1 ocorrer é muito pequena, enquanto as probabilidades do tipo 2 e 3 tornam-se maiores (especialmente o tipo 2). No Capítulo 5, os resultados das simulações considerando o método de PG são comparados com os obtidos considerando a definição de um especialista para a função de regressão.

4.2.2 Algoritmo Genético para ajustar a Base de Dados no Módulo de Inferência Principal

Quando há informação suficiente disponível, pode ser interessante liberar o usuário da definição de alguns parâmetros do modelo *fuzzy*. Nestes casos considera-se que o sistema pode aprender através dos dados. Esta seção descreve como um algoritmo genético pode otimizar a partição *fuzzy* de todas as variáveis da base de regras do módulo de inferência principal. A justificativa para a escolha da base de dados, apenas, se deve em função de ser esta a que mais influencia no processo de inferência e, cujo ajuste, nem sempre é facilmente realizável de forma manual.

Portanto, no algoritmo genético proposto, cada indivíduo que compõe a população representa todo o conjunto de funções de pertinência (a base de dados) desta base de regras. O *fitness* de cada indivíduo é calculado através da completa execução do processo de predição espaço-temporal. O sistema realiza uma predição para a região de estudo no último instante de tempo usado para treinamento. Para avaliar o indivíduo, compara-se a imagem predita com a imagem real existente para o mesmo ano. Este processo é repetido até que o número máximo de gerações seja alcançado, ou o nível de similaridade entre as imagens predita e real seja considerado aceitável.

A Figura 35 ilustra o esquema geral do algoritmo genético desenvolvido.

Depois de definir o melhor conjunto de funções de pertinência para a região em estudo, pode-se utilizar este conjunto otimizado para gerar predições para a região em diferentes anos. Em função disso, assume-se que o instante de tempo considerado para teste deve ser diferente do adotado no processo de treinamento.

A seguir são apresentadas características relacionadas à codificação e parâmetros de entrada empregados no algoritmo genético desenvolvido.

Parâmetros de Entrada

- Conjunto de imagens binárias registradas e o ano a ser predito
- Número total de indivíduos que irá compor a população;
- Condições de parada: número máximo de gerações ou nível de similaridade aceitável entre a imagem predita e imagem real de treinamento.

(S_k) corresponde ao tipo de função: valor 1 para triangular, 2 para trapezoidal e 3 para gaussiana. Os parâmetros L_k e R_k definem o tamanho da abertura esquerda e direita da função k , respectivamente; C_{1k} é a distância entre o ponto inicial do núcleo da função de pertinência k e o ponto final do núcleo da função de pertinência ($k-1$); C_{2k} é o tamanho do núcleo da função de pertinência k . Considerando o tipo trapezoidal, os valores decodificados (l_k, c_{1k}, c_{2k}, r_k) podem ser calculados como:

$$c_{1k} = c_{2k-1} + C_{1k};$$

$$c_{2k} = c_{1k} + C_{2k};$$

$$l_k = c_{1k} - L_k;$$

$$r_k = c_{2k} + R_k.$$

Com base nestes valores decodificados, é possível calcular os parâmetros absolutos para cada função de pertinência, conforme apresentado na Tabela 8.

Tabela 8: Parâmetros absolutos das funções de pertinência.

	Funções Triangulares	Funções Trapezoidais	Funções Gaussianas
Parâmetros Absolutos das Funções	$\{l_k, \frac{c_{1k} + c_{2k}}{2}, r_k\}$	$\{l_k, c_{1k}, c_{2k}, r_k\}$	$\{\frac{c_{1k} + c_{2k}}{2}, \frac{L_k + C_{2k} + R_k}{6}\}$

As principais características do algoritmo genético adotado aqui são apresentadas a seguir.

População Inicial

A população inicial é composta por funções de pertinência distribuídas uniformemente. Cada indivíduo é formado pela livre combinação das funções triangular, trapezoidal e gaussiana.

Avaliação dos Indivíduos (*Fitness*)

O mecanismo de inferência descrito no módulo de inferência principal (Figura 28) é executado considerando que cada indivíduo representa uma possível solução (ou seja, uma base de dados ou partição específica). Este processo irá produzir a imagem final predita para o dado ano. A imagem final é comparada com a imagem real existente para

este mesmo ano, e o nível de similaridade identificado entre as duas imagens é usado como valor de *fitness* do indivíduo correspondente.

O nível de similaridade é obtido através da seguinte relação I_A/S_A , onde I_A corresponde ao número de *pixels* que são iguais (possuem a mesma cor) na imagem predita e na imagem real para o ano A . S_A corresponde à superfície total da imagem no ano A . Ou seja, é realizado um cálculo de proporção do número de acertos em relação ao total de *pixels* que poderiam ter sido acertados.

Processo de Seleção

O método de seleção por torneio é aplicado (GOLDBERG e DEB, 1991), usando um conjunto composto de 10% dos indivíduos da população. O indivíduo do grupo com melhor *fitness* (maior nível de similaridade) será selecionado como um possível pai e os operadores de mutação ou *crossover* serão aplicados de acordo com suas respectivas taxas.

Crossover

Aqui o *crossover* é aplicado na forma padrão. Assim, para cada par de pais gerados, um valor aleatório (r) é gerado. Se $r \leq$ taxa de *crossover*, o ponto de *crossover* simples é escolhido através de uma seleção aleatória e a troca é realizada.

Mutação

A taxa de mutação é considerada para cada gene do indivíduo. Caso a mutação ocorra, a modificação depende do parâmetro selecionado ($S_k, L_k, C_{1k}, C_{2k}, R_k$):

- Parâmetro S_k : o novo valor é escolhido aleatoriamente do conjunto de possíveis funções de pertinência $T = \{1, 2, 3\}$.
- Parâmetro L_k : o novo valor é escolhido do intervalo $[0; (c_{1k} - l_{k-1})]$.
- Parâmetro C_{1k} : novo valor é escolhido do intervalo $[0; (c_{1k+1} - c_{2k-1})]$.
- Parâmetro C_{2k} : novo valor é escolhido do intervalo $[0; (c_{1k+1} - c_{1k})]$.
- Parâmetro R_k : novo valor é escolhido do intervalo $[0; (r_{k+1} - c_{2k})]$.

No processo de mutação, não são consideradas questões de completude e sobreposição (DELGADO, 2002), pois estes fatores serão tratados pelo operador de correção.

Correção

Se um operador genético (*crossover* ou mutação) gerar um conjunto de partições infactível, um operador de correção é aplicado para ajustar o(s) indivíduo(s) que produziu(ram) o erro. Como apresentado em Maruo e Delgado (2006) e Delgado (2002), uma partição é considerada interpretável somente se a sobreposição das funções de pertinência respeitar os limites de $[\gamma_{\min}, \kappa_{\max}]$, onde γ_{\min} é denominada sobreposição mínima permitida e garante a completude da partição e κ_{\max} é chamada de sobreposição máxima permitida e garante a visibilidade no conjunto de partições (DELGADO, 2002). A Figura 37 ilustra os parâmetros de completude e sobreposição de uma partição considerada interpretável.

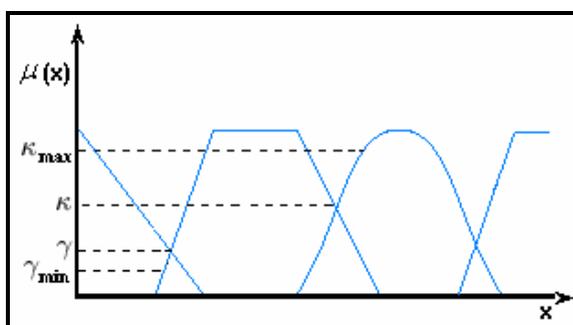


Figura 37: Partição interpretável com $\gamma \geq \gamma_{\min}$ e $\kappa \leq \kappa_{\max}$.

A correção depende do local onde a inconsistência ocorre e o tipo da função de pertinência que será alterada.

Para funções trapezoidal e triangular, o processo é mais simples, pois no caso de partições onde $\gamma < \gamma_{\min}$, o operador muda o parâmetro L_{i+1} onde $i+1$ é a função localizada à direita onde o erro acontece. Neste caso, o valor de L_{i+1} é acrescido de um Δ de forma que, $\gamma = \gamma_{\min}$ no ponto onde a função i sobrepõe a função $i+1$. No caso de partições onde $\kappa > \kappa_{\max}$, o operador muda o parâmetro C_{i+1} onde $i+1$ é a função localizada à direita onde o erro acontece. Desta forma, o valor de C_{i+1} é acrescido de um Δ de modo que, $\kappa = \kappa_{\max}$ no ponto onde a função i sobrepõe a função $i+1$.

Para funções Gaussianas, por serem simétricas, não é possível corrigir um lado sem afetar o outro. Por isso, os parâmetros da função gaussiana corrigida (ν , σ) são obtidos através da solução do seguinte sistema de equações, empregado em Maruo (2006):

$$\begin{cases} x_1 = v - \sigma \sqrt{-2 \ln \mu_1} \\ x_2 = v - \sigma \sqrt{-2 \ln \mu_2} \end{cases}$$

Onde

μ_1 e μ_2 são valores de pertinência onde a função i sobrepõe as funções $(i-1)$ e $(i+1)$, respectivamente.

x_1 é o valor de suporte onde a função $(i-1)$ sobrepõe o ponto $\mu_1' = \max(\gamma, \min(\mu_1, \kappa))$.

x_2 é o valor do suporte onde a função $(i+1)$ sobrepõe o ponto $\mu_2' = \max(\gamma, \min(\mu_2, \kappa))$.

(16)

A Figura 38 ilustra dois exemplos de correção de partições *fuzzy* para garantir a interpretabilidade do modelo. Nestes exemplos, a função de pertinência gaussiana, é corrigida de forma a manter a completude mínima e sobreposição máxima com relação à função de pertinência trapezoidal localizada à sua esquerda.

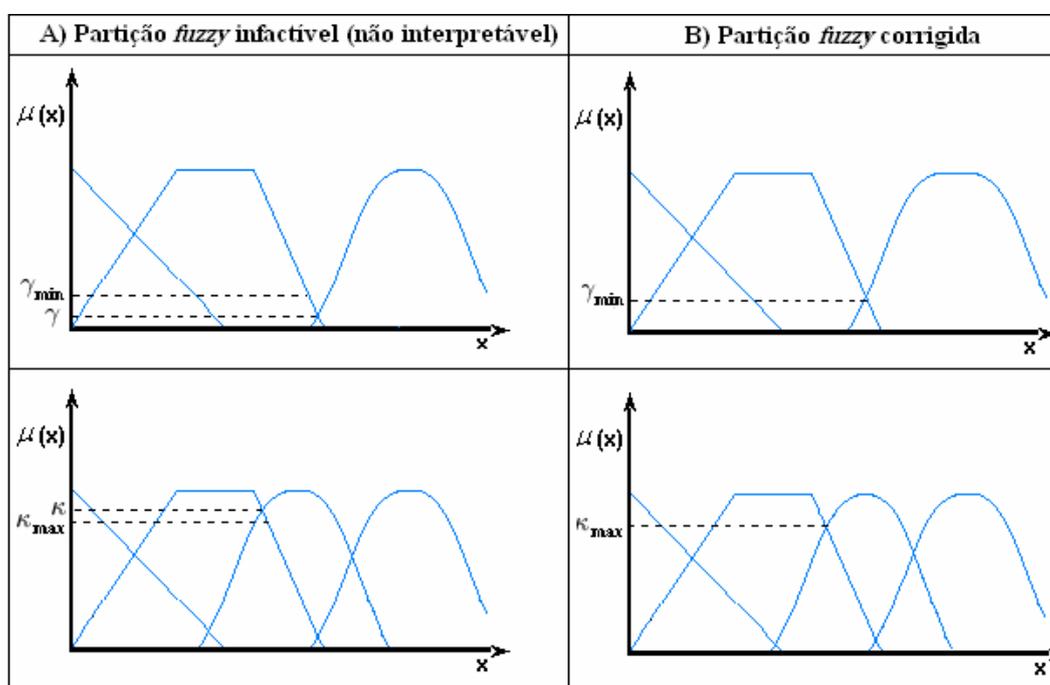


Figura 38: Exemplos de correção de partições *fuzzy* para garantir a interpretabilidade do modelo. Em A) a partição infactível, e em B) a partição corrigida.

CAPÍTULO 5

SIMULAÇÕES E RESULTADOS

5.1 PREDIÇÃO ESPAÇO-TEMPORAL EM REGIÕES FLORESTAIS

Este capítulo tem como objetivo validar o desempenho da abordagem proposta, através da realização de previsões para regiões com diferentes tendências de evolução florestal e comparação com outras abordagens desenvolvidas para o mesmo propósito. O modelo de previsão espaço-temporal proposto foi aplicado no estudo de três regiões: a floresta de Ticoporo, na Venezuela (imagem de 512 x 512 *pixels*); a região de La Joyanca, na Guatemala (imagem de 462 x 353 *pixels*); e a floresta de Tabe, na França (imagem de 459 x 504 *pixels*). As imagens de sensoriamento remoto obtidas de cada região são apresentadas nas Figuras 39, 40 e 41. A região específica da floresta de Ticoporo, na Cordilheira dos Andes, contém uma floresta privada usada para exploração industrial. Em função disto, nesta área o desmatamento não apresenta um comportamento contínuo. Para executar a análise da região sem considerar esta área privada, a máscara ilustrada na Figura 39(b) foi aplicada nas imagens apresentadas na Figura 39(a), antes de iniciar o processo de previsão.

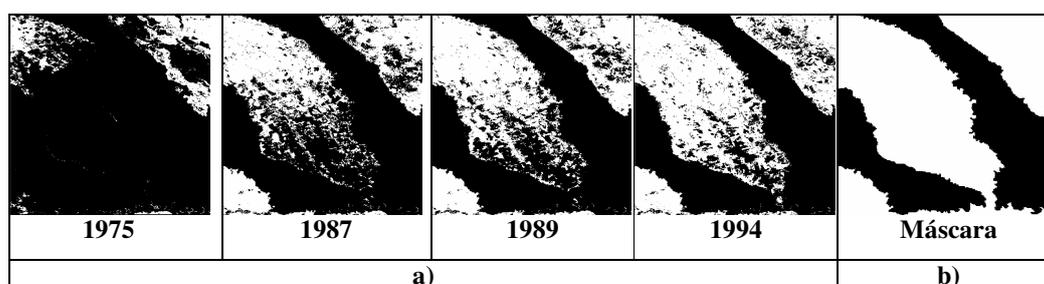


Figura 39: Dados da Floresta de Ticoporo. a) Imagens registradas. b) Máscara da Floresta Industrial.

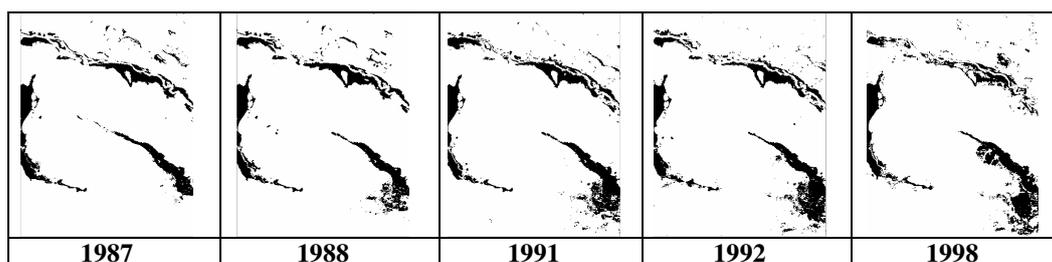


Figura 40: Imagens da floresta localizada em La Joyanca.

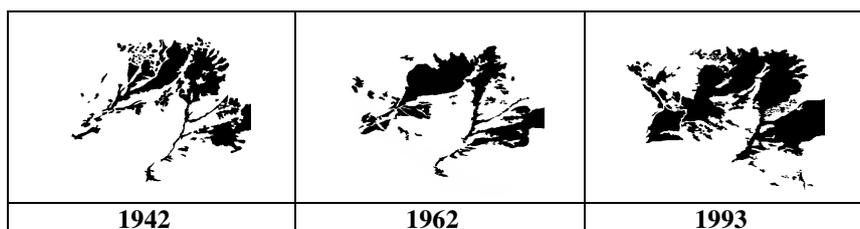


Figura 41: Imagens da floresta de Tabe.

Como se pode notar, em geral o número de informações (imagens) disponíveis sobre o histórico de evolução de cada região não é muito significativo. E, além disso, a distância temporal entre cada imagem registrada pode variar bastante, dificultando a utilização de métodos de predição tradicionais. Neste sentido, a proposta de um método de predição que seja capaz de se adaptar à análise de cada região mostra-se uma alternativa bastante atrativa.

Algumas variações do método proposto serão comparadas com outros métodos voltados para predição de evolução florestal. Portanto, cinco abordagens denominadas aqui de Preditores Espaço-Temporal (*Spatio-Temporal Predictors* - STP) baseadas em diferentes metodologias serão consideradas nesta seção:

- AutomataSTP: abordagem baseada em autômatos celulares para realização de predição espaço-temporal (CENTENO, SELLERON e GONÇALVES, 2003) (mais detalhes na Seção 3.3);
- MathFormSTP: abordagem baseada em fórmulas matemáticas e alguns conceitos de conjuntos *fuzzy* para realização de predição espaço-temporal (CENTENO e SELLERON, 2001, 2002) (mais detalhes na Seção 3.3);
- Abordagens propostas:
 - FuzzySTP: abordagem baseada em um esquema de inferência *fuzzy* (ver Figura 28) para realização de predição espaço-temporal, onde os parâmetros do sistema *fuzzy* e os coeficientes da regressão linear são inteiramente definidos por um especialista.
 - FuzzyGPSTP: Semelhante ao FuzzySTP, mas contém adicionalmente um algoritmo de programação genética que permite automatizar a busca da função de regressão.
 - SoftCompSTP: Semelhante ao FuzzyGPSTP, mas contém adicionalmente um algoritmo genético que trabalha na otimização do conjunto de partições *fuzzy* (base de dados) no Módulo de Inferência Principal.

5.1.1 Conhecimento Obtido Através do Especialista

A primeira abordagem proposta, a FuzzySTP, é comparada com outras técnicas existentes (AutomataSTP e MathFormSTP) para validar o sistema na predição da evolução florestal de uma região na Venezuela (Ticoporo). A abordagem FuzzySTP, é composta por um sistema *Fuzzy* como apresentado na Figura 28. Contudo, nesta primeira proposta, este sistema é composto por uma base de conhecimento fixa (base de regras + base de dados) (JANG, SUN e MIZUTANI, 1997) que é definida por um especialista, como ilustrado na Tabela 6 e Figura 47 respectivamente.

As três abordagens comparadas nesta seção empregam um método de regressão linear para definição do tamanho da superfície final da imagem. Neste caso, a classe e coeficientes da função de regressão são ajustados manualmente. Os resultados apresentados na Figura 42 ilustram os níveis de similaridade identificados entre as imagens predita e real no ano de 1994, bem como uma visualização das diferenças identificadas entre estas.

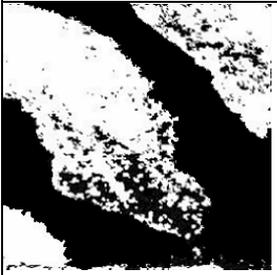
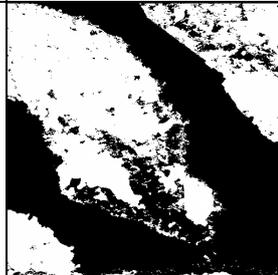
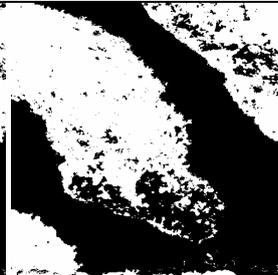
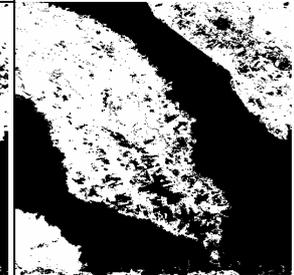
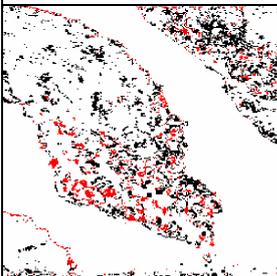
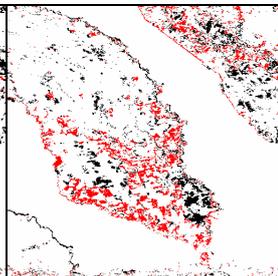
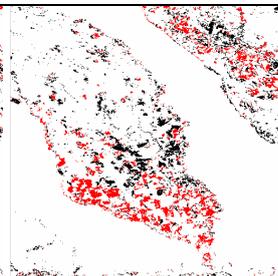
Nível de Similaridade para Ticoporo – 1994			Imagem Real
AutomataSTP	MathFormSTP	FuzzySTP	
88.6%	89.28%	89.57%	
			
Diferenças entre a imagem predita e real			
			
	Pixels que são brancos na imagem real e pretos na imagem predita.		
	Pixels que são pretos na imagem real e brancos na imagem predita.		
	Pixels que são iguais na imagem real e na imagem predita.		

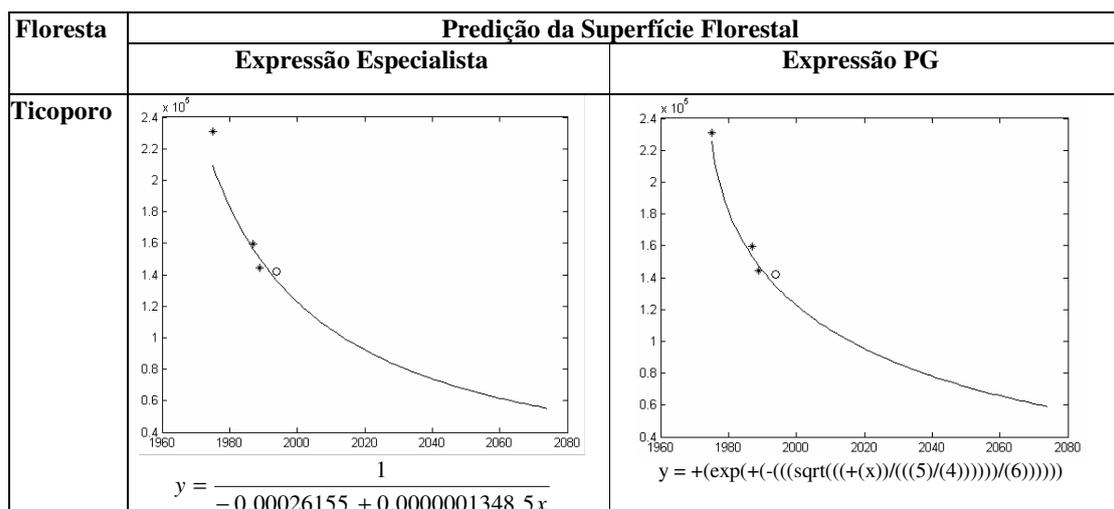
Figura 42: Comparação dos resultados da predição para Ticoporo.

Como as metodologias empregadas nesta comparação fazem uso de diferentes ferramentas computacionais para realizar predição espaço-temporal, não foi possível comparar o custo computacional associado a cada uma delas. Assim, é importante ressaltar que o termo ‘desempenho’ empregado nesta seção, refere-se unicamente ao nível de semelhança entre a imagem real e a predita, e não à velocidade de execução do processo.

5.1.2 Expressão Simbólica Obtida de Forma Automática

Durante a fase de desenvolvimento, o FuzzySTP foi modificado para incorporar um mecanismo automático de definição da função de regressão. Este nível maior de autonomia foi alcançado por meio de um algoritmo de programação genética (ver a Seção 4.2.1 para maiores detalhes), e esta atualização foi chamada de FuzzyGPSTP.

A Figura 43 apresenta os resultados obtidos pelo método de regressão linear cujos coeficientes são definidos por um especialista (Expressão Especialista) e a regressão simbólica baseada em PG (Expressão PG). Nesta figura, os dados utilizados para treinamento são representados pelo símbolo ‘*’ e o ponto utilizado para teste pelo símbolo ‘o’. No caso da floresta de Tabe, em função de não haver muitas informações (imagens) disponíveis, optou-se por utilizar todos os dados para treinamento, sendo descartada a possibilidade de validação com um ponto de teste nesta região.



disso, como se pode notar na Figura 43, a abordagem FuzzyGPSTP trabalha com a não-linearidade existente nos dados de uma maneira mais eficiente, permitindo expressões simbólicas obtidas de forma flexível, e cuja previsão seja otimista (progressão da área florestal) ou pessimista (regressão da área florestal).

5.1.3 Base de Dados Obtida de Forma Automática

Como apresentado na Seção 4.2.2, a metodologia proposta neste trabalho pode ser também melhorada por meio de um mecanismo inteligente baseado em algoritmos genéticos para definir automaticamente a base de dados (ou seja, o conjunto de partições *fuzzy*) no Módulo de Inferência Principal. A abordagem baseada em AG (SoftCompSTP) foi executada em 10 rodadas com um máximo de 100 gerações e 50 indivíduos na população. Neste algoritmo, a taxa de *crossover* aplicada é igual a 0,6, e a taxa de mutação igual a 0,05 para cada alelo do indivíduo. Nas simulações realizadas com o SoftCompSTP, os parâmetros utilizados para completude mínima (γ_{\min}) e sobreposição máxima (κ_{\max}) das funções de pertinência foram 0,02 e 0,95, respectivamente.

A média e desvio padrão do nível de similaridade resultante das diferentes rodadas realizadas com as abordagens propostas são apresentadas na Tabela 9. Esta tabela permite comparar os resultados obtidos pelas abordagens FuzzySTP, FuzzyGPSTP e SoftCompSTP para as florestas de Ticoporo (na Venezuela) e La Joyanca (na Guatemala). No caso da abordagem FuzzySTP, os resultados apresentados na Tabela 9 referem-se a uma única simulação, visto que não há algoritmos evolutivos envolvidos nesta abordagem.

Tabela 9: Comparação entre as simulações realizadas para as florestas de Ticoporo e La Joyanca.

	TICOPORO (512x512 <i>pixels</i>) Superfície Real = 141.623 em 1994			LA JOYANCA (462 x 353 <i>pixels</i>) Superfície Real = 17.303 em 1998		
	Similaridade (%) (μ, σ, best) *	Superfície Predita / Final (best)	T-student	Similaridade (%) (μ, σ, best) *	Superfície Predita / Final (best)	T-student
FuzzySTP	(89,57; 0 ; 89,57)	138.770 / 139.973	-	(91,04; 0 ; 91,04)	19.793 / 19.832	-
FuzzyGPSTP	(89,37; 0,2; 89,61)	136.890 / 138.532	0,187	(91,64; 1,1; 92,07)	18.429 / 18.367	0,004
SoftCompSTP	(89,47; 0,2; 89,73)	136.890 / 137.895		(92,78; 0,2; 92,96)	18.429 / 18.591	
* μ : média no nível de similaridade calculada considerando-se as 10 rodadas; σ : desvio padrão na similaridade calculado considerando-se as 10 rodadas; best : o melhor indivíduo de todas as rodadas.						

O objetivo aqui é analisar como o aumento de autonomia do sistema pode afetar

os resultados da predição. Foram avaliadas três diferentes abordagens: 1) um sistema que depende inteiramente de um especialista (FuzzySTP); 2) um sistema de autonomia intermediária (FuzzyGPSTP); 3) um sistema com maior autonomia em relação aos demais (SoftCompSTP), pois neste caso a função de regressão e a base de dados do módulo de inferência principal são ajustadas automaticamente. A Tabela 10 apresenta um resumo das técnicas empregadas em cada uma das abordagens propostas neste trabalho.

Tabela 10: Técnicas empregadas em cada abordagem proposta neste trabalho.

	Expressão utilizada no cálculo da Superfície Predita (Módulo <i>Defuzzificador</i>)	Base de Dados utilizada no Módulo de Inferência Principal
FuzzySTP	Definida manualmente por um especialista	Definida manualmente por um especialista
FuzzyGPSTP	Definida de forma automática por um algoritmo de Programação Genética	Definida manualmente por um especialista
SoftCompSTP	Definida de forma automática por um algoritmo de Programação Genética	Definida de forma automática por um Algoritmo Genético

As Figuras 44, 45 e 46 apresentam as imagens preditas obtidas pelos melhores indivíduos de todas as rodadas resultantes das abordagens FuzzySTP, FuzzyGPSTP e SoftCompSTP para as florestas de La Joyanca, Tabe e Ticoporo. No caso da floresta de Tabe, como todas as imagens foram utilizadas na fase de treinamento, qualquer ano pode ser utilizado para teste (optou-se por realizar a predição para o ano 2010), visto que não há como calcular o nível de similaridade.

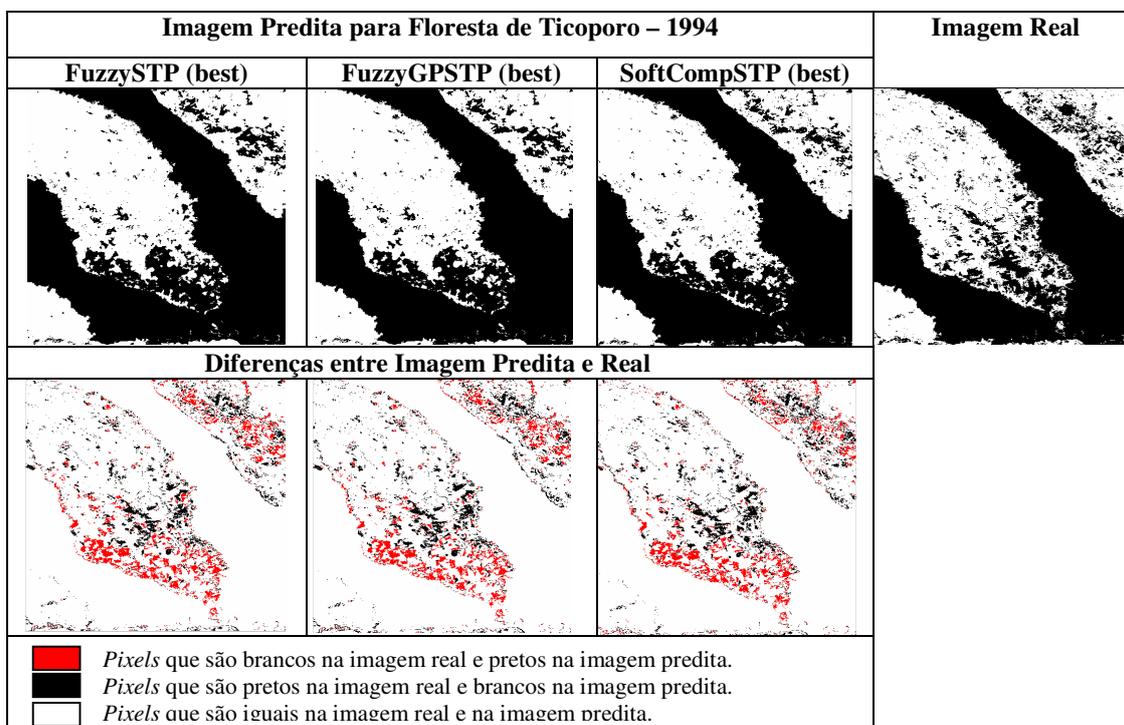


Figura 44: Imagens preditas resultantes das simulações com os métodos de predição

FuzzySTP, FuzzyGPSTP e SoftCompSTP e comparação com a imagem real de Ticoporo.

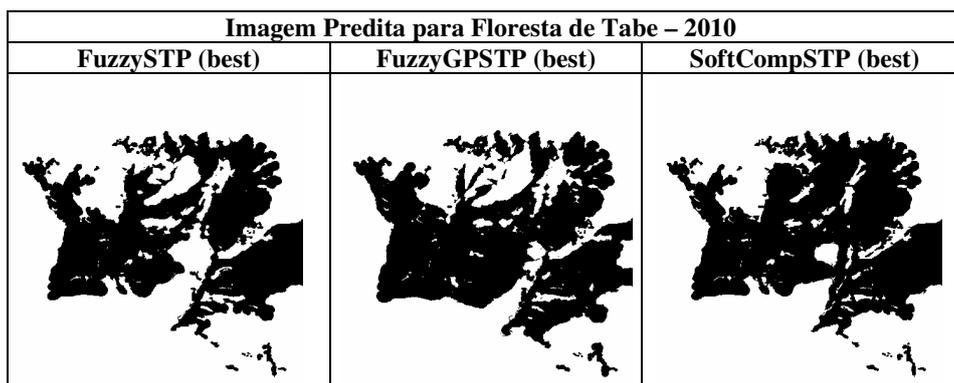


Figura 45: Imagens preditas resultantes das simulações com os métodos de predição FuzzySTP, FuzzyGPSTP e SoftCompSTP para a floresta de Tabe.

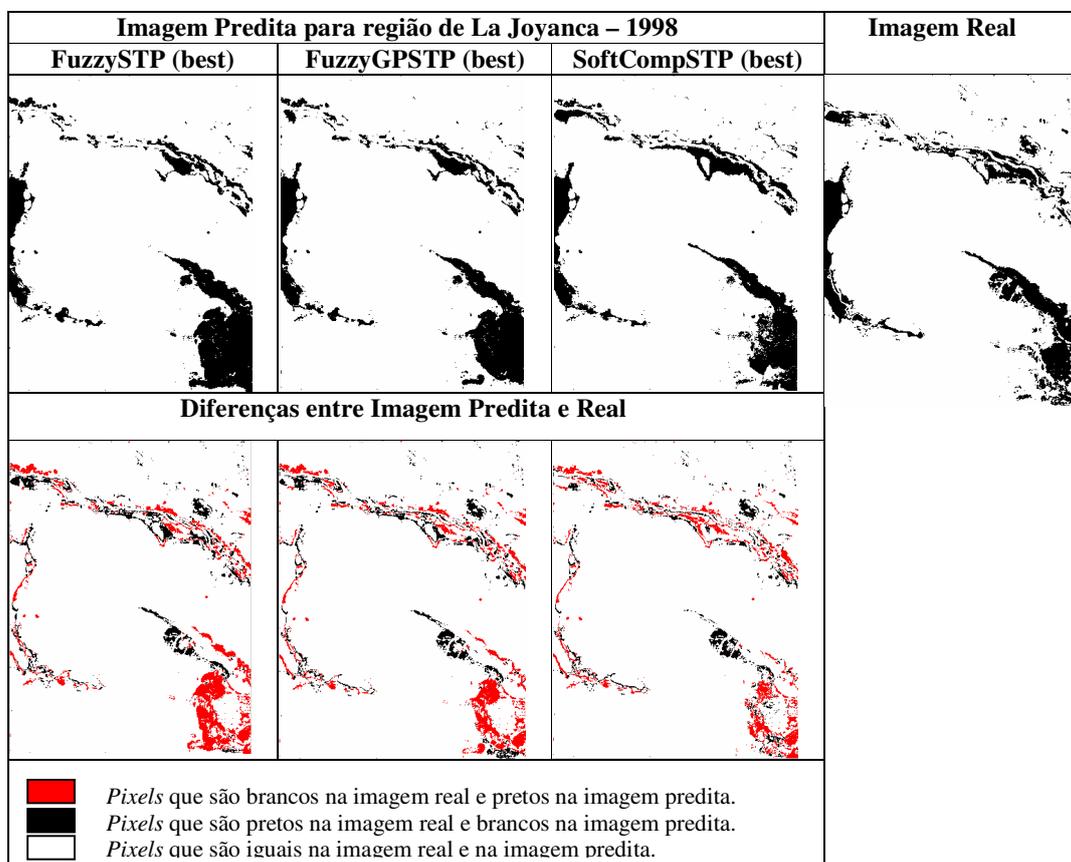


Figura 46: Imagens preditas resultantes das simulações com os métodos de predição FuzzySTP, FuzzyGPSTP e SoftCompSTP e comparação com a imagem real da região de La Joyanca.

Como apresentado na Tabela 9, o teste T-Student foi utilizado para comparar o nível de similaridade resultante das simulações realizadas com as abordagens FuzzyGPSTP e SoftCompSTP. Este teste tem como objetivo comprovar, a partir de um modelo estatístico

convencional, se as amostras pertencem a população distintas (ou seja, se diferenças médias entre o desempenho das duas abordagens são estatisticamente significativas). Para realização do teste foi estabelecido um valor de probabilidade de aceitação máximo de 0,05, o que indica um nível de confiança de 95% ou superior.

É importante salientar que aumentando o nível de autonomia, é possível não somente liberar o usuário da definição de alguns parâmetros do modelo, mas também propiciar um aumento de eficiência/desempenho no sistema. No caso de Ticoporo, como os dados disponíveis para treinamento não são muitos, os benefícios do uso de AG não são tão evidentes (o nível de confiança é menor que 95% como mostrado no teste T-Student). Contudo, como pode ser notado no caso da região de La Joyanca, quando a quantidade de informação disponível é maior, o desempenho do sistema também pode ser melhorado pelo uso das técnicas evolutivas.

A Figura 47 apresenta a partição do universo definida por um especialista para as três regiões analisadas. Este conjunto de partições foi empregado no Módulo de Inferência Principal do sistema nas simulações realizadas com as abordagens FuzzySTP e FuzzyGPSTP.

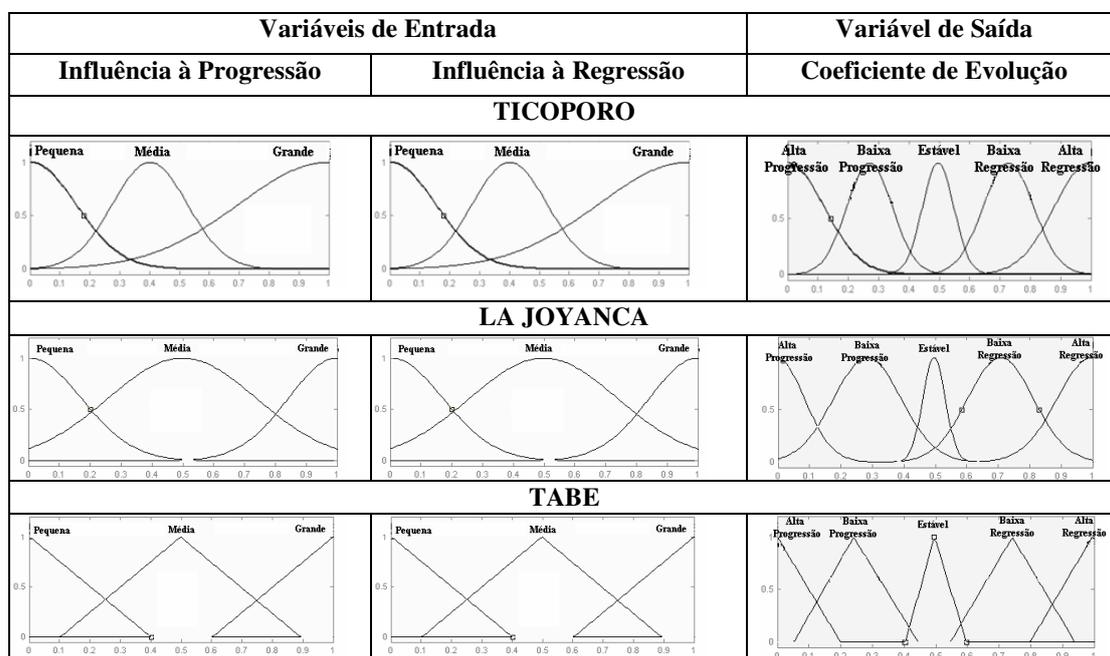


Figura 47: Partição do universo definida por um especialista (FuzzySTP e FuzzyGPSTP).

Como ilustrado na Figura 47, as partições ajustadas pelo especialista não foram distribuídas uniformemente ao longo do universo de discurso de cada variável. No caso de Ticoporo, as funções de pertinência associadas com os termos lingüísticos ‘Pequeno’ e

‘Médio’ são mais específicas que a associada com o termo ‘Grande’. A razão é: quanto mais próximo estiver um *pixel* de uma região de progressão/regressão, maior é a influência desta região sobre ele. Assim, *pixels* mais próximos ou influências maiores são mais importantes que *pixels* mais distantes no raciocínio *fuzzy*. Desta forma, o suporte do conjunto *fuzzy* associado com o termo ‘Grande’ aumenta de acordo com o seu peso no processo de raciocínio. A mesma idéia foi aplicada para a variável de saída associada com o termo ‘Estável’, que foi representado por uma função de pertinência mais específica que as demais, diminuindo a importância dos *pixels* identificados como estáveis no processo de defuzzificação. No caso de La Joyanca e Tabe, as variáveis de entrada foram distribuídas uniformemente como forma de representar que os especialistas possuem flexibilidade suficiente para distribuir as partições de pertinência de acordo com o raciocínio *fuzzy* considerado adequado para cada situação.

A Figura 48 apresenta a partição do universo resultante do algoritmo genético de otimização, executado para as três regiões analisadas. Este conjunto de partições foi empregado no Módulo de Inferência Principal nas simulações realizadas com a abordagem SoftCompSTP.

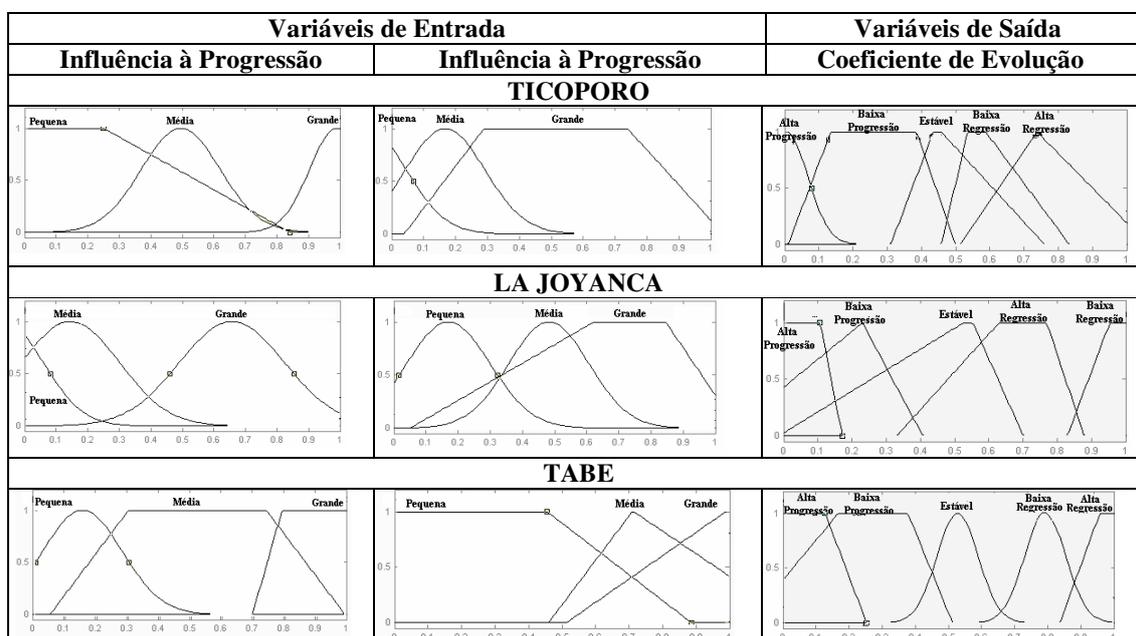


Figura 48: Partição do universo definida pelo algoritmo genético proposto (SoftCompSTP).

Aqui, é possível notar que o ajuste automático da base de dados produz conjuntos de partições não uniformes. Ao mesmo tempo em que permite explorar a não-uniformidade de distribuição dos dados, o AG mantém os conjuntos de partições interpretáveis. Desta

forma, o método mostra-se eficiente para o propósito de otimização do conjunto de partições, pois respeita as restrições de completude mínima e sobreposição máxima (mais detalhes na Seção 4.2.2).

Para permitir uma análise da capacidade de previsão, o método foi aplicado em cada uma das regiões analisadas em outros três instantes de tempo. A abordagem utilizada neste caso corresponde à SoftCompSTP, que representa a proposta completa apresentada neste trabalho. Os resultados obtidos são ilustrados nas Figuras 49, 50 e 51.

Predições para a floresta de Ticoporo		
2005	2010	2015
Superfície Predita 115.870	Superfície Predita 108.530	Superfície Predita 102.110
		

Figura 49: Predições para a floresta de Ticoporo, utilizando a abordagem SoftCompSTP.

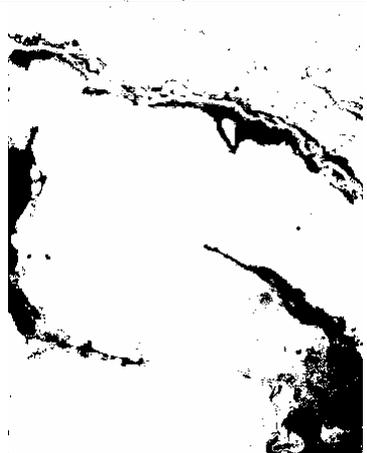
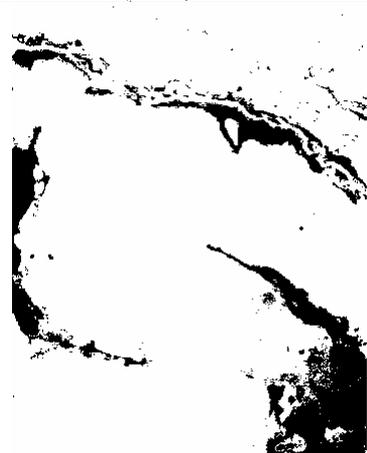
Predições para a floresta de La Joyanca		
2005	2010	2015
Superfície Predita 19.505	Superfície Predita 20.092	Superfície Predita 20.565
		

Figura 50: Predições para a floresta de La Joyanca, utilizando a abordagem SoftCompSTP.

Predições para a floresta de Tabe		
2005	2010	2015
Superfície Predita 71.830	Superfície Predita 77.197	Superfície Predita 82.980
		

Figura 51: Predições para a floresta de Tabe, utilizando a abordagem SoftCompSTP.

5.2 PREDIÇÃO EM OUTROS CONTEXTOS

A abordagem proposta neste trabalho foi desenvolvida com o objetivo de gerar predição espaço-temporal da evolução da paisagem em regiões florestais. Contudo, na etapa de simulação e obtenção de resultados, observou-se que o método não precisaria ficar restrito ao contexto ambiental. Assim, buscando um conjunto maior de seqüência de imagens além de avaliar a robustez da proposta, procurou-se ampliar a área de aplicação.

Por se tratar de um método que trabalha exclusivamente com imagens binárias, as quais ilustram variações no espaço e no tempo, e com fenômenos temporais representados basicamente por avanços e recuos em uma imagem (regiões de progressão e regressão), é possível aplicá-lo na realização de predições em outros contextos de estudo. Desta forma, sob uma análise pouco criteriosa, pode-se considerar que qualquer seqüência de imagens binárias (sejam imagens de sensoriamento remoto ou não) que apresente variações no espaço e no tempo, independente do tipo de variação e unidade temporal envolvida, pode representar uma possível candidata para aplicação do método proposto.

Como exemplo inicial, a metodologia apresentada neste trabalho foi aplicada em uma seqüência de imagens tomográficas referentes a um dedo componente da mão humana. Nesta seqüência de imagens, a variação no espaço é referente ao aumento/diminuição do diâmetro do dedo analisado, e a unidade temporal refere-se aos cortes/fatias selecionados para análise. O dedo analisado é representado por 50 imagens que representam suas fatias, e destas, sete foram selecionadas para utilização no estudo, com um intervalo de oito cortes entre si (ou seja, foram selecionadas as fatias 1, 8, 16, 24, 32, 40 e 48). Das sete imagens

selecionadas, seis foram utilizadas na fase de treinamento e uma na fase de testes. A Figura 52 ilustra as imagens trabalhadas referentes às imagens tomográficas do dedo analisado.

A utilização deste conjunto de imagens tomográficas não tem como objetivo ilustrar uma simulação real de predição, mas sim, verificar o desempenho da metodologia proposta em um contexto de predição onde as imagens digitais não são oriundas de satélites, ou outros meios relacionados com sensoriamento remoto. Para este fim, imagens tomográficas representam uma boa alternativa, pois em geral estão associadas a um conjunto grande de imagens, representando uma seqüência com variação espacial e intervalo temporal fixo.

Como um outro exemplo de possível aplicação da metodologia desenvolvida, realizou-se uma predição com base em uma seqüência de imagens de ressonância magnética. Nesta seqüência de imagens, a variação no espaço é referente ao aumento de uma região que representa um tumor cerebral, onde a unidade temporal é medida em semanas. A Figura 53 ilustra as imagens trabalhadas. Estas imagens foram retiradas de um estudo realizado por Ross et al. (2003), referente ao uso de imagens de ressonância magnética na terapia de combate ao câncer. Para os objetivos relacionados ao trabalho proposto, o motivo que está causando o aumento das células cancerosas será desconsiderado, em função de tal informação não influenciar no resultado final.

Imagens tomográficas de um dedo, representando sua variação de diâmetro						
Fatia 1	Fatia 8	Fatia 16	Fatia 24	Fatia 32	Fatia 40	Fatia 48
						
a) Imagens Tomográficas.						
						
b) Imagens ajustadas manualmente para preenchimento da região que representa o dedo analisado.						

Figura 52: Imagens tomográficas de um dedo componente da mão humana.

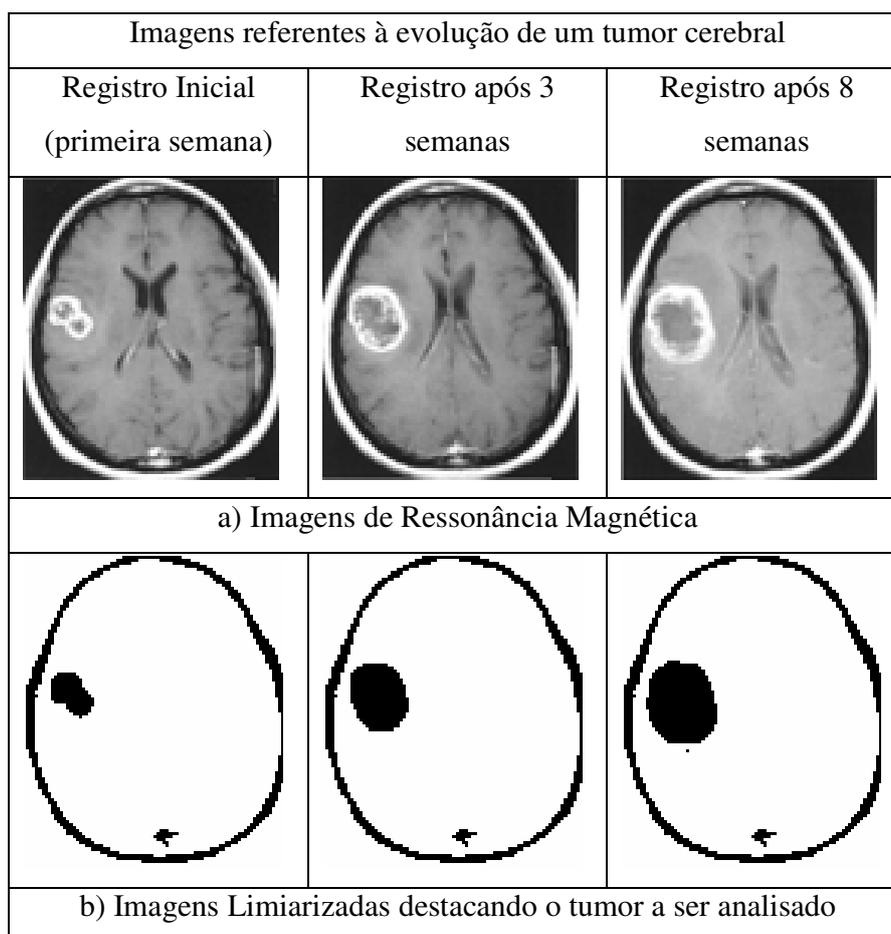


Figura 53: Imagens referentes ao acompanhamento da evolução de um tumor cerebral. Em a) Imagens de Ressonância Magnética, e em b) Imagens limiarizadas.

As abordagens FuzzySTP, FuzzyGPSTP e SoftCompSTP foram executadas para este conjunto de imagens, e os resultados são apresentados a seguir.

Com relação ao valor predito para a superfície das imagens analisadas, a Figura 54 apresenta a aproximação realizada pelo especialista, através de um cálculo de regressão linear, e a obtida através do algoritmo de PG.

caso do tumor cerebral o limiar de sobreposição possa ser diminuído de modo a garantir partições mais interpretáveis.

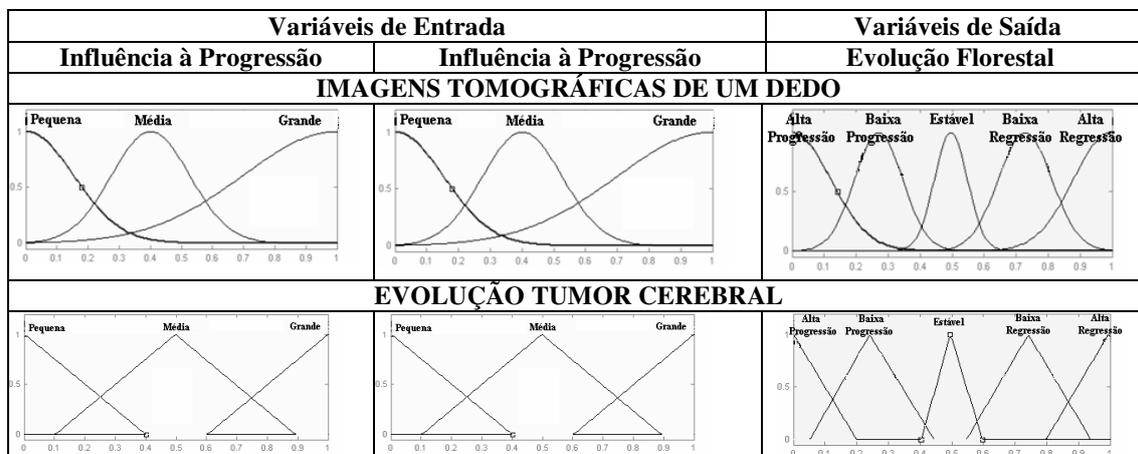


Figura 55: Partição do universo definida pelo especialista (FuzzySTP e FuzzyGPSTP).

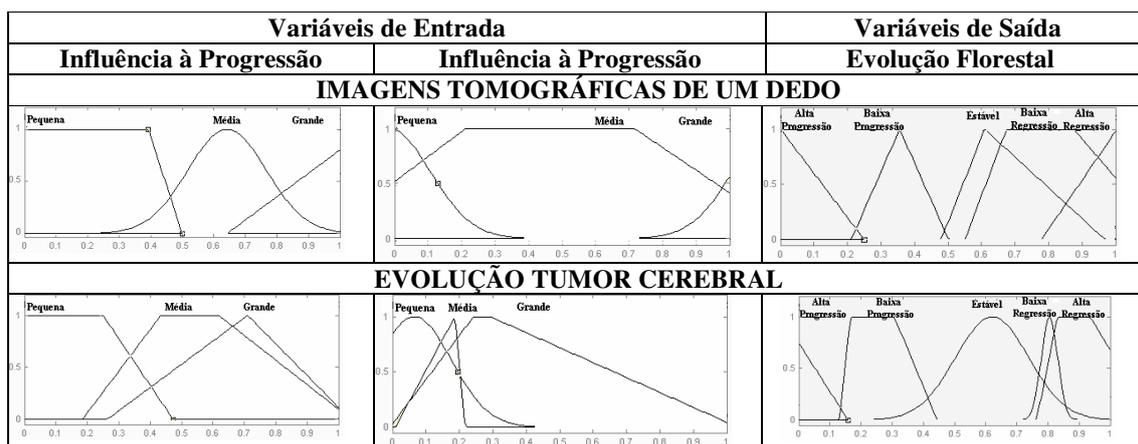


Figura 56: Partição do universo definida pelo algoritmo genético proposto (SoftCompSTP).

As Figuras 57 e 58 apresentam o resultado das predições realizadas pelos métodos FuzzySTP, FuzzyGPSTP e SoftCompSTP para as imagens analisadas.

Como apresentado na Figura 57, apesar da diferença com relação ao nível de similaridade não ser muito significativa, o método de predição SoftCompSTP apresentou melhores resultados quando comparado ao FuzzySTP e FuzzyGPSTP. Este resultado foi verificado também nas simulações realizadas na Seção 5.1, o que reforça a idéia de que o maior nível de autonomia associado ao método de predição pode melhorar o desempenho do mesmo.

No caso das imagens de ressonância magnética utilizadas, por existirem poucas imagens, como no caso da floresta de Tabé, não foi possível realizar a validação do método.

Contudo, o objetivo principal das simulações apresentadas nesta seção é apresentar a possibilidade de aplicação da metodologia proposta em outros contextos de predição. Os exemplos apresentados aqui se referem a contextos relacionados com a área médica, contudo, nada impede que a aplicação da metodologia em imagens digitais relacionadas a outros contextos seja investigada.

Imagens Preditas da região analisada, referente às duas imagens reservadas para teste				
	FuzzySTP	FuzzyGPSTP	SoftCompSTP	Imagem Real
Imagens referentes à fatia 7 selecionada do dedo analisado	Imagens Preditas			
				
	Superfície Predita: 268 Superfície Final: 266	Superfície Predita: 245 Superfície Final: 246	Superfície Predita: 245 Superfície Final: 248	Superfície Real: 200
	% de Similaridade			
	0,9872	0,9853	0,9879	
				
 Pixels que são brancos na imagem real e pretos na imagem predita.  Pixels que são pretos na imagem real e brancos na imagem predita.  Pixels que são iguais na imagem real e na imagem predita.				

Figura 57: Predições para a seqüência de imagens tomográficas de um dedo.

Imagem Predita da região analisada, referente a 12 semanas após o primeiro registro		
FuzzySTP	FuzzyGPSTP	SoftCompSTP
		
Superfície Predita: 1152 Superfície Final: 1153	Superfície Predita: 1093 Superfície Final: 1092	Superfície Predita: 1093 Superfície Final: 1085

Figura 58: Predições para a seqüência de imagens referente à evolução de um tumor cerebral.

Apesar dos resultados apresentados terem se mostrado interessantes, vale ressaltar que o objetivo inicial do trabalho não contemplava esta possibilidade, o que resultou em uma análise pouco detalhada da mesma.

A Tabela 11 apresenta um comparativo entre as técnicas utilizadas na proposta deste trabalho, e as utilizadas no trabalho desenvolvido por Centeno e Selleron (2002).

Tabela 11: Diferenciais da proposta.

Técnicas Empregadas	Proposta de Centeno e Selleron (2002)	Proposta deste Trabalho
Processo de Subtração	Geram os Mapas de Progressão e Regressão.	Geram os Mapas de Progressão e Regressão.
Fórmulas Matemáticas	Geram a Imagem <i>Fuzzy</i> .	Geram os Mapas de Influência a Progressão e Regressão.
Processo de multi-limiarização	Busca Local.	Busca Global e Local.
<i>Fuzzy</i>	Aplica alguns conceitos de conjuntos <i>fuzzy</i> no processo de limiarização.	Utiliza um Sistema de Inferência <i>Fuzzy</i> completo.
Computação Evolutiva	Não implementa.	Técnicas de PG e AG.
Contexto de Predição	Avaliada em um contexto ambiental.	Avaliada em um contexto ambiental e médico.

A Tabela 11 permite verificar que a proposta deste trabalho empregou técnicas de inteligência computacional de maneira mais abrangente, se comparada ao trabalho que lhe serviu como base. Além disso, o processo de predição de um modo geral passou a contar com novas etapas até a criação da imagem *fuzzy*. As simulações, por sua vez, puderam ser realizadas também em um contexto médico, além do contexto ambiental inicialmente previsto.

CAPÍTULO 6

DISCUSSÃO E CONCLUSÕES

6.1 CONCLUSÕES

O objetivo deste trabalho foi apresentar uma abordagem alternativa para realizar a predição espaço-temporal da evolução da paisagem de regiões florestais. O método proposto baseia-se na comparação de uma seqüência de imagens de sensoriamento remoto obtidas de regiões florestais em diferentes instantes de tempo. Um sistema *fuzzy* aliado a técnicas evolucionárias foi aplicado sobre estas imagens para analisar e prever o estado futuro da paisagem destas regiões.

O preditor espaço-temporal desenvolvido corresponde a um sistema de inferência *fuzzy* (SIF) que pode ser ajustado por meio de um especialista, ou através de algoritmos de otimização (algoritmos de PG e AG). Este SIF é composto pelos módulos de Transformação, Fuzzificador, Inferência Principal, Agregação e Defuzzificador. No módulo Defuzzificador, o algoritmo de PG desenvolvido pode liberar o usuário de informar a classe e coeficientes da função utilizada para prever a superfície florestal da região estudada. E no módulo de Inferência Principal, o AG pode automatizar a definição da base de dados, trabalhando com diferentes formatos de funções de pertinência, explorando a não-uniformidade das partições, e mantendo sua interpretabilidade.

Os resultados obtidos mostraram que o uso de técnicas de Inteligência Computacional é uma alternativa interessante, visto que a abordagem proposta foi comparada com outras técnicas apresentadas na literatura, obtendo desempenho equivalente. As modificações referentes à adição de sistemas *fuzzy*, programação genética e algoritmos genéticos, não somente melhoraram o desempenho do sistema, como permitiram a produção de um modelo de interpretação final com um bom nível de autonomia, facilitando seu uso por especialistas não familiarizados com terminologias matemáticas.

Considerando o contexto de predição espaço-temporal em regiões florestais, o método mostrou-se flexível, pois permitiu a análise e acompanhamento de fenômenos temporais contínuos de um modo geral, mesmo que estes fenômenos tenham sido desencadeados por diferentes fatores como: queimadas, diminuição da floresta em função do aumento de pastagens, avanço das cidades, etc.

Como apresentado na última seção do capítulo de simulações e resultados, o modelo proposto possibilitou sua aplicação também na predição de evolução em outros contextos, como por exemplo na área médica, mostrando-se uma ferramenta flexível. Esta possibilidade incentiva a realização de trabalhos futuros.

Deve-se levar em consideração, que a abordagem proposta mostrou-se adequada para realizar predições de fenômenos temporais contínuos, ou seja, eventos que apresentam um comportamento constante no decorrer do tempo, fazendo com que a região analisada apresente tendência à regressão ou à progressão. A aplicação do método em regiões cuja evolução é descontínua, não foi avaliada, visto que a superfície predita tem grande influência no resultado final da predição, e neste caso, a superfície poderia apresentar comportamentos muito distintos com o decorrer do tempo.

Vale ressaltar que a abordagem em questão não é e não tem pretensão de ser uma modelagem exata. Ela retrata tendências de evoluções com base em informações do histórico da região analisada e pode servir de auxílio na tomada de decisão por parte de especialistas ambientais.

6.2 TRABALHOS FUTUROS

Este trabalho foi desenvolvido com o objetivo de aprimorar uma metodologia de predição anteriormente implementada por Centeno e Selleron (2001, 2002), que aplica alguns conceitos de sistemas *fuzzy* no processo preditivo.

A abordagem apresentada neste trabalho aplicou sistemas *fuzzy* de uma maneira mais abrangente e fez uso de técnicas evolutivas para aumentar a autonomia de algumas etapas do processo. Contudo, a abordagem como um todo ainda possui muitos aspectos a serem aperfeiçoados. Desta forma, como trabalhos futuros, sugere-se a complementação das pesquisas, a fim de aprimorar ainda mais os resultados e aplicabilidade do método proposto.

Como exemplo, pode-se incorporar mecanismos automáticos para ajustar outros parâmetros do sistema *fuzzy* desenvolvido, como toda a base de conhecimento do sistema, incluindo a base de dados do módulo defuzzificador e a base de regras no módulo de inferência principal e defuzzificador.

Além disso, pode-se tentar melhorar o algoritmo genético utilizado na abordagem SoftCompSTP, adicionando mecanismos de busca local para testar a abordagem proposta

em outras regiões florestais e diferentes contextos de predição.

O resultado obtido através do algoritmo de programação genética apresentou, em algumas simulações, equações bastante complexas. Para tornar estas equações mais claras, um processo de simplificação pode ser empregado a fim de melhorar a interpretabilidade do modelo. Além disso, a simplificação pode ainda melhorar o desempenho do sistema.

O uso do filtro da mediana no Módulo de Transformação tende a eliminar possíveis ruídos que existam nas imagens, mas por outro lado, acarreta na suavização das imagens. Torna-se interessante então efetuar outras simulações sem a aplicação deste filtro para verificar se esta suavização poderia influenciar nos resultados de predição.

Outra sugestão de trabalho futuro consiste na possibilidade de paralelização do processo realizado no Módulo de Inferência Principal, quando é inferido o valor do coeficiente de evolução para cada *pixel* da imagem. A paralelização pode acelerar o processo de inferência realizado neste módulo.

E por fim, a flexibilidade apresentada pelo método estimula uma investigação mais detalhada do desempenho da abordagem em diferentes contextos de predição, como na área médica, para acompanhamento da evolução de tumores, ou corpos estranhos que possam ser identificados em exames clínicos associados a imagens digitais. Neste contexto, será necessário realizar um levantamento de quais exames médicos fazem uso de imagens digitais, cujas amostras possam representar mudanças no espaço e no tempo.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, M. A. **DIG-PB: Proposta de um Sistema Distribuído de Informação Geográfica para Auxílio à Gestão de Recursos Hídricos da Paraíba**. Dissertação de Mestrado em Informática. Universidade Federal da Paraíba – UFPB, Campina Grande, 1999.

ALMEIDA, C. **Modelagem Espacial Dinâmica como Ferramenta de Planejamento: Simulação de Mudanças de Uso do Solo em Bauru e Piracicaba (SP)**. Tese de Doutorado em Sensoriamento Remoto. INPE, São José dos Campos, 2003.

AVELINO, P. H. M. **A trajetória da tecnologia de sistemas de informação geográfica (SIG) na pesquisa geográfica**. Revista Eletrônica da Associação dos Geógrafos Brasileiros – Seção Três Lagoas. Três Lagoas, v. 1- nº 1 – ano 1. Novembro de 2004.

BANZHAF, W; NORDIN, P.; KELLER, R. E.; FRANCONI, F. D. **Genetic Programming: an introduction**. ISBN 155860510X. Morgan Kaufmann Publishers, 1998.

BARRETO, J. **Inteligência Artificial. No Limiar do Século XXI**. ISBN 859003822X. rrr Edições, 1997.

BARRETO, A. M. S. **Algoritmo Genético dos Mínimos Quadrados Ortogonal para o Treinamento de Redes RBF**. Dissertação de Mestrado em Ciências em Engenharia Civil. Programa de Pós-Graduação de Engenharia Civil da COPPE/UFRJ. Rio de Janeiro, 2003.

BITTNER, T.; SMITH, B. **Formal ontologies for space and time**. IFOMIS, Department of Philosophy, Leipzig, Buffalo, University of Leipzig, University at Buffalo and NCGIA: 17. 2003.

BOHM, W., GEYER-SCHULZ, A. **Exact uniform initialization for genetic programming**. Foundations of Genetic Algorithms IV (FOGA 4). ISBN 155860460X. pp 379-407. Morgan Kaufmann Publishers, 1996.

BURROUGH, P.A. **Development of intelligent geographical information systems**. In: International Journal of Geographical Information Systems 6 (1):1-11. 1992.

CÂMARA, G. **Modelos, Linguagens e Arquiteturas para Bancos de Dados Geográficos**. Tese de PHD. INPE, São José dos Campos, 1995.

CÂMARA, G., CASANOVA, M., HEMERLY, A., MAGALHÃES, MEDEIROS, C. **Anatomia de Sistemas de Informação Geográfica**. 197p. Instituto de Computação, UNICAMP, Campinas, 1996.

CÂMARA, G.; MONTEIRO, A. M. V. **Introdução à Modelagem Dinâmica Espacial**. Tutorial apresentado no XI Simpósio Brasileiro de Sensoriamento Remoto, Belo Horizonte - MG, 05-10 abril 2003, INPE.

CARUANA, R. A.; SCHAFFER, J. D. **Representation and hidden bias: Gry vs. binary coding for genetic algorithms**. In: Proceedings International Conference On Machine Learning, 5, 1988. Morgan Kaufmann, 1988.

CASTANHO, J. E. C.; TOZZI, C. L. **Obtenção da transformação de corpo rígido em registro de imagens com deformação usando thin plate splines**. In: Anais do IX Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens SIBGRAPI 96, SBC/UFMG, Caxambu, 1996.

CAVES, R.; QUEGAN, S.; WHITE, R. **Quantitative comparison of the performance os SAR segmentation Algorithms**. Transaction on Image Processing- IEEE, v. 7, n. 11, p. 1534-1546, 1998.

CENTENO, T. M.; GÓIS, J. A. **Integração fuzzy de imagens e dados heterogêneos no auxílio à avaliação de impacto ambiental**. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 3037-3044.

CENTENO, T. M.; SAINT-JOAN, D.; DESACHY, J. **Approach of the spatio-temporal prediction using vectorial geographic data**. In Proceedings of SPIE, Remote Sensing for Geography, Geology, Land Planning and Cultural Heritage, volume 2960, pp. 96-103, Taormina, 1996.

CENTENO, T. M.; SELLERON, G. **Spatio-temporal prediction applying fuzzy logic in a sequence of satellite**. Proceedings of SPIE - SPIE's International Symposium on Remote Sensing, volume 4545, pp.84-91. Toulouse-France, Setembro, 2001.

CENTENO, T. M.; SELLERON, G. **Téledétection et logique floue: diagnostic et projections temporelles de la déforestation sur un front pionnier tropical**. Bulletin de La Société Française de Photogrammétrie et Téledétection, Saint-Mandé - France, v. 3, p. 4-15, 2002.

CENTENO, T. M.; SELLERON, G.; GONÇALVES, R. M. **Modelagem Preditiva a partir de uma seqüência de imagens de satélite utilizando Autômatos Celulares**. Anais do XI Simpósio Brasileiro de Sensoriamento Remoto, Belo Horizonte, Brasil, 05 – 10 de abril de 2003, INPE, p. 975-981.

CHELLAPILLA, K. **Evolving computer programs without sub-tree crossover**. IEEE Transactions on Evolutionary Computation. Vol. 1 Issue 3. pp 209-216. IEEE Press, September, 1997.

CLARAMUNT, C. F.; SEDE, M.H.; PRELAZ-DROUX, R.; VIDALE, L.; **Sémantique et logique spatio temporeles**. In Revue internationale de géomatique, volume 4, pp. 165-180, 1994.

CORDÓN, O. ; HERRERA, F. ; HOFFMANN, F. ; MAGDALENA, L. **Genetic Fuzzy Systems. Evolutionary Tuning and Learning of Fuzzy Knowledge Bases**. Advances in Fuzzy Systems – Applications and Theory. World Scientific. 2001.

CORDÓN, O.; GOMIDE, F.A.C.; HERRERA, F.; HOFFMAN, F.; MAGDALENA, L.; **Genetic fuzzy systems. new developments**. Fuzzy Sets and Systems, 141(1), pp. 1–3, 2004.

COSTA, P. L. C. G. **Controlo de uma Equipa de Robots Móveis**. Dissertação de Mestrado em Engenharia Eletrotécnica e de Computadores. Faculdade de Engenharia da Universidade do Porto. Porto, 1998.

COUCLELIS, H. **From cellular automata to urban models: new principles for model development and implementation.** Environment and Planning B: Planning and Design, v. 24, n. 2, p. 165-174, 1997.

COX, E. **Fuzzy Modeling and Genetic Algorithms for Data Mining and Exploration.** Morgan Kaufmann Publishers, 2005.

CRAMER, N. **A representation for the adaptive generation of simple sequential programs.** In Grefenstette, J., editor, Proceedings of an International Conference on Genetic Algorithms and the Applications, pages 183-187, Carnegie-Mellon University, Pittsburgh, PA, USA. 1985.

DARWIN, C. **On the origin of species by means of natural selection or the preservation of favored races in the struggle for life.** Murray, London, UK. 1859.

DE CASTRO, L. N.; VON ZUBEN, F. (Ed.). **Recent Developments in Biologically Inspired Computing.** Idea Group Publishing, 2005.

DE JONG, K. A. **An Analysis of the Behavior of a Class of Genetic Adaptive Systems.** PhD thesis, Department of Computer and Communications, University of Michigan. 1975.

DE JONG, K. A. **Evolutionary Computation A Unified Approach.** MIT Press, 2006.

DELGADO, M. R. B. S. **Projeto automático de sistemas nebulosos: uma abordagem co-evolutiva.** Tese de Doutorado em Engenharia Elétrica. UNICAMP. Campinas, SP, 2002.

DIAS, T. L. **Vida e Evolução de Objetos Geográficos: Uma Ontologia do Espaço Urbano.** Proposta de Tese de Doutorado em Computação Aplicada. INPE, São José dos Campos, 2003.

DIAS, T.; CÂMARA, G.; DAVIS, C. **Modelos espaço-temporais**, em M. Casanova, G. Câmara, C. Davis, L. Vinhas, G. Ribeiro (org), "Bancos de Dados Geográficos" (cap 4). Editora MundoGeo. 2005.

DOLFUS, O. **O Espaço Geográfico**. Rio de Janeiro: Bertrand Brasil, 1991.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. **Análise Espacial de Dados Geográficos**. Brasília: EMBRAPA (ISBN 85-7383-260-6), 2004.

DUARTE, O. **Técnicas Difusas en la Evaluación de Impacto Ambiental**. Ph.D. Thesis, Universidad de Granada. 2000.

DUARTE, G. D. **Processamento de Imagens Digitais - AULA 4**. janeiro de 2006. Disponível em: <http://www.cefetrs.tche.br/~glaucius/tst_pid/pid_a04.htm>. Acesso em 16/03/2006.

EDELWEISS, N.; OLIVEIRA, J. P. M. **Modelagem de aspectos temporais de sistemas de Informação**. In: IX Escola de computação, Recife: Universidade Federal de Pernambuco, 1994.

EGENHOFER, M., GOLLEDGE, R. **Spatial and Temporal Reasoning in Geographic Information Systems**. Edited by Max J. Egenhofer and Reginald G. Golledge, Eds. Article Citations. 1998.

ENGELBRECHT, A. P. **Computational Intelligence: An Introduction**. John Wiley & Sons, 2002.

ESPINOSA, J; VANDEWALLE, J. **Constructing Fuzzy Models with Linguistic Integrity from Numerical Data - AFRELI Algorithm**. IEEE Transactions on Fuzzy Systems, 8(5), pp.591–600, 2000.

ESQUEF, I. A. **Técnicas de Entropia no Processamento de Imagens**. Dissertação de Mestrado em Instrumentação Científica. Centro Brasileiro de Pesquisas Física, Rio de Janeiro. 2002.

FEDEROV, D. **Sistema semi-automático de registro e mosaico de imagens**. Dissertação de Mestrado. Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2002.

FOGEL, D. B.; OWENS, A. J.; WALSH, M. J. **Artificial Intelligence through Simulated Evolution**. John Wiley. 1966.

FONTE, C. M. P. C. **Entidades Geográficas Difusas – Métodos de Construção e Processamento**. Universidade de Coimbra, 2003.

FOOK, K. D. **Integração da Estatística Espacial em Ambientes GIS**. Monografia de Qualificação em Computação Aplicada. INPE, São José dos Campos, 2005.

FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. **Geographically Weighted Regression: The Analysis of Spatially Varying Relationships**. Chichester: Wiley, 2002.

GATRELL, A. C. **Concepts of space and geographical data**. In: MAGUIRE, D. J., GOODCHILD, M. F., RHIND, D. W. **Geographical Information Systems: principles and applications**. Longman Scientific & Technical, 1991. Cap.9, p.119-134.

GATTASS, Marcelo. **Imagem Digital**. Outubro de 2005. Disponível em: <<http://www.tecgraf.puc-rio.br/~mgattass/cg/pdf/>>. Acesso em 16/03/2006.

GOLDBERG, D. E., DEB, K. **A comparative analysis of selection schemes used in genetic algorithms**. Foundations of Genetic Algorithms (FOGA). ISBN 1558601708. pp 69-93. Morgan Kaufmann Publishers, 1991.

GOMIDE, Fernando. **Notas de Aula IA 861 – Sistemas Nebulosos (Computação com Regras, Variáveis Lingüísticas, Números e Aritmética Nebulosa)**. Dca/Feec/Unicamp. 2005. Disponível em: <<http://www.dca.fee.unicamp.br/~gomide/courses/IA861/transp/index.html>>. Acesso em: 26/05/2006.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. Addison-Wesley, 1992.

GOUDARD, B., SINAY, M. C. F. **Técnicas de pesquisa operacional para avaliar alternativas de projetos com potencial poluidor.** XXXIII SBPO - Simpósio Brasileiro de Pesquisa Operacional - A pesquisa operacional e o Meio Ambiente 6 a 9 de novembro de 2001 - Campos do Jordão - SP, p. 773-784, 2001.

HOFFMANN, F.; NELLES, O. **Structure identification of TSK-fuzzy systems using genetic programming.** In Proceedings of IPMU 2000, Madrid, Spain. pp 438–445. 2000.

HOLLAND, J. H. **Adaptation in natural and artificial systems.** The University of Michigan Press, Ann Arbor, MI, 1975.

JAIN, R.; KASTURI, R.; SCHUNCK, B. G. **Machine Vision,** McGraw-Hill, 1995

JIN, Y. **Fuzzy Modeling of High-Dimensional Systems: Complexity Reduction and Interpretability Improvement.** IEEE Transactions on Fuzzy Systems, 8(2), pp. 212–221, 2000.

JANG, J.S.; SUN, C.T.; MIZUTANI E. **Neuro-Fuzzy and Soft Computing.** Prentice Hall, 1997.

KAVOURAS, M. **Understanding and Modelling Spatial Change.** In: FRANK A. RAPER J. e CHEYLAN J.P. eds.: Life and Motion of Socio-Economic Units, Chapter 4. London: Taylor & Francis, GISDATA Series 8. 2001.

KITANO, H. **Neurogenetic learning: an integrated method of designing and training neural networks using genetic algorithms.** Physica D, Amsterdam, v. 75, p. 225-238, 1994.

KLEMENT, E.P., MESIAR, R., PAP, E. **Triangular Norms.** Kluwer Academic Publishers, 2000.

KOZA, J. R. **Hierarchical genetic algorithms operating on populations of computer programs.** In Proceedings of the Eleventh International Joint Conference on Artificial Intelligence IJCAI-89, N. S. Sridharan (Ed.), volume 1, pp 768--774, Morgan Kaufmann Publishers, 1989.

KOZA, J. R. **Genetic Programming: On the Programming of Computers by Means of Natural Selection.** ISBN 0262111705. MIT Press, 1992.

KOZA, J. R. **Genetic Programming II: Automatic Discovery of Reusable Programs.** ISBN 0262111896. MIT Press, 1994

KOZA, J.R.; BENNETT, F.H.; ANDRE, D.; KEANE, M.A. **Genetic Programming III: Darwinian Invention and Problem Solving.** Morgan Kaufmann Publishers, 1999.

KOZA, J. R.; KEANE, M. A. ; STREETER, M. J.; MYDLOWEC, W.; YU, J.; LANZA, G. **Genetic Programming IV: Routine Human-Competitive Machine Intelligence.** Kluwer Academic Publishers. 2003.

KRAMER, M. D.; ZHANG, D. **GAPS: a genetic programming system.** The 24th Annual International Computer Software and Applications Conference 2000 (COMPSAC 2000) ISBN 0769507921. pp 614–619. IEEE Press, October, 2000.

LAMBIN, E. F. **Modeling Deforestation Processes - A Review.** Trees series B: Research Report. European Commission, Luxembourg. 1994.

LANGRAN, G. **A review of temporal database research and its use in GIS application.** In International Journal of Geographical Information Systems, volume 3, pages 215-232, 1989.

LANGRAN, G. **Time in Geographic Information Systems.** Taylor et Francis, 1992.

LARSEN, P. M. **Industrial Applications of Fuzzy Logic Control.** International Journal of Man-Machine Studies, Vol. 12, N. 1, pp 3–10. 1980.

LAURINI, R.; THOMPSON, D. **Fundamentals of Spatial Information Systems.** London: Academic Press: 1992, 680p.

LIOTTE, S. V.; MACEDO, A. B.; PEDRO, M. F. **Utilização de Técnicas de Geoprocessamento para apoio ao planejamento físico-territorial do município de Pariquera-Açu/SP**, 2000, Dissertação de Mestrado em Geociências - Universidade de São Paulo.

LUKE, S. **Two fast tree-creation algorithms for genetic programming**. IEEE Transactions in Evolutionary Computation, Vol 4 Issue 3 pp. 274-283 IEEE Press. September, 2000.

LUKE, S.; PAINAIT, L. **A survey and comparison of tree generation algorithms**. Proceedings of the 6th Annual Conference in Genetic Programming (GECCO 2001). ISBN 1558607749. Springer-Verlag, 2001.

McEACHREN, A.M., BUTTENFIELD, B.P.; CAMPBELL, J.B.; DIBIASE, D.; MONMONIER, M. **Visualization**. In Geography's Inner Worlds, R. Abler, M. Marcus and J. Olson (eds.), pp. 99-137. New Brunswick, New Jersey: Rutgers University Press. 1992.

MAMDANI, E. H.; ASSILIAN, S. **An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller**. International Journal of Man-Machine Studies, Vol. 7, N. 1, pp 1-13. 1975.

MANOLOPOULOS, Y.; PAPADOPOULOS, A.; VASSILAKOPOULOS, M. **Spatial Databases: Technologies, Techniques and Trends. Chapter 11 - Spatio-Temporal Prediction Using Data Mining Tools**. IDEA Group Publishing, December 2004, ISBN 1-59140-387-1.

MARBLE, D. F. **Geographic Information System: A overview**. IN: Introductory Readings in Geographical Informations Systems. Philadelphia. Taylor and Francis, p.8-17. 1990.

MARTINES, P. R. **Análise espaço-temporal da expansão urbana através do Geoprocessamento: uma aplicação para a cidade de Presidente Prudente (1917-1998)**. Unesp, 1999. Disponível em: <<http://www.multimidia.prudente.unesp.br/patricia/index.htm>>. Acesso em: 11/11/2005.

MARUO, M. H. **Projeto automático de sistemas nebulosos utilizando algoritmos genéticos auto-adaptativos**. Dissertação de Mestrado em Informática Industrial. UTFPR. Curitiba, 2006.

MARUO, M. H.; DELGADO, M. R. B. S. **Co-evolutionary genetic fuzzy system: a self-adapting approach**. In: Proceedings of the IEEE International Conference on Fuzzy Systems - FUZZ-IEEE'2006, pp. 6977-6984. 2006.

MEDEIROS, J. S. **Banco de dados Geográficos e Redes neurais Artificiais: Tecnologias de Apoio à Gestão do Território**. Tese de Doutorado em Geografia Física - Universidade de São Paulo, 1999.

MEYER, T. P.; PACKARD, N. H. **Local forecasting of high-dimensional chaotic dynamics**. In: CASDAGLI, N.; EUBANK, S. (Eds.), Nonlinear Modeling and Forecasting. Addison-Wesley. 1992.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. Springer-Verlag. 1996.

MITCHELL, M. **An introduction to genetic algorithms**. Cambridge. MIT Press, 1996. 209 p.

MONMONIER, M. **Strategies for the Visualization of Geographic Time-Series Data**. Cartographica. Vol. 27, No. 1, pp. 30-45. 1990.

MOURA, A. C. M. **Contribuições Metodológicas do Geoprocessamento à Geografia**. Belo Horizonte: Centro de Sensoriamento Remoto - IGC - UFMG, 2001.

NOVO, E. M. **Sensoriamento Remoto: princípios e aplicações**. São Paulo. Edgard Blucher, 1989, 307p.

PACHECO, A. P. **Sensoriamento Remoto Multitemporal aplicado à Cobertura vegetal de Mata Atlântica**. Geodesia Online. UFPE/Recife. 2001. Disponível em: <<http://geodesia.ufsc.br/Geodesia-online/arquivo/2001/01/AP.htm>>. Acesso em: 02/11/2005.

PEDROSA, B. M. **Ambiente Computacional para Modelagem Dinâmica Espacial**. Tese de Doutorado em Computação Aplicada. INPE. São José dos Campos, 2004.

PEDRYCZ, W.; GOMIDE, F. **An Introduction to Fuzzy Sets: Analysis and Design**. MIT Press, Cambridge. 1998

PEUQUET, D. J. **It's about time: a conceptual framework for the representation of temporal dynamics in Geographic Information Systems**. *Annals of the Association of American Geographers*, 84(3), 1994, pp. 441-461

POKRAJAC, D; OBRADOVIC, Z. **“Combining Regressive and Auto-Regressive Models for Spatial-Temporal Prediction**. *Machine Learning of Spatial Knowledge Workshop at the 17th Int'l. Conf. on Machine Learning*, Stanford, CA, June 2000.

RECHENBERG, I. **“Cybernetic solution path of an experimental problem”**. Technical report, Royal Aircraft Establ., Farnborough, UK. 1965.

RECHENBERG, I. **“Evolutionsstrategie: Optimierung Technischer Systeme nach Prinzipien Biologischer Evolution”**. Frommann-Holzboog. 1973.

ROCHA, J. C. F.; KAESTNER, C. A. A.; BORGES, D. L. **Redes Bayesianas em Fotointerpretação**. In: Encontro Nacional de Inteligência Artificial, 1997, Brasília. Anais do ENIA'97, 1997.

ROCHA, C. H. **Geoprocessamento, Tecnologia Transdisciplinar**. Juiz de Fora. Ed. do Autor. 2000.

ROSENFELD, A.; PFALTZ J.L. **Sequential operations in digital picture processing**. *Journal of the Association for Computing Machinery*, 13, pp.471–494. 1966.

ROSS, B. D.; MOFFAT, B. A.; LAWRENCE, T. S.; MUKHERJI, S. K.; GEBARSKI, S. S.; QUINT, D. J.; JOHNSON, T. D.; JUNCK, L.; ROBERTSON, P. L.; MURASZKO, K. M.; DONG, Q.; MEYER, C. R.; BLAND, P. H.; MCCONVILLE, P.; GENG, H.; REHEMTULLA, A.; CHENEVERT, T. L. **Evaluation of Cancer Therapy Using Diffusion Magnetic Resonance Imaging**. *Molecular Cancer Therapeutics*, Vol. 2, 581-587, June 2003.

SAINT-JOAN, D.; DESACHY, J. **A Fuzzy Expert System for Geographical problems: an agricultural application.** In FUZZ-IEEE'95, Fourth IEEE International Conference on Fuzzy Systems, volume 2, pages 469-476, 1995.

SAINT-JOAN, D.; DESACHY, J. **A raster-based fuzzy expert system for forestry evolution.** In IGARSS'96 International Geoscience and Remote Sensing Symposium, 1996.

SAINT-JOAN, D.; VIDAL, F.(a). **Application combinée d'un système expert flou et d'analyses morphomathématiques pour caractériser la dynamique d'un massif forestier.** MappedMonde. 4 p. - 8 fig. 1997.

SAINT-JOAN, D.; VIDAL, F.(b). **Une interface système expert flou / morphologie mathématique sur images numériques pour l'étude des évolutions spatio-temporelles des milieux naturels: le cas des massifs forestiers de la soulane de Tabé em Ariège.** Actes Journées du programme environnement vie et sociétés - les temps de l'environnement - Tome II - Session 5 - pp. 565-572. 1997.

SCHERER, A. **Combining neural networks with other prediction techniques.** In: Proceedings of the 29th Annual Hawaii International Conference on System Sciences. p. 437-446. 1996.

SCHULTZ, R. E. O.; CENTENO, T. M.; DELGADO, M. R. B. S. **Spatio-temporal prediction by means of a fuzzy rule-based approach.** In: Proceedings of the IEEE International Conference on Fuzzy Systems - FUZZ-IEEE'2006, 2006. pp. 6621-6628.

SCHWEFEL, H.P. **Numerical Optimization of Computer Models.** John Wiley. 1981.

SIARRY, P; GUELY, F. **A Genetic Algorithm for Optimizing Takagi-Sugeno Fuzzy Rule Bases.** Fuzzy Sets and Systems, 99(1), pp. 37-47, 1998.

SILVA, C. S.; BARBOSA, P. S. F. **Algoritmo do Gradiente Conjugado Escalonado em RNA para a Previsão de Consumo Horário de Água em Sistemas de Abastecimento.**

In: SEMINÁRIO - Planejamento, Projeto e Operação de Redes de Abastecimento de Água: O Estado da Arte e Questões Avançadas, 2002, João Pessoa-PB, Brasil.

SILVERT, W. **Ecological Impact Classification with Fuzzy Sets**. Ecological Modelling, vol. 96, p. 1-10, 1997.

SOARES, V. P.; BRITES, R. S.; RIBEIRO, C. A. A. S. **Avaliação da Mudança da Cobertura em Áreas Reflorestadas Usando Razão de Bandas de Imagens de Satélite**. CERNE, V.4, N.1, p022-033, 1998.

STEFEN, C. A. **Introdução ao Sensoriamento Remoto**. Instituto Nacional de Pesquisas Espaciais, Divisão de Sensoriamento Remoto, 2000. Disponível em: <<http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em 16/03/2006.

TAKAGI, T.; SUGENO, M. **Derivation of Fuzzy Control Rules from Human Operator's Control Actions**. In Proceedings of the IFAC Symp. on Fuzzy Information, Knowledge Representation and Decision Analysis, Marseilles, France. pp 55–60. 1983.

TAKASHINA, N. T. **Era da Gestão da Sabedoria: modismo ou tendência da qualidade para o próximo milênio?** Publicado em: 03/02/2004. Disponível em: <<http://www.kmpress.com.br/portal/artigos/preview.asp?id=184>>. Acesso em: 15/11/2005.

TANSCHKEIT, R. **Sistemas Fuzzy**. Disponível em: <www.ica.ele.puc-rio.br/cursos/download/LN-Sistemas%20Fuzzy.pdf>. Acesso em: 08/10/2006.

TANOMARU, J. **Motivação, Fundamentos e Aplicações de Algoritmos Genéticos**. II Congresso Brasileiro de Redes Neurais. III Escola de Redes Neurais. Curitiba, 1995.

TEIXEIRA, A. S. **Democracia e educação**. Educação e o Mundo Moderno. São Paulo: Companhia editora Nacional, 1969, p. 205-221.

TERADA, R. **Desenvolvimento de algoritmos e estruturas de dados**. ISBN 0074609602. McGraw-Hill, Makron, 1991.

VON ZUBEN, F. J.; CASTRO, L. N. **Redes Neurais com Funções de Ativação de Base Radial**. DCA/FEEC/Unicamp. Notas de aula. 2005.

WORBOYS, M. F. **A Generic Model for Spatio-Bitemporal Geographic Information**. Spatial and Temporal Reasoning in Geographics Information Systems. M. J. E. R. G. Golledge, New York, Oxford University Press: 25-39. 1998.

ZADEH, L.A. **Fuzzy Sets**. Information and Control, Vol. 8, pp. 338-352. 1965.

ZADEH, L.A. **The concept of a linguistic variable and its application to approximate reasoning**. **Information Science**. New York: Elsevier Publishing Company Inc. n. 8 p. 199-249 301-357. 1975.

ZADEH, L. A. **Linguistic variables, approximate reasoning and dispositions**. *Med. Inform.*, 8(3), pp. 173-186. 1983.

RESUMO

Informações geográficas representam uma importante ferramenta para tomada de decisão no planejamento físico-territorial. O termo Sistemas de Informação Geográfica (SIG) caracteriza os sistemas de informação cuja principal característica é possibilitar a realização de análises espaciais envolvendo dados referenciados geograficamente. No entanto, é inevitável a existência de erros e incerteza na informação geográfica incorporada aos SIG. Os sistemas *fuzzy*, por outro lado, apresentam um grande potencial na modelagem de incertezas e aparecem, portanto, como uma alternativa para a representação e o tratamento da informação geográfica. Desta forma, um modelo baseado em sistemas *fuzzy* e apoiado por técnicas evolutivas é proposto neste trabalho a fim de incorporar mecanismos inteligentes ao tratamento destas informações. O objetivo é desenvolver um preditor espaço-temporal da evolução de florestas através de um sistema baseado em Inteligência Computacional (IC), considerando uma seqüência de imagens de sensoriamento remoto de paisagens em diferentes regiões. O sistema *fuzzy* é composto por cinco módulos e recebe como entrada uma seqüência de imagens binárias produzindo ao final uma projeção para o fenômeno temporal em questão. Com o auxílio de técnicas evolutivas como os algoritmos genéticos e a programação genética, a autonomia do sistema pode ser incrementada, liberando o usuário da definição de alguns parâmetros do sistema. Os resultados mostram que o modelo é competitivo com as abordagens tradicionais, e que o uso de técnicas evolutivas pode incrementar o desempenho do sistema, sempre que há informação disponível suficiente. Além disso, o uso de variáveis lingüísticas *fuzzy* torna o sistema mais interpretável, facilitando o seu uso por parte de operadores pouco acostumados com formulações matemáticas.

Palavras-chave: Predição Espaço-Temporal; Imagens de Sensoriamento Remoto; Sistemas *Fuzzy*; Algoritmos Genéticos; Programação Genética.

Área de concentração: Informática Industrial.

Ata

Nº 437

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)