



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DISSERTAÇÃO DE MESTRADO

FLÁVIA PESSOA MONTEIRO

ClasSIS: UMA METODOLOGIA PARA CLASSIFICAÇÃO
SUPERVISIONADA DE IMAGENS DE SATÉLITE EM ÁREAS DE
ASSENTAMENTO LOCALIZADOS NA AMAZÔNIA

UFPA/ITEC/PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2015



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

FLÁVIA PESSOA MONTEIRO

ClasSIS: UMA METODOLOGIA PARA CLASSIFICAÇÃO
SUPERVISIONADA DE IMAGENS DE SATÉLITE EM ÁREAS DE
ASSENTAMENTO LOCALIZADOS NA AMAZÔNIA

Dissertação de Mestrado submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica, com ênfase em Computação Aplicada, sob orientação do Prof. Dr. Carlos Renato Lisboa Francês.

UFPA/ITEC/PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2015



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ClasSIS: UMA METODOLOGIA PARA CLASSIFICAÇÃO
SUPERVISIONADA DE IMAGENS DE SATÉLITE EM ÁREAS DE
ASSENTAMENTO LOCALIZADOS NA AMAZÔNIA

AUTOR: FLÁVIA PESSOA MONTEIRO

Dissertação de mestrado submetida à avaliação da banca examinadora aprovada pelo colegiado do programa de pós-graduação em engenharia elétrica da Universidade Federal do Pará e julgada adequada para obtenção do título de Mestre em Engenharia Elétrica, com ênfase em computação aplicada.

APROVADA EM _____ / _____ / _____

Prof. Dr. Carlos Renato Lisboa Francês - UFPA
ORIENTADOR

Prof. Dr. Ádamo Lima de Santana - UFPA
MEMBRO PPGEE/UFPA

Prof. Dr. Marcelino Silva da Silva - UFPA
MEMBRO-EXTERNO UFPA-CASTANHAL

Visto:

Prof. Dr. Evaldo Gonçalves Pelaes
COORDENADOR DO PPGEE/ITEC/UFPA

AGRADECIMENTOS

Dedico esse trabalho primeiramente a Deus, por mais essa benção na minha vida e de minha família.

Agradeço ao meu orientador prof^o Dr. Renato Francês, por me conceder a oportunidade e ter me guiado nesta jornada.

Quero agradecer ao meu pai Niedson Jorge e a minha mãe Fátima do Socorro, por me oferecerem o suporte necessário para construir tanto minha vida profissional quanto pessoal.

Dedico para as minhas irmãs Gabriela e Fernanda, por sempre estarem presentes na minha vida.

Dedico à minha vó Miraci e a minha vó Vanda, pela constante preocupação e carinho. À minha tia madrinha Ana Selma, por ser um exemplo a ser seguido na profissão.

À minha tia e melhor amiga Nilma Monteiro.

Quero agradecer ao prof^o Jorge Souza, pela atenção, colaboração, paciência e cuidados dedicados.

Ao amigo e prof^o Carlos Natalino pelo cuidado e preocupação dedicados a minha formação e ao meu crescimento como profissional.

Aos amigos Pedro Ramos, Evelin Cardoso e Priscila Aranha, pela ajuda e parceria. Aos demais amigos do LPRAD.

E por fim, um agradecimento especial ao engenheiro Rodrigo Carvalho por sempre estar presente ao meu lado nos momentos difíceis e alegres dessa jornada.

“E tudo quando pedirdes em meu nome eu o farei, para que o Pai seja glorificado no Filho.

Se pedirdes alguma coisa em meu nome, eu o farei.”

João 14:13-14

Sumário

RESUMO	11
ABSTRACT	12
CAPÍTULO 1 – INTRODUÇÃO	13
CAPÍTULO 2 – SENSORIAMENTO REMOTO	17
2.1. Considerações Iniciais	17
2.2. Geoprocessamento e Sistemas de Informações Geográficas (SIG)	17
2.3. Sensoriamento Remoto	18
2.3.1. Conceitos e Princípios	18
2.3.2. Sistemas de Sensores	19
2.3.3. Resoluções	22
2.3.4. Satélite LANDSAT	23
2.3.5. Processamento Digital de Imagens	26
2.3.6. Classificação de Imagens Digitais	26
2.3.6.1. Classificação por pixel	27
2.3.6.2. Classificação por regiões	27
2.4. Considerações Finais	28
CAPÍTULO 3 – INTELIGÊNCIA COMPUTACIONAL	29
3.1. Considerações Iniciais	29
3.2. Inteligência Computacional e Aprendizado de Máquina	29
3.2.1. Modelos Preditivos	31
3.2.2. Modelos Descritivos	32
3.2.3. Árvore de Decisão	33
3.2.3.1. CART – <i>Classification and Regression Trees</i>	35
3.2.3.2. RF - <i>Random Forest</i>	36
3.2.4. Técnica de Máxima Verossimilhança	36
3.2.5. SVM - Support Vector Machine	37
3.2.6. RNA - Redes Neurais Artificiais	38
3.3. Considerações Finais	39
4.1. Considerações Iniciais	40
4.2. Comparação de Técnicas de Classificação de Imagens de Satélite	40
4.3. Considerações Finais	44
5.1. Considerações iniciais	45
5.2. Metodologia ClasSIS	45
5.2.1. Módulo de Tratamento de Imagem	45

5.2.1.1.	1ª Fase – Aquisição de Dados	46
5.2.1.2.	2ª Fase – Processamento Digital de Imagens	47
5.2.2.	Módulo de Análise e Extração de Padrões	48
5.2.2.1.	3ª. Fase – Normalização dos Dados	48
5.2.2.2.	4ª. Fase – Classificação de Imagens.....	49
5.2.2.3.	5ª. Fase – Pós-Processamento	49
5.3.	Considerações Finais	50
6.1.	Considerações iniciais.....	51
6.2.	Localização e caracterização da área de estudo	51
6.3.	Aplicação da Metodologia ClasSIS	53
6.3.1.	Módulo de Tratamento de Imagens	53
6.3.1.1.	Aquisição de dados.....	53
6.3.1.2.	Processamento digital de imagens.....	55
6.3.2.	Módulo de Análise e Extração de Padrões	56
6.3.2.1.	Transformação dos dados.....	56
6.3.2.3.	Escolha da Técnica de Classificação.....	61
6.3.3.	Pós-processamento dos dados	65
6.4.	Considerações finais	66
7.1.	Considerações Iniciais	68
7.2.	Análise dos resultados	68
7.3.	Considerações Finais	72
8.1.	Contribuições da Dissertação.....	74
8.2.	Trabalhos Futuros	75
8.3.	Dificuldades Encontradas	76
	Entre as principais dificuldades podem-se destacar:	76

LISTA DE ABREVIATURAS E SIGLAS

INCRA	Instituto Nacional de Colonização e Reforma Agrária
IMAZON	Instituto do Homem e Meio Ambiente da Amazônia
APP	Áreas de Preservação Permanente
ARL	Áreas de Reserva Legal
LULC	<i>Land Use and Land Cover</i>
ClasSIS	Metodologia para Classificação Supervisionada de Imagens de Satélite
CO₂	Dióxido de Carbono ou Gás Carbônico
GIS	<i>Geographic Information System</i>
SIG	Sistemas de Informações Geográficas
TM	<i>Thematic Mapper</i>
DN	<i>Digital Number</i>
NASA	<i>National Aeronautics and Space Administration</i>
ERTS-1	<i>Earth Resources Technology Satellite</i>
LANDSAT	<i>Land Remote Sensing Satellite</i>
MSS	<i>Multispectral Scanner Subsystem</i>
RBV	<i>Return Beam Vidicom</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
CART	<i>Classification and Regression Trees</i>
SVM	<i>Support Vector Machine</i>
SRM	<i>Structural Risk Minimization</i>
RNAs	Redes Neurais Artificiais
PA	Projeto de Assentamento
BD	Banco de Dados
IA	Inteligência Artificial
AM	Aprendizado de Máquina
AGs	Algoritmos Genéticos
RF	<i>Random Forest</i>
MAXVER	Máxima Verossimilhança
INPE	Instituto Nacional de Pesquisas Espaciais
SPRING	Sistema de Processamento de Informações Georreferenciadas
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária

LISTA DE FIGURAS

Figura 1. Processo de interação entre o sol (emissor), satélite/sensor (receptor) e estação de recepção dos dados	19
Figura 2. Níveis de coleta de dados espectrais: campo (terrestre), avião (suborbital) e satélite (orbital).....	22
Figura 3. Satélites Landsat 5 e Landsat 7	24
Figura 4. Hierarquia de aprendizagem	31
Figura 5. Modelo de árvore de decisão para diagnóstico de pacientes.	34
Figura 6. Metodológico ClasSIS.	46
Figura 7. Área de estudo, PA 26 de Março.	52
Figura 8. Disposição dos lotes no PA 26 de Março.	53
Figura 9. Composição colorida R5G4B3 da órbita/ponto 223/64 do satélite Landsat 5,.....	54
Figura 10. Inconsistências na classificação do projeto TerraClass encontradas na região do assentamento 26 de Março.	58
Figura 11. Processo de geração da base de treinamento.	59
Figura 12. Gráfico da dinâmica do uso e cobertura da terra do PA 26 de Março.	66
Figura 13. Classificação das imagens da série temporal do assentamento 26 de Março.	68
Figura 14. Dinâmica de uso e cobertura da terra no assentamento 26 de Março. Utilizando a técnica Random Forest com a variável “área preservada”.	70
Figura 15. Dinâmica de uso e ocupação da terra no assentamento 26 de Março. Utilizando a técnica Random Forest não utilizando a variável “área preservada”.	70
Figura 16. Comparação entre a imagem original, o resultado da técnica RF e o Projeto TerraClass no ano de 2010.	71
Figura 17. Comparação entre o mapeamento temático do TerraClass (externo) e da técnica Random Forest (interno) no ano de 2010.	72

LISTA DE TABELAS

Tabela 1. Bandas espectrais e suas principais características de aplicação de cada banda do sensor LANDSAT.	25
Tabela 2. Banco de imagens utilizado no estudo de caso do Assentamento 26 de Março... 54	54
Tabela 3. Avaliação do índice Kappa.	61
Tabela 4. Comparativo da acurácia e do índice Kappa das técnicas estudadas.	62
Tabela 5. Matriz de precisão (%) da classificação do uso e cobertura da terra.	62
Tabela 6. Matriz de confusão da RF.	63
Tabela 7. Matriz de confusão da RNA.	64
Tabela 8. Matriz de confusão da técnica SVM.	64
Tabela 9. Matriz de confusão do algoritmo CART.	65

RESUMO

A Amazônia é um dos biomas mais complexos e diversificados do planeta e seu nível de preservação ambiental possui impacto de âmbito global. Entretanto, para além dos aspectos ambientais, a complexidade da região envolve outras diferentes especificidades nos vieses social, econômico e cultural. De fato, tais vieses estão intrinsecamente interligados, de tal forma que, por exemplo, aspectos culturais podem afetar as relações entre o uso e a cobertura da terra e, em se tratando de Amazônia, dependendo da escala dessas mudanças, pode implicar consequências planetárias. Em função da criticidade que envolve a região, diversas ações governamentais, de organizações e movimentos sociais e da comunidade internacional, vem tentando racionalizar o uso e a cobertura da terra, de maneira a criar uma relação de exploração sustentável dos recursos naturais disponíveis. Um importante programa governamental se baseia na criação de assentamentos, com o respectivo apoio, no que diz respeito a determinados financiamentos de infraestrutura, maquinário, mudas e sementes, assistência técnica, entre outros. Entretanto, apesar dos esforços envidados, a solução é de extrema complexidade, dada a extensa correlação de fatores a serem avaliados e combinados em busca do sucesso e do aprimoramento de tais programas. Assim, por conta de toda complexidade envolvida, é de primordial importância a existência de metodologias que consigam contemplar a complexidade e a interdisciplinaridade inerentes. Com a intenção de debruçar-se sobre toda essa problemática, um conjunto de Instituições da Amazônia elaborou e aprovou o projeto Desenvolvimento de Competências e Formação de Recursos Humanos em Recuperação de Áreas Degradadas em Projetos de Assentamentos em Áreas Amazônicas - Edital N°047/2012 – Programa CAPES/Pró-Amazônia. Este trabalho apresenta uma metodologia inovadora de análise do uso e cobertura da terra, em projetos de assentamentos localizados na Amazônia, como parte integrante do supracitado. Tal metodologia é composta por dois módulos (de tratamento de imagens e de classificação e extração de padrões), sendo que cada módulo é subdividido em etapas para a realização de suas funções precípuas. A metodologia proposta nesta dissertação, a qual possui um alto grau de generalização, visa a categorizar o uso e cobertura da terra, por meio da associação de cada pixel a uma classe temática pré-definida. Com a finalidade de validar a estratégia proposta, são realizados estudos de casos em assentamentos localizados na região Sudeste do estado do Pará, na Amazônia brasileira.

Palavras-Chave: Classificação de imagens de satélite, LULC, LULCC, Satélite LANDSAT 5, Assentamento 26 de Março, TerraClass, Árvore de Decisão, *Random Forest*, SVM, CART, MPL.

ABSTRACT

Amazon has one of the most complex and diversified biomes of the planet. Its environmental preservation has an impact in the global scenario. However, besides the environmental factors, the complexity of the region involves other different aspects such as social, economical and cultural. In fact, they are intrinsically interrelated in such a way, that, for example, cultural features may affect land use/land cover. Moreover, depending on the scale of such changes, there may be consequences on the planet. Due to the criticality involving the region, several actions of governments, organizations and social movements and the international community, has been trying to rationalize the land use/land cover, in order to create a sustainable exploitation of available natural resources. An important government program is based on the creation of settlements, with respective support, with regard to certain infrastructure financing, machinery, seeds and seedlings, technical assistance, etc. However, despite the efforts made, the solution is extremely complex, given the extensive correlation of factors to be assessed and combined in search of success and improvement of such programs. So, because of all complexity involved, it is of paramount importance that there are methodologies that contemplate the complexity and inherent interdisciplinarity. Intending to have a closer look at this whole issue, an Amazonian set of institutions drew up and approved the project Skills Development and Training of Human Resources for Degraded Areas Recovery in Settlement Projects in Amazonian Areas – Public Notice Nº047 / 2012 - CAPES/Pró-Amazônia Programme. This work presents an innovative methodology for land use/land cover analysis, in projects of settlements located in the Amazon, as part of the above mentioned. Such methodology comprises two modules (image processing, and classification and patterns extraction), each module is subdivided into steps to performing their primary functions. The methodology proposed in this work, which has a high degree of generalization, aims to categorize the land use/land cover, through the association of each pixel to a predefined thematic class. In order to validate the proposed strategy, case studies are carried out in settlements located at the Southeast region of the State of Pará, in the Brazilian Amazon.

Keywords: Satellite image classification, LULC, LULCC, LANDSAT 5 satellite, 26th March Settlement, Terra Class, Decision Tree, Random Forest, SVM, CART, MPL.

CAPÍTULO 1 – INTRODUÇÃO

Raras ações de natureza política possuem o significado social, econômico e ambiental tão amplo quanto os projetos de colonização rural na Amazônia, os quais, em sua trajetória, expressam sucessos e fracassos de famílias assentadas (FEARSLIDE, 2000). Hoje existem na Amazônia Legal 3.554 projetos de assentamento da reforma agrária, onde vivem 752 mil famílias, em 76,7 milhões de hectares.

No Brasil, foi criado em 1970 um órgão público denominado INCRA (Instituto Nacional de Colonização e Reforma Agrária) cuja sua principal missão, consiste na realização do ordenamento fundiário nacional focado na reforma agrária. Em linhas gerais, a reforma agrária é em um conjunto de medidas com finalidade de promover uma melhor distribuição da terra, estabelecendo diretrizes para o licenciamento ambiental de projetos de assentamento, visando o desenvolvimento sustentável (INCRA, 2003).

Para o Instituto do Homem e Meio Ambiente da Amazônia - IMAZON, nos projetos de assentamentos da reforma agrária, 37% da área deles já foram desmatadas (IMAZON, 2013). O Instituto Nacional de Colonização e Reforma Agrária, INCRA, reconhece o problema e indica que a situação é ainda mais grave no Pará.

As taxas de desmatamento na Amazônia são muito altas e a indicação dos responsáveis por elas é um tema complexo e controverso. Em 392 desses assentamentos, a supressão da cobertura florestal já atingiu valores alarmantes entre 50% e 75% dos lotes, comprometendo áreas de preservação permanente (APP) e áreas de reserva legal (ARL), gerando impactos expressivos no meio ambiente. O governo brasileiro estima que 75% do CO₂ emitido se origina a partir da mudança no uso da terra e das florestas. O mesmo estudo aponta que a conversão da floresta amazônica em pastagens e em terras agrícolas foi responsável, na década de 1990, por uma emissão anual estimada em 1,20 Pg CO₂ (FEARSLIDE, 2000).

Em relação ao uso e cobertura da terra (em inglês, *Land Use and Land Cover - LULC*), diversas pesquisas têm apontado que as práticas e processos de uso da terra praticados na região amazônica, com destaque para a degradação das florestas, podem afetar o clima regional, ecossistemas e, em última análise, o clima global (OLIVEIRA, MORAES,

2003). Por conta disso, o estudo da dinâmica de uso e cobertura da terra, nos projetos de assentamentos na região amazônica, mostra-se como ferramenta fundamental para descoberta e compreensão dos motivos que impulsionam a degradação ambiental desses assentamentos.

Atualmente, os avanços tecnológicos favoreceram o surgimento e o aperfeiçoamento de diversas técnicas de coleta de dados. Dentre os vários métodos de obtenção de dados e informações acerca do espaço geográfico, o sensoriamento remoto tem apresentado elevado potencial na aquisição de grandes volumes de dados georeferenciados em diferentes escalas através de imagens, sendo altamente aplicado em projetos que visam o mapeamento do uso e cobertura do solo.

Devido às dimensões continentais da Região Amazônica, o uso de sensoriamento remoto tem sido indispensável para o monitoramento ambiental, detecção de focos de queimadas e de ações de desflorestamento. Em associação, o uso de técnicas e ferramentas para a classificação de imagens de satélites vem se tornando ferramenta poderosa de apoio ao estudo do uso e cobertura da terra e das mudanças ocorridas ao longo dos anos (FOODY, 2002). O uso de tais metodologias vem permitindo que sejam propostas políticas públicas mais eficientes, tanto para conter/minimizar o desflorestamento, quanto para auxiliar a fixação das famílias nos assentamentos, proporcionando maneiras sustentáveis de subsistência às famílias assentadas.

O sensoriamento remoto tem um papel fundamental no monitoramento do uso e cobertura da terra da Amazônia, pois permite obter informações históricas e atuais para um ambiente vasto e de difícil acesso. A classificação é um processo de extração de informações que abrange um conjunto de técnicas, que podem ser matemáticas ou estatísticas, e a principal finalidade é automatizar a categorização de todos os *pixels* de uma imagem dentro de temas ou classes de uso e cobertura da terra (LIANG et al., 2012).

As técnicas de classificação, via de regra, são agrupadas em *supervisionadas* e *não supervisionadas*. Na primeira, é necessária a obtenção prévia de informações de um especialista de domínio, com profundo conhecimento de fundo em relação ao fenômeno estudado. Já as técnicas não supervisionadas podem prescindir desse conhecimento prévio (REBOUÇAS, 2011). Nesse caso, as informações podem ser obtidas a partir de mapas já existentes ou a partir de trabalho de campo nas áreas de interesse do estudo. Tipicamente as técnicas classificação supervisionada mais referenciadas na literatura especializadas são a máxima verossimilhança (JENSEN & TULLIS, 2008), Máxima a posteriori (MAP) (LOPES et al., 1990), máquina de vetores de suporte (PAL & MATHER, 2005) e redes neurais

(KAVZOGLU & MATHER, 2003). Analogamente, via de regra, as técnicas de classificação não supervisionadas mais discutidas são: Mapas auto-organizáveis (KOHONEN, 2001), algoritmos genéticos híbridos (AWAD, CHEHDI & NASRI, 2007), Gaussian Maximum Likelihood (FOODY, 1992), que são junções entre métodos estatísticos para geração da base de treino com os diversas técnicas supervisionadas conhecidas (FOODY, 1992; MINAI & WILLIAMS, 1990; CARPENTER, 1999). O desempenho de técnicas não supervisionadas é geralmente degradadas por diversos fatores, tais como variações de iluminação, mudanças de condições atmosféricas, e calibração de sensores, que normalmente são obtidas por razão de diferentes tempos de aquisição.

1.1. Motivação

O município de Marabá possui um número significativo de assentamentos, que, ao longo dos anos, tem sofrido com a degradação ambiental. Inúmeras experiências de recomposição florestal de áreas degradadas mediante a implantação de sistemas agroflorestais fracassaram. Portanto, a recomposição de áreas degradadas nos assentamentos, por meio de composições agroflorestais, não é uma tarefa simples. Os planos de recuperação devem considerar aspectos silviculturais, ambientais e sociais. Os entraves, são diversos, envolvem a dificuldade de os assentados encontrarem mudas; pouco conhecimento para manipular sementes e no manejo; a baixa qualidade e frequência da assistência técnica, e a presença de pragas e doenças.

Assim, o uso de imagens de satélite para realização de estudos da dinâmica das atividades econômicas desenvolvidas nos assentamentos, e a avaliação dos impactos gerados no meio ambiente, constitui matéria fundamental para a proposição de ações mitigatórias e de políticas públicas que incentivem a educação ambiental, formas sustentáveis de geração de renda, recuperação das áreas degradadas, entre outras.

Nesse contexto, com a intenção de debruçar-se sobre toda essa problemática, um conjunto de Instituições da Amazônia (UFPA, UFRA, UNIFESSPA, UFMA e INPE) elaborou e aprovou o projeto Desenvolvimento de Competências e Formação de Recursos Humanos em Recuperação de Áreas Degradadas em Projetos de Assentamentos em Áreas Amazônicas - Edital N°047/2012 – Programa CAPES/Pró-Amazônia.

1.2. Objetivos

Nesta dissertação, uma metodologia de classificação de imagens de satélite, para a realização de análises multitemporais do uso e cobertura da terra, em projetos de assentamentos, localizados na Amazônia, é proposta. As regiões de assentamentos rurais, são caracterizadas por áreas pequenas (cerca de 2 mil hectares) e com perfil de agricultura familiar e pecuária. Mas, essa metodologia comporta não apenas a avaliação do estudo de caso aqui apresentado, mas também pode ser adaptada para o estudo de qualquer outra área de interesse, como áreas urbanas.

1.3. Organização da Dissertação

Este documento está dividido como segue:

- Capítulo 2 – Referencial Teórico: Apresenta conceitos básicos e introdutórios da área de sensoriamento remoto.
- Capítulo 3 - Apresenta conceitos básicos de inteligência computacional, que serão necessários para o entendimento deste trabalho.
- Capítulo 4 – Trabalhos Relacionados: Apresenta um levantamento dos principais trabalhos que abordam as diferentes técnicas de classificação de imagens de satélite, para o estudo do uso e cobertura da terra, na literatura recente.
- Capítulo 5 - Metodologia: Descreve a metodologia proposta por esta dissertação, denominada ClasSIS, que tem a finalidade de classificar imagens de satélite, em áreas de assentamentos, localizados na Amazônia.
- Capítulo 6 – Estudo de Caso: Apresenta o processo de aplicação passo a passo da metodologia proposta (ClasSIS), por intermédio de um estudo de caso no Projeto de Assentamento (PA) 26 de Março, em Marabá/PA.
- Capítulo 7 – Análise dos Resultados: Apresenta os resultados obtidos a partir da classificação das imagens do PA 26 de Março, enfatizando a dinâmica do uso e cobertura da terra no Assentamento.
- Capítulo 8 – Conclusão: Apresenta as considerações finais sobre os resultados alcançados pelo trabalho, apontando as dificuldades encontradas e os possíveis estudos futuros.

CAPÍTULO 2 – SENSORIAMENTO REMOTO

2.1. Considerações Iniciais

Ao longo deste capítulo, serão apresentados conceitos básicos e introdutórios da área de sensoriamento remoto, os quais serão necessários para o entendimento deste trabalho. Inicia-se com o geoprocessamento e sua importância no cenário atual. Em seguida, abordam-se os fundamentos e características das principais técnicas de sensoriamento remoto e os principais conceitos de processamento digital de imagens.

Ressalta-se que não se tem a pretensão de esgotar o assunto. Trata-se meramente de um levantamento dos fundamentos básicos necessários ao escopo deste trabalho. Entretanto, para aprofundamento dos assuntos abordados neste capítulo, sugere-se consulta no que concerne a geoprocessamento em NOVO (1989).

2.2. Geoprocessamento e Sistemas de Informações Geográficas (SIG)

De acordo com Watrin (1998), a partir de dados multiespectrais oriundos de sensoriamento remoto é possível analisar, planejar e monitorar a dinâmica de ocupação humana desordenada, que acaba resultando em constantes mudanças na cobertura vegetal do ambiente.

O desafio de trabalhar com grandes volumes de dados e com variáveis que sofrem constantes transformações, como variações climáticas e de uso do solo, estão entre as principais dificuldades encontradas nas áreas de cartografia, análise de recursos naturais, transportes, comunicação, energia e planejamento urbano e regional (CÂMARA; MEDEIROS, 1998).

O geoprocessamento surge nesse cenário como um forte instrumento de gestão territorial, que, segundo Chaves (2005), apresenta uma gama extensa de possibilidades e utilizações, muitas destas ainda são pouco exploradas. Seu principal objetivo é abstrair e transferir de maneira ordenada, as informações obtidas no mundo real para sistemas computacionais por meio de técnicas e de uma metodologia adequada para gerenciá-las e manipulá-las, para que possam servir de subsídio para intervenções positivas na realidade

espacial. Para Rocha (2000), esta transferência é feita sobre bases cartográficas, por meio de um sistema de referência apropriado.

Os Sistemas de Informações Geográficas (SIG) são instrumentos computacionais de geoprocessamento que automatizam a produção de documentos cartográficos. Segundo Bahr (1999) é impossível existir um SIG sem estar intimamente ligado à cartografia. Os SIGs foram tecnologicamente melhorados de uma cartografia com soluções matemáticas e gráficas para a representação de feições naturais, artificiais e de área (BRANDALIZE, 1993). A principal diferença entre um *software* de Cartografia e um SIG é a capacidade de armazenar a topologia de um mapa e de tratar diversas projeções cartográficas (CÂMARA, 1994).

Para Leite (2006) e QUADROS (2004), a necessidade de diminuição dos custos para a criação de mapas cartográficos, resultou na busca por técnicas que realizassem todo o processo de aquisição, armazenamento, análise e apresentação de dados georreferenciados na superfície terrestre.

Os SIGs permitem ainda a integração de dados de diversas fontes de informações, tais como: levantamentos cadastrais, levantamentos via satélite, levantamentos topográficos e censos (QUINTANILHA, 1995), criando um banco de dados (BD) georreferenciado. De acordo com Hassen (1989), os BDs são estruturas responsáveis pelo armazenamento integrado de registros, permitindo que diversos conjuntos de dados sejam usados por diferentes programas.

2.3. Sensoriamento Remoto

2.3.1. Conceitos e Princípios

As atividades humanas, há centenas de anos, vem modificando o meio ambiente em que está inserido, causando mudanças em grandes escalas temporais e espaciais. O estudo dessa dinâmica de uso e ocupação da terra se torna imprescindível para o controle dos impactos no meio ambiente e para a gestão dos recursos naturais.

Diante desse contexto, as imagens de satélites surgem como uma alternativa viável, no estudo de informações do uso da terra, levantamento ou identificação de solos e cobertura da vegetação, mesmo não tendo a precisão das fotografias aéreas (GARCIA,

1982).

Tendo seu início nas décadas de 60 e 70, o sensoriamento remoto pode ser definido como a aquisição de informações de objetos na superfície terrestre, por meio de um sensor, sem que este esteja em contato físico com o objeto alvo (NOVO, 1998).

Segundo (INPE, 2006a), o sensoriamento remoto corresponde a um conjunto de atividades, cujo objetivo principal reside na caracterização das propriedades de alvos naturais e artificiais, por meio da detecção, registro e análise do fluxo de energia radiante, por eles refletido ou emitido, coletando, assim, informações de uma determinada área sem a necessidade do contato direto com a mesma, como apresentado na Figura 1.

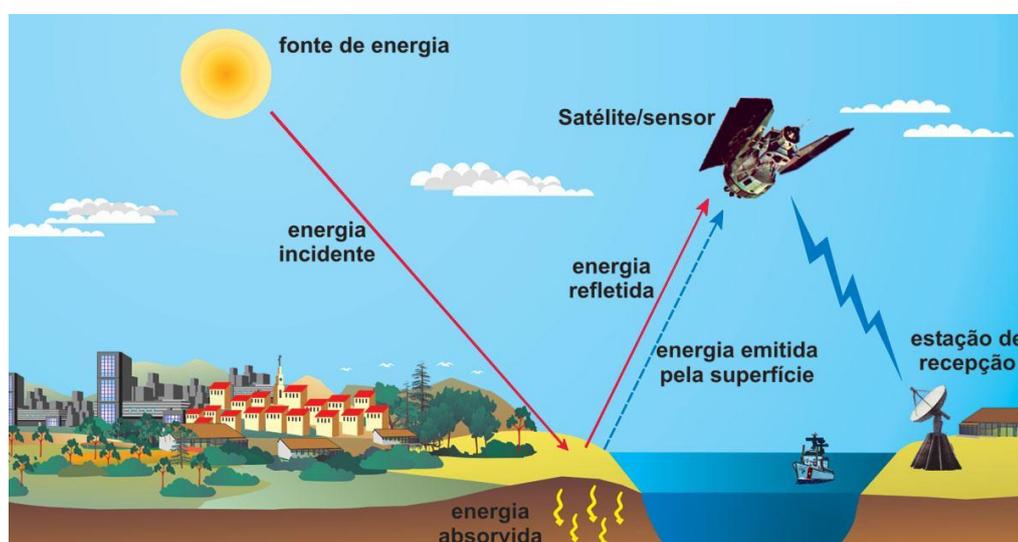


Figura 1. Processo de interação entre o sol (emissor), satélite/sensor (receptor) e estação de recepção dos dados. Fonte: FLORENZANO (2002)

Cotidianamente, depende-se de produtos resultados da aplicação do sensoriamento remoto, focadas tanto para áreas específicas quanto para as mais gerais, como por exemplo: previsão do tempo, levantamento do uso e cobertura da terra e zoneamento ambiental (GOMES, 2005).

2.3.2. Sistemas de Sensores

Realizar o reconhecimento da superfície da Terra de maneira rápida e confiável é a tarefa mais importante para o sucesso do levantamento da dinâmica do uso e cobertura da terra. Para que isso ocorra, via de regra, são utilizados sistemas sensores para obtenção de dados resultantes da reflexão e/ou emissão da radiação eletromagnética pelos alvos da

superfície que se pretende estudar (NOVO, 2008).

De acordo com Novo (2008) e Rocha (2000), os sistemas sensores são responsáveis pela conversão da energia dos objetos em um produto passível de interpretação, seja na forma de imagens, gráficos ou tabelas. Os sensores são capazes de identificar essa energia em forma de radiação eletromagnética em determinadas faixas de espectro e, através de sua frequência, intensidade e polarização, e de transformá-las em informações. Sendo assim, o sistema de aquisição de dados por sensoriamento remoto é formado por uma fonte de energia eletromagnética, por um sensor que transforma a energia, proveniente do alvo, em sinal e por um analisador que transforma este sinal em informação. Com o desenvolvimento tecnológico, é possível medir, com razoável precisão e de forma remota, as propriedades espectrais desses alvos.

Um sistema sensor é basicamente formado por três componentes principais: o coletor, o detetor e o processador. O primeiro é um componente óptico responsável por concentrar o fluxo de energia proveniente do detetor. O detetor corresponde a um componente de dimensões pequenas, feito de um material com propriedades elétricas, que produz um sinal elétrico de acordo com a variação do fluxo de energia que o mesmo absorve. O processador é responsável pela amplificação e digitalização dos sinais gerados pelo detetor (MORAES, 2002).

De acordo com (MOREIRA, 2001; NOVO, 1992; LILLESAND & KIEFER, 1994), existem muitas formas de classificar os sistemas de sensores, levando em conta as diferentes características que estes apresentam, sendo que as mais comuns consideram três aspectos: a fonte de radiação, o princípio de funcionamento e o tipo de produto gerado.

- *Sensores passivos*: não possuem fonte própria de energia eletromagnética, detectam a radiação solar ou a radiação emitida pelos objetos da superfície, ou seja, dependem de uma fonte externa para operar. Exemplo: sensor fotográfico, espectrômetros e radiômetros.
- *Sensores ativos*: possuem uma fonte própria de energia eletromagnética. Eles emitem energia eletromagnética para os objetos terrestres a serem imageados e detectam parte desta energia que é refletida por estes na direção destes sensores. Exemplo: sensores de radar e a laser.

Quanto ao princípio de funcionamento, os sistemas sensores são agrupados em duas categorias: de varredura (*scanning*) e de não-varredura (*non scanning*).

- *Não-varredura (non scanning)*: registram a radiação refletida de uma área da superfície terrestre em sua totalidade, num mesmo instante. Por essa razão também

são conhecidos como sensores de quadro (*framing systems*). Os dados de radiação coletados por esses sensores podem ser expressos em duas formas: imagem (por exemplo, sistemas fotográficos) e não-imagem (gráfica ou numérica, por exemplo, radiômetros).

- *Varredura (scanning)*: a imagem da cena é formada pela aquisição sequencial de imagens elementares do terreno ou “elementos de resolução”, também chamados *pixels*.

O último aspecto é quanto ao tipo de produto, no qual procura-se distinguir o processo de registro da radiação através da forma que esse produto é gerado. Os sensores são classificados em duas categorias: fotográficos e não-fotográficos.

- *Não-fotográfico*: a energia é representada em quantidade discreta, e seus dados estão em forma de sinais elétricos permitindo serem transmitidos eletronicamente, por esta razão, são facilmente digitalizados e analisados por meio de técnicas computacionais.
- *Fotográfico*: a energia é representada de maneira contínua (analógica), é mais simples quando comparado ao não-fotográfico, seu processo usa reações químicas na superfície de um filme sensível à luz, para detectar as variações de energia dentro de uma cena.

A aquisição de dados espectrais de alvos da superfície terrestre pode ser realizada em sistemas sensores em três níveis: o terrestre, o suborbital e o orbital. No nível terrestre, os sistemas sensores podem ser instalados em mastros, colocados em barcos, fixados em bóias ou fixados dentro de laboratórios. Enquanto que no nível suborbital, na maioria dos casos, utilizam-se aeronaves como plataforma de coleta de dados e, para o nível orbital, empregam-se os satélites não tripulados e balões.

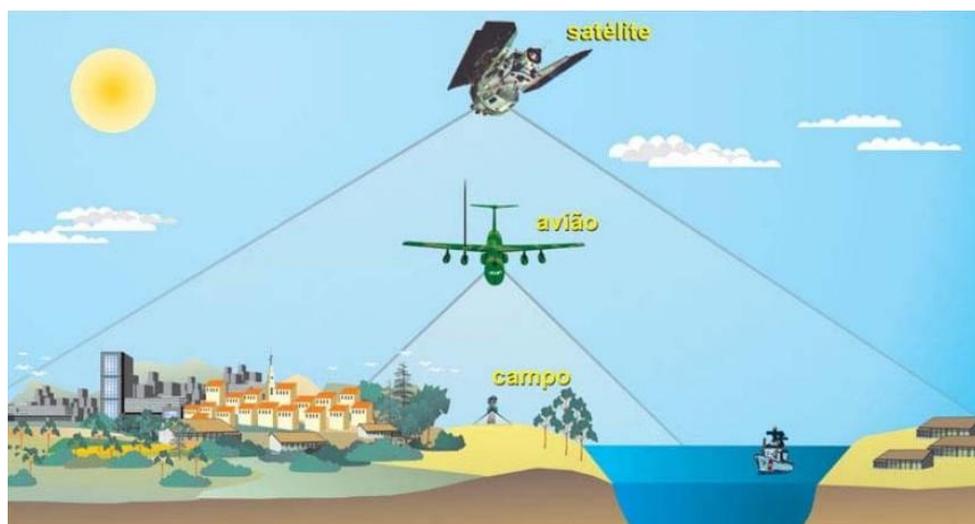


Figura 2. Níveis de coleta de dados espectrais: campo (terrestre), avião (suborbital) e satélite (orbital). Fonte: FLORENZANO (2002)

A escolha certa do sensor está diretamente ligada ao objetivo da pesquisa, pois a definição correta das características do sistema, como por exemplo: informações espectrais e o nível de coleta, que acarretará na precisão dos resultados pretendidos.

2.3.3. Resoluções

O conhecimento acerca dos parâmetros de desempenho dos sistemas sensores é de suma importância para o sucesso da aquisição e análise dos dados. Para cada tipo de aplicação, independentemente do tipo de sensor, é necessário buscar as configurações adequadas de resoluções espacial, espectral, temporal e radiométrica (INPE, 2006a; NOVO, 2008).

A resolução espacial de uma imagem determinará o tipo de aplicação para a qual pode ser utilizada e possui papel importante na interpretação e análise de imagens, pois está relacionada ao nível de detalhe das informações adquiridas pelo sensor.

Segundo Navulur (2006), as resoluções espaciais são categorizadas da seguinte maneira: (1) baixa resolução - imagens com *pixels* maiores ou iguais a 30 m, (2) média resolução – *pixels* de 2,0 a 30 metros, (3) alta resolução – de 0,5 a 2,0 metros e (4) altíssima resolução – menores que 0,5 metros.

A resolução espectral é definida, segundo Novo (2008), como a medida da largura das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade do sinal de retorno, sendo diretamente proporcional à capacidade de

discernimento das variações no comportamento espectral do alvo estudado. Quanto menor a faixa, melhor a resolução espectral ou o poder de discriminação do sensor.

A resolução temporal, para Moreira (2001), é definida em função da plataforma na qual o sensor está colocado. Considerando os sensores orbitais, a resolução temporal indica o intervalo de tempo que o satélite leva para voltar a recobrir a área de interesse. Quanto maior a largura da faixa, menor é o intervalo de tempo de cobertura. Já para Jensen (2009), resolução temporal de um sistema de sensoriamento remoto consiste no intervalo de tempo em que o sensor registra imagens de uma área particular, como por exemplo, Landsat 5 TM, cuja resolução temporal é de 16 dias.

Lillesand e Kiefer (1994) destacam a importância do conhecimento do conceito de pixel, sendo que, uma imagem de sensoriamento remoto digital é composta por um conjunto destes elementos, dispostos na forma de uma matriz bidimensional. Cada *pixel* representa uma porção da superfície terrestre e o conjunto de *pixels* corresponde à área total coberta pela imagem. Cada *pixel* é associado a um valor de intensidade denominado número digital (DN, *Digital Number*), que representa a medida física da quantidade de energia eletromagnética refletida ou emitida pelos alvos e detectada pelo sensor. O número digital é armazenado com uma quantidade finita de bits e o número de bits utilizados para armazenar uma imagem digital expressa a resolução radiométrica.

2.3.4. Satélite LANDSAT

A NASA (*National Aeronautics and Space Administration*) em 23 de julho de 1972, com o apoio do Ministério do Interior Americano, iniciou o programa para lançamento do satélite com sistema experimental chamado de *Earth Resources Technology Satellite* (ERTS-1), mas teve seu nome alterado para LANDSAT (*Land Remote Sensing Satellite*) e, em 1975, houve o início da família LANDSAT (LANDSAT 2, 3, 4, 5 e 7). Os satélites LANDSAT 5 e 7 foram lançados com a finalidade de realizar o mapeamento multiespectral, em alta resolução, de recursos da superfície da Terra.

De acordo com o INPE (2006, b), os três primeiros satélites da série LANDSAT apresentavam dois tipos de sensor: um imagiador multiespectral de varredura (MSS – *Multispectral Scanner Subsystem*) de 4 canais, sendo duas no visível e duas no infravermelho, com resolução de 80 metros e um sistema RBV – *Return Beam Vidicom*, de 3 canais com resolução de 80 metros, no qual são observadas todas as cenas imageadas de

forma instantânea.

O LANDSAT 5 difere dos anteriores por apresentar, além do sensor MSS, o sensor TM (*Thematic Mapper*), que é um sensor óptico mecânico que registra dados em sete bandas espectrais: três, na regiões do visível; uma no infravermelho próximo; duas no infravermelho médio e uma no infravermelho termal, com resolução temporal de 16 dias e resolução espacial de 30 metros, exceto para o termal que é de 120 metros.

O LANDSAT 7 foi lançado em abril de 1999, teve sua última atualização em 2003 e foi encerrado. Neste satélite foi incluído o sensor ETM+ (*Enhanced Thematic Mapper Plus*), que opera de forma idêntica ao TM, diferindo apenas pelo acréscimo de uma banda pancromática e o aumento de ganho na banda termal, com resolução espacial de 60 metros na banda termal e de 15 metros na pancromática, sendo que a última oferece uma resolução espectral de 0,52 – 0,90 m (EMBRAPA, 2005).

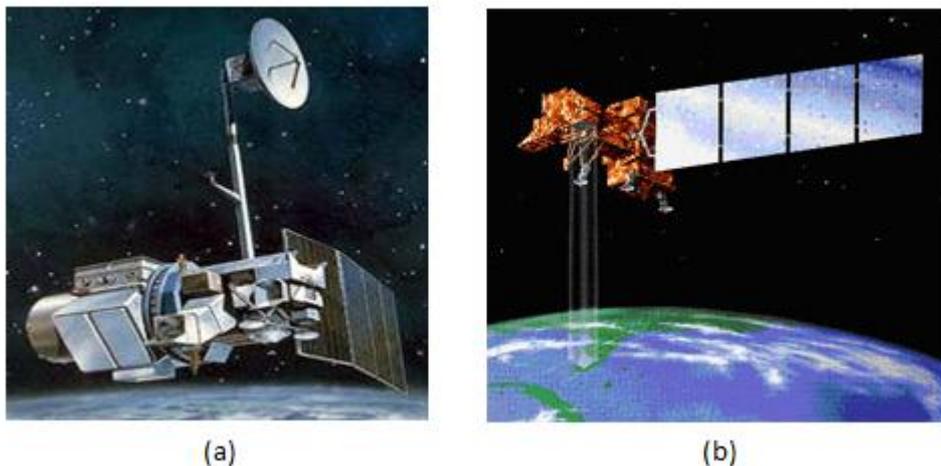


Figura 3. Landsat 5 (a) e Landsat 7 (b). Fonte: <http://landsat.usgs.gov/>

As informações das faixas espectrais, para cada banda deste satélite, bem como as suas potenciais aplicações, foram definidas por Rocha (2000) e estão descritas na tabela 1.

Tabela 1. Bandas espectrais e suas principais características de aplicação de cada banda do sensor

LANDSAT. Fonte: ROCHA (2000)

Banda	Intervalo μm	Principais características e aplicações
1	0,45 - 0,52	Apresenta grande penetração em corpos d'água, com elevada transparência, permitindo estudos batimétricos. Sofre absorção pela clorofila e pigmentos fotossintéticos auxiliares (carotenóides). Apresenta sensibilidade à fumaça oriunda de queimadas ou atividade industrial. Pode apresentar atenuação pela atmosfera.
2	0,52 - 0,60	Apresenta grande sensibilidade à presença de sedimentos em suspensão, possibilitando sua análise em termos de quantidade e qualidade. Boa penetração em corpos de água.
3	0,63 - 0,69	A vegetação verde, densa e uniforme, apresenta grande absorção, ficando escura permitindo bom contraste entre as áreas ocupadas com vegetação e aquelas sem vegetação (exemplo: solo-exposto, estradas e áreas urbanas). Apresenta bom contraste entre diferentes tipos de cobertura vegetal (exemplo: campo cerrado e floresta). Permite análise da variação litológica em regiões com pouca cobertura vegetal. Permite o mapeamento de drenagem através da visualização da mata galeria e entalhe dos cursos dos rios em regiões com pouca cobertura vegetal. É a banda mais utilizada para delimitar a mancha urbana, incluindo identificação de novos loteamentos. Permite a identificação de áreas agrícolas.
4	0,76 - 0,9	Os corpos de água absorvem muita energia nesta banda e ficam escuros, permitindo o mapeamento da rede de drenagem e delineamento de corpos de água. A vegetação verde, densa e uniforme reflete muita energia nesta banda, aparecendo bem clara nas imagens. Apresenta sensibilidade à rugosidade da copa das florestas (dossel). Apresenta sensibilidade à morfologia do terreno, permitindo a obtenção de informações sobre Geomorfologia, Solos e Geologia. Serve para análise e mapeamento de feições geológicas e estruturais. Serve para separar e mapear áreas ocupadas com Pinus e Eucalipto. Serve para mapear áreas ocupadas com vegetação que foram queimadas. Permite a visualização de áreas ocupadas com macrófitas aquáticas (exemplo: aguapé). Permite a identificação de áreas agrícolas.
5	1,55 - 1,75	Apresenta sensibilidade ao teor de umidade das plantas, servindo para observar estresse na vegetação, causado por desequilíbrio hídrico. Esta banda sofre perturbações em caso de ocorrer excesso de chuva antes da obtenção da cena pelo satélite.
6	10,40 - 12,5	Apresenta sensibilidade aos fenômenos relativos aos contrastes térmicos, servindo para detectar propriedades termais de rochas, solos, vegetação e água.
7	2,08 - 2,35	Apresenta sensibilidade à morfologia do terreno, permitindo obter informações sobre Geomorfologia, Solos e Geologia. Esta banda serve para identificar minerais com íons hidroxilas. Potencialmente favorável à discriminação de produtos de alteração hidrotermal.

2.3.5. Processamento Digital de Imagens

Nos últimos vinte e cinco anos, o aumento da utilização de imagens digitais de sensoriamento remoto possibilitou grandes avanços no desenvolvimento das técnicas voltadas à análise de dados multidimensionais, adquiridos por diversos tipos de sensores (INPE, 2006, a).

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2006), o processamento digital de imagens visa à identificação, extração, condensação e realce da informação de interesse, a partir da enorme quantidade de dados que usualmente compõe as imagens digitais, fornecendo ferramentas computacionais para facilitar a identificação e a extração das informações contidas nas imagens, resultado obtido a partir de imagem bruta, objetivando sua posterior análise e interpretação.

Conforme (LILLESAND; KIEFER, 1994), o processamento de imagens digitais abrange técnicas em diferentes contextos: pré-processamento, realce e classificação. As técnicas de pré-processamento têm por objetivo a retificação das distorções e a restauração dos dados da imagem, já as técnicas de realce de imagens visam a melhorar a qualidade visual das imagens, aumentando a distinção entre as características da cena. Para Crosta (1992), as técnicas de classificação de imagem consistem em associar a cada *pixel* uma informação qualitativa (atributo), na qual os valores de nível de cinza que cada *pixel* possui pode ser associado ao nível de reflectância dos materiais que compõem o terreno, estando cada *pixel* ou conjunto de *pixels* associado a uma classe ou tema.

Tais procedimentos, conforme o interesse do pesquisador, podem ser realizados separadamente, em diferentes composições espectrais, permitindo preservar os níveis de cinza da imagem original a ser classificada.

2.3.6. Classificação de Imagens Digitais

A classificação de imagens de satélite é utilizada para obtenção de padrões dos tipos de superfície terrestre, por intermédio da extração de informações importantes nas imagens, de forma automatizada, para criação de mapas digitais temáticos da região de interesse. O resultado final da classificação é uma imagem digital formada por um mapa de *pixels* classificados, representando, em polígonos, os padrões homogêneos de classes de alvos (mapa digital temático).

As técnicas de classificação mais utilizadas para sensoriamento remoto estão divididas entre supervisionada e não-supervisionada. Na classificação supervisionada, cada *pixel* da amostra da base de treinamento tem a sua classe determinada. Essas amostras são escolhidas por um especialista, para que sejam definidas a quantidade e os tipos de classes que serão utilizadas para classificação. Na classificação não-supervisionada, a classificação é realizada de forma automática pelos algoritmos, que fazem a extração, identificação e classificação dos *pixels* e a geração das classes.

2.3.6.1. Classificação por *pixel*

Na classificação *pixel a pixel*, o classificador tem que identificar, de forma confiável, as diferentes assinaturas espectrais extraídas a partir de um determinado conjunto de bandas espectrais (EASTMAN, 2009).

Na classificação por *pixel* é utilizada apenas a informação espectral de cada *pixel* para achar regiões homogêneas. Estes classificadores podem ser separados em métodos estatísticos (utilizam regras da teoria de probabilidade) e determinísticos (não utilizam probabilidade) (SPRING, 1997).

No método de classificação por *pixel*, cada tipo de classe temática, a ser mapeada, utiliza um conjunto de amostras. Os *pixels* são comparados um a um às amostras fornecidas, decidindo assim a qual classe temática eles pertencem. Esses métodos de classificação desconsideram o contexto de inserção dos *pixels* e a textura da imagem (COUTINHO, 1997).

A classificação de imagem *pixel a pixel* pode ser realizada com técnicas supervisionada ou não-supervisionada. Na classificação supervisionada, as áreas de treino, disponibilizadas ao classificador, são dadas pelo especialista, com conhecimento prévio da área de estudo. Já na não-supervisionada, o processo ocorre de forma automática pelo classificador, sendo função do analista fazer a correspondência das classes com o mapeamento real (CHUVIECO, 2002).

2.3.6.2. Classificação por regiões

Na classificação por regiões, além da utilização da informação espectral de cada *pixel*, também é utilizado a informação espacial que envolve a relação com seus vizinhos. Os classificadores procuram simular o comportamento de um foto-intérprete, reconhecendo

áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais das mesmas. A informação de borda é utilizada inicialmente para separar regiões e as propriedades espaciais e espectrais que irão unir áreas com mesma textura (SPRING, 1997).

A necessidade de criar métodos digitais de classificação de imagens reduzindo a subjetividade do processo de interpretação visual e ao mesmo tempo considerando algumas características do meio e não exclusivamente o valor espectral do *pixel* levou ao desenvolvimento de algoritmos de segmentação visando a considerar nas interpretações digitais de imagens de satélite, além do valor espectral dos *pixels*, as características da textura e o contexto de inserção destes (COUTINHO, 1997).

O processo de segmentação representa um passo no sentido de preparar as imagens de satélite para uma futura classificação temática. Os elementos analisados e utilizados na classificação são as regiões criadas a partir da aplicação do segmentador, utilizado para definir o espaço de atributos da classificação (VENTURIERI e SANTOS, 1998).

Para realizar a segmentação é necessário definir dois limiares:

- *O limiar de similaridade*: limiar mínimo, abaixo do qual duas regiões são consideradas similares e agrupadas em uma única região;
- *O limiar de área*: valor de área mínima, dado em número de *pixels*, para que uma região seja individualizada (SHIMABUKURO et al., 1999).

Os classificadores por regiões, supervisionados ou não, agrupam segmentos similares com base em distâncias de separabilidade (COSTA, 1999) e, em vez de considerar um *pixel* como unidade de medida, consideram um agrupamento de *pixels*.

2.4. Considerações Finais

Este capítulo apresentou, de maneira sucinta, os conceitos e fundamentos necessários ao escopo pretendido para esta dissertação, na área de sensoriamento remoto. Foram abordadas definições elementares de geoprocessamento. Ratifica-se que não há intenção da autora em discutir a fundo ou esgotar os assuntos alvo deste capítulo.

Tais assuntos são amplamente discutidos na literatura especializada e podem ser melhor compreendidos em publicações de referências, tal como:

- Geoprocessamento: MORAES, E. C. “Sensoriamento remoto: Princípios e Interpretação de Imagens”. INPE – 2012.

CAPÍTULO 3 – INTELIGÊNCIA COMPUTACIONAL

3.1. Considerações Iniciais

No âmbito deste capítulo, serão apresentados conceitos elementares da área de inteligência computacional, os quais serão necessários para o entendimento deste trabalho. Com tal intuito, apresenta-se um conjunto de modelos e as taxonomias mais referenciadas na literatura especializada.

Analogamente ao sensoriamento remoto, não se tem a pretensão de esgotar o assunto. Trata-se meramente de um levantamento dos fundamentos básicos necessários ao escopo deste trabalho. Entretanto, para aprofundamento dos assuntos abordados neste capítulo, sugere-se consultar (FACELI et al., 2011).

3.2. Inteligência Computacional e Aprendizado de Máquina

Diversos domínios do conhecimento humano tendem a concentrar grandes volumes de dados, como por exemplo: astronomia, climatologia, geologia e outros. Todas essas informações precisam ser armazenadas e gerenciadas, para que seja possível retirar o máximo de conhecimento (MITRA & ACHARYA, 2003).

Com o passar dos anos, cada vez mais a tecnologia teve espaço nesses diversos domínios, disponibilizando um número maior de possibilidades no que se refere à aquisição de dados e, a partir da década de 1970, houve uma maior disseminação da utilização de técnicas de computação baseadas em Inteligência Artificial (IA), voltadas para solucionar problemas reais, que tendem a crescer, seja em complexidade, seja em volume de dados. Segundo LUGER e STUBBLEFIELD (1998), define-se como IA o ramo da ciência da computação que se preocupa com a automatização do comportamento inteligente. Com isso, necessita-se que as técnicas sejam capazes de criar por si próprias, a partir do conhecimento adquirido por experiências passadas, uma hipótese que consiga resolver o problema em questão. Esse processo é conhecido como Aprendizado de Máquina (AM) (FACELI et al., 2011).

Baseando-se em Mitchell (1997), o Aprendizado de Máquina se constitui como a capacidade de aprendizagem a partir de experiências passadas, para realização de uma determinada tarefa, focando-se em melhorar seu desempenho. Para o processo de

aprendizagem, é aplicado o princípio de inferência denominado indução, no qual se obtêm conclusões genéricas a partir de um conjunto particular de exemplos (FACELI et al., 2011). Para Rezende (2003), a indução é a forma de inferência lógica que permite conclusões genéricas a partir de um conjunto particular de exemplos.

Os modelos gerados por algoritmos de AM são treinados a partir de um conjunto de dados, com o objetivo de induzir hipóteses válidas capazes de lidar com situações não apresentadas durante seu desenvolvimento, para outros objetos do mesmo domínio, sem haver necessidade de refazer o modelo. A essa propriedade se dá o nome capacidade de generalização da hipótese.

De acordo com Faceli et al. (2011), quando uma hipótese apresenta uma baixa capacidade de generalização, significa que mesma está superajustada aos dados existentes na base, o que caracteriza-se como *overfitting*. No caso inverso, o *underfitting*, o algoritmo induz hipóteses com baixa taxa de acerto, configurando uma condição de subajustamento. Segundo Monard e Baranauskas (2003), um dos motivos para que essa situação ocorra, é quando os exemplos de treinamento disponíveis na base são pouco representativos ou também pelo modelo ser muito simples, e não capture os padrões existentes.

A forma como é representada e pesquisada a hipótese induzida é particular de cada algoritmo de AM, agindo como uma restrição que implicará na hipótese que melhor se ajusta ao conjunto de treinamento. Sem esses procedimentos, os modelos serão especializados para cada situação presente na base, com isso, não conseguiriam aplicar o conhecimento adquirido para novos dados.

Outro aspecto importante para a construção de um bom modelo é o processo de tratamento dos dados. O modelo precisa ser capaz de lidar com a presença de diversos tipos de imperfeições, como, dados ausentes, inconsistentes, redundantes e ruidosos. Para solucionar esses problemas, é necessário, muitas vezes, que a base de dados original passe por uma etapa de pré-processamento. Em tal etapa, são utilizadas diversas técnicas para que o modelo não tenha dificuldade em induzir hipóteses corretamente. Segundo Faceli et al. (2011), essas técnicas podem ser agrupadas da seguinte forma:

- Eliminação manual de atributos;
- Integração de dados;
- Amostragem de dados;
- Balanceamento de dados;
- Limpeza de dados;
- Redução de dimensionalidade;

- Transformação de dados.

Os algoritmos de AM podem ser organizados de acordo com o paradigma de aprendizado a ser adotado para a tarefa, sendo que podem ser divididas em: preditivas e descritivas.



Figura 4. Hierarquia de aprendizagem, modificado de FACELI et al. (2011).

3.2.1. Modelos Preditivos

São modelos que correspondem um conjunto de amostras rotuladas a uma função que irá estimar seus valores, sejam eles de natureza discreta ou contínua. Quando o rótulo é formado por um domínio com valores nominais, um estimador criado é um **classificador**. Quando o rótulo é constituído por valores numéricos, ordenado e infinito, o estimador é conhecido como **regressor**. Tanto modelos de classificação quanto de regressão possuem aprendizado supervisionado. Segundo Bigus (1996), o aprendizado supervisionado é utilizado quando, em um banco de dados, se tem tanto as perguntas como as respostas. Com isso, faz-se necessário o uso de atributos de entrada e de saída (também conhecido como atributo alvo), para que uma hipótese seja capaz de relacionar os valores dos atributos de entrada de uma determinada amostra presente no conjunto de treinamento, ao seu valor correspondente ao seu atributo de saída. De acordo com Faceli et al. (2011), os principais métodos preditivos são organizados em:

- **Métodos baseados em distância:** consideram a proximidade entre os dados na realização de predições. São afetados pela medida ou função de distância utilizada, e necessitam que os atributos sejam normalizados, para que todos os valores estejam

na mesma escala. Um método baseado em distância utilizado com frequência é o algoritmo dos vizinhos mais próximos.

- **Métodos probabilísticos:** são algoritmos baseados no teorema de Bayes, utilizados para tarefas de previsão e diagnóstico. Representam a distribuição de probabilidade conjunta de um determinado grupo de variáveis aleatórias, ou seja, as informações disponíveis são de natureza imprecisa. O algoritmo mais conhecido desse método é o Naive-Bayes.
- **Métodos baseados em procura:** são construídos com base na caracterização do problema, de acordo com a busca em um espaço de possíveis soluções. Representam estratégias capazes de encontrar uma solução em um base conhecida, de forma rápida, eficaz e generalizada. Os modelos que são frequentemente apontados na literatura são a árvore de decisão e os modelos baseados em regras.
- **Métodos baseados em otimização:** são problemas de maximização ou minimização, onde buscam uma hipótese que descreva as informações de acordo com a função que se pretende otimizar, levando em consideração um conjunto de restrições. Um dos modelos mais conhecidos são os chamados de Algoritmos Genéticos (AG).

3.2.2. Modelos Descritivos

As tarefas do aprendizado descritivo, ou não supervisionado, se referem à identificação de informações relevantes nos dados sem a presença de um elemento externo para guiar o aprendizado. Essencialmente, o aprendizado reside na identificação de propriedades intrínsecas aos dados de entrada, de maneira a construir representações desses dados que possam servir a diversos propósitos como auxílio à tomada de decisões ou descoberta de conhecimento. Essas técnicas são utilizadas principalmente quando o objetivo do aprendizado é encontrar padrões ou tendências que auxiliem no entendimento dos dados (SOUTO et al., 2003). Mais precisamente no aprendizado não supervisionado não existem atributos meta. A partir do conjunto de dados X , um algoritmo de AM não supervisionado aprende a representar as entradas submetidas segundo algum critério de qualidade. As tarefas descritivas podem ser divididas em: sumarização, associação e agrupamento (FACELI et al., 2011).

- **Métodos de sumarização:** tem o objetivo de encontrar uma descrição simples e compacta dos dados. Para isso, podem ser utilizadas desde medidas estatísticas

simples como mínimo, média, desvio padrão, até técnicas sofisticadas de visualização e de determinação de relações funcionais entre atributos (HAN e KAMBER, 2000; MIRKIN, 2011).

- **Métodos de associações:** refere-se à busca de padrões frequentes de associações entre os atributos de um conjunto de dados. O agrupamento, por sua vez, lida com a identificação de grupos nos dados de acordo com a similaridade entre os objetos.
- **Métodos de agrupamento:** é encontrar uma estrutura de *clusters* (grupos) nos dados em que os objetos pertencentes a cada *cluster* compartilham alguma característica ou propriedade relevante para o domínio do problema em estudo, ou seja, são de alguma maneira similares (JIN e DUBES, 1988).

3.2.3. Árvore de Decisão

A técnica de árvore de decisão possui aprendizado preditivo baseado em procura, criando uma hipótese baseada em instâncias particulares para a geração conclusões generalizadas, similar a regras de *if-then*. Ela abrange todo o espaço amostral, com isso, pode realizar predições para qualquer exemplo de entrada (FACELI et al., 2011).

Segundo Safavian e Landgrebe (1991), os principais objetivos da classificação por árvore de decisão são:

- Alta taxa de acurácia para classificação para amostras que não foram vistos na base de treinamento;
- Facilidade de atualização;
- Estrutura de simples compreensão;

Para Russell e Norvig (2003), uma árvore de decisão tem seus atributos de entrada divididos em contínuos ou discretos, no qual, para valores contínuos a aprendizagem é chamada de regressão, e para valores discretos são chamadas de classificação.

Para Hosokawa (2011), uma árvore de decisão é uma estrutura composta por simples regras de decisão, onde são divididas sucessivamente uma coleção de registros em conjuntos menores. Para cada divisão, os dados são separados de acordo com características em comum até chegar a pontos indivisíveis, que representam as classes. Os atributos do banco de dados são representados como nós internos (diferente do atributo classe), sendo que os valores do atributo classe são chamados de folhas. Para cada valor do atributo do nó pai à

um nó filho, é rotulado formando ligações que são conhecidas como ramos. Seguindo o mesmo raciocínio, a estruturada da árvore é organizada de tal forma que:

- Cada nó interno (não-folha) seja rotulado com o nome de um dos atributos previsores;
- Cada ramo ou arestas saindo de um nó interno seja rotulado com valores do atributo naquele nó;
- Cada folha seja rotulada com uma classe.

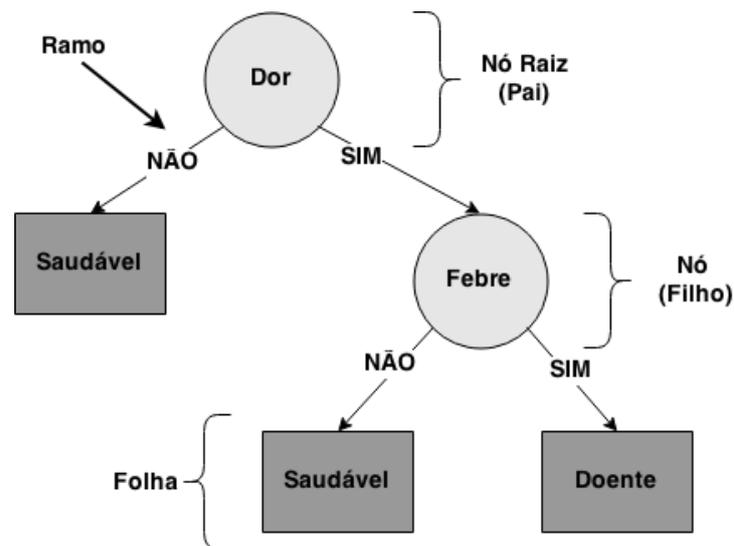


Figura 5. Modelo de árvore de decisão para diagnóstico de pacientes.

Para a construção de uma Árvore de Decisão, é necessário que seja escolhido um critério para a seleção de atributo preditivo, que será utilizado em cada nó. Os critérios de seleção para a melhor divisão são baseados em diferentes medidas, tais como: impureza, distância e dependência.

A poda é considerada a parte mais importante do processo de construção de árvore, pelo razão da existência de ruídos na base de dados. Com isso, as árvores induzidas classificam novos objetos em um modo não confiável e tendem a ter uma grande estrutura tornando difícil a compreensão. O método de poda pode evitar problemas com ruídos ou erros nos ramos da árvore de decisão que levam ao *overfitting* (FACELI et al., 2011). Existem diversas formas de realizar poda em uma árvore de decisão, e todas elas são classificadas como pré-poda ou pós-poda:

- Pré-poda realiza o procedimento durante a construção da árvore. Onde o processo parar de dividir os atributos e transformará o nó corrente em um nó folha da árvore

- Pós-poda realiza o procedimento após a construção da árvore, eliminando ramos completos, fazendo a exclusão de todos os nós abaixo desse ramo e transformando o nó em folha que representa a classe mais frequente no ramo.

Os algoritmos de árvore de decisão são bem aplicados para a classificação do uso e cobertura da terra, pois apresentam tais vantagens: facilidade de interpretação dos resultados, o baixo tempo de processamento, a capacidade do modelo em trabalhar com dados medidos em distintas escalas, o fato de não demandar distribuição normal dos dados e a capacidade em processar as relações não lineares entre os preditores e as classes de cobertura da terra (FRIEDL & BRODLEY, 1997).

3.2.3.1. CART – *Classification and Regression Trees*

O algoritmo CART (*Classification and Regression Trees*) consiste em uma técnica não-paramétrica que estabelece o resultado através de partição binária recursiva, aonde o nó pai se divide entre dois nós-filhos e o processo pode ser repetido tratando cada nó filho como um nó pai. Aonde dependendo do atributo ser é nominal a árvore é de classificação ser contínuo árvore de regressão (BREIMAN et al., 1984)

Segundo Fonseca (1994) umas das virtudes do CART é a grande capacidade de pesquisa de relação entre os dados mesmo quando elas não são evidentes, bem como a produção de resultados sob a forma de árvores de decisão de grande simplicidade e legibilidade. As principais vantagens do Algoritmo de CART são:

- Poder utilizar variáveis independentes de diferentes tipos, desde contínuas, ordinais e nominais.
- Não obrigar a realização de transformações das variáveis iniciais independentes (como a logaritmização ou normalização), já que o método tem bom comportamento para qualquer tipo de dados.
- Poder usar a mesma variável em diferentes estágios do modelo, permitindo reconhecer efeitos que certas variáveis produzem sobre outras.
- Não necessitar satisfazer qualquer condição de aplicabilidade do modelo, o que não acontece nos modelos paramétricos.

Para executar a divisão de um nó em dois filhos o algoritmo utiliza questões cuja resposta só pode ser “sim” ou “não”. Quando encontrada a melhor divisão o processo é

repetido para cada nó filho, até que a divisão seja interrompida, ou seja, impossível de ser realizada. Após o fim do crescimento da árvore do algoritmo CART, é realizada a pós-poda para aumentar o poder de generalização (BREIMAN et al., 1984).

3.2.3.2. RF - *Random Forest*

O algoritmo *Random Forest* (RF) é um classificador estatístico muito eficaz e com vasta aplicação (CUTLER et al., 2007), eficiente na classificação de imagens de satélite (GISLANSO, et al., 2006). O procedimento geral passa por reunir um conjunto de métodos, que usa várias “árvores de decisão”, independentes e distribuídas de forma semelhante por vetores aleatórios segundo um padrão de entrada (BREIMAN, 2001), com o objetivo de produzir uma classificação mais exata possível (CUTLER et al., 2007).

O RF é um método frequentemente utilizado na comunidade científica para classificação e regressão, uma vez que consegue lidar com dados com poucas observações e muitas variáveis, com dados que têm interações complexas, e até com os que têm correlações elevadas entre variáveis predictoras. Consiste num conjunto de modelos baseados em árvores, onde cada árvore é obtida escolhendo de forma aleatória, durante a sua construção, observações e variáveis dos dados originais. Cada árvore sugere um voto para a classe que julga ser a correta, para um determinado padrão de entrada; sendo que a classificação final é determinada pelo maior número de votos reunidos pelas árvores alocadas a cada classe (GISLANSO et al., 2005).

A sua aplicação na classificação de imagens satélite é recomendável, pois inclui métricas que destacam a importância de variáveis, e a similaridade entre pontos, que podem ser agrupados, em diferentes níveis, classificando a imagem por inteiro, atribuindo valores quando inexistentes, produzindo um resultado gráfico (CUTLER et al., 2007).

3.2.4. Técnica de Máxima Verossimilhança

A técnica de Máxima Verossimilhança (MAXVER) é uma das mais utilizadas em sensoriamento remoto dentro da abordagem estatística. Considerado um método tradicional estatístico, que envolve parâmetros (vetor média e matriz de covariância) da distribuição gaussiana multivariada e é supervisionado, pois estima esses parâmetros através das amostras de treinamento (ERBERT, 2001).

Este tipo de classificador é baseado na estratégia de “Otimização de Bayes” ou

“Método Bayesiano”, o qual minimiza o erro de classificação sobre toda entrada de dados classificados. Assumindo que todos os atributos de entrada possuam distribuição normal, e a partir desse ponto, calcula a probabilidade de um dado pixel pertencer a uma classe específica (INPE, 2008)

Na primeira fase, a imagem é classificada pelo algoritmo de Máxima Verossimilhança atribuindo classes aos *pixels*, considerando os valores de níveis digitais. Na fase seguinte, leva-se em conta a informação contextual da imagem, ou seja, a classe atribuída depende tanto do valor observado nesse *pixel*, quanto das classes atribuídas aos seus vizinhos.

Segundo Meneses e Sano (2012), o algoritmo de Máxima Verossimilhança é um classificador eficiente aonde as classes de treinamento são utilizadas para estimar a forma da distribuição dos pixels contidos em cada classe no espaço de n bandas, como também a localização do centro de cada classe. Se a distribuição dos pontos for claramente não esférica, como um elipsóide, seria esperado que a possibilidade (probabilidade) de um ponto pertencer ao agrupamento dependesse não somente da distância ao centro do agrupamento, mas também das dimensões e direções dos eixos do elipsóide.

3.2.5. SVM - Support Vector Machine

Support Vector Machine (SVM) é uma técnica de aprendizado de máquina preditivo, fundamentada nos princípios da Minimização do Risco Estrutural (*Structural Risk Minimization* – SRM). Esta técnica busca minimizar o erro com relação ao conjunto de treinamento (risco empírico), assim como o erro com relação ao conjunto de teste, conjunto de amostras não empregadas no treinamento do classificador (risco na generalização). O objetivo de SVM consiste em obter um equilíbrio entre esses erros, minimizando o excesso de ajustes com respeito às amostras de treinamento (*overfitting*) e aumentando a capacidade de generalização (VAPNIK, 1999).

Segundo (SMOLA et al., 1999b), algumas de suas principais características são:

- Capacidade de generalização: eficiente na classificação de dados que não pertençam ao conjunto utilizado em seu treinamento, evitando o *overfitting*.
- Robustez em grandes dimensões: diante de objetos de grandes dimensões, como, por exemplo: imagens. Comumente há ocorrência de *overfitting* nos classificadores gerados por outros métodos inteligentes sobre esses tipos de dados.

- Convexidade da função objetivo: implica na otimização de uma função quadrática, que possui apenas um mínimo global.
- Teoria bem definida: as SVMs possuem uma base teórica bem estabelecida dentro da Matemática e Estatística.

Vale destacar que a SVM só pode ser utilizada na separação de um par de classes a cada vez. Dados de sensoriamento remoto de cenas naturais envolvem a presença de um número maior de classes. Desta forma, aplicações de técnicas SVM na classificação de imagens de sensoriamento remoto requerem abordagens adequadas (MELGANI & BRUZZONE, 2004).

3.2.6. RNA - Redes Neurais Artificiais

As redes neurais artificiais são modelos computacionais inspirados no sistema nervoso biológico, cujo funcionamento é semelhante a alguns procedimentos humanos, ou seja, aprendem pela experiência, generalizam exemplos através de outros, e abstraem características. (WASSERMAN, 1989). A RNA pode exercer tarefas aplicadas tanto para a regressão quanto para a classificação, dependendo do algoritmo e da problemática escolhida.

O algoritmo de treinamento mais comum das RNAs envolve uma regra de correção de erros, na qual se recorre à otimização de uma função quadrática do erro entre as respostas da RNA e os rótulos dos exemplos (FACELI et al., 2011).

Vários algoritmos têm sido propostos na literatura para o ajuste dos parâmetros, para que o modelo obtenha um melhor desempenho, os principais modelos são: Perceptron, Perceptron Multicamadas, Redes de Kohonen e Redes de Hopfield, cada um destes com características direcionadas para diferentes aplicações.

É importante destacar, que a tarefa de extração do conhecimento por um modelo RNA exige recursos e esforços adicionais. Então, deve-se antes do início do processo de construção do modelo, atentar se o cenário em que o problema se encaixa, justifica a utilização de uma RNA.

Entre as técnicas de Inteligência Artificial, as Redes Neurais Artificiais (RNAs) têm sido utilizadas com frequência em problemas de classificação de imagens de sensoriamento remoto (BENEDIKTSSON, SWAIN & ERSOY (1990); HEPNER, et al (1990); YOSHIDA e OMATU (1994); KUSHADORNO, et al (1994); BINAGHI & RAMPININI (1993); MACHADO, et al (1993); CHAKRABARTI, BINDAL e THEAGHARAJAN (1995) e

FOODY, MCCULLOCH e YATES (1995)).

Vários trabalhos têm demonstrado a eficácia da utilização de RNAs para a classificação de imagens de satélite. Para (RIBEIRO & CENTENO, 2001), a classificação digital consiste em associar determinado *pixel* a determinada categoria ou classe por meio de critérios e estabelecidos.

3.3. Considerações Finais

Este capítulo apresentou, concisamente, os conceitos essenciais ao escopo pretendido para esta dissertação. Foram abordadas definições elementares de inteligência computacional. Ratifica-se que não há intenção da autora em discutir a fundo ou esgotar os assuntos alvo deste capítulo.

Tais assuntos são amplamente discutidos na literatura especializada e podem ser melhor compreendidos em publicações de referências, tal como:

- Inteligência Computacional: FACELI, K. et al. “Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina”, LTC, 1a Edição, 2011

CAPÍTULO 4 – TRABALHOS RELACIONADOS

4.1. Considerações Iniciais

A análise do uso e cobertura da terra (termo em inglês, *Land Use/Land Cover - LULC*) e a detecção das mudanças associadas, são vitais para o entendimento do processo de transformação do meio ambiente. A identificação e monitoramento das transformações no uso e cobertura da terra utilizando imagens multiespectrais de satélite vêm se tornando o tópico de interesse de pesquisadores na área de sensoriamento remoto. Observando esse contexto, serão abordados trabalhos realizados recentemente nesta área, enfatizando diferentes técnicas e métodos adotados no processo de classificações de imagens de satélite.

4.2. Comparação de Técnicas de Classificação de Imagens de Satélite

O sensoriamento remoto tem um papel fundamental no monitoramento do uso e cobertura da terra, pois permite obter informações históricas e atuais de ambientes com grandes dimensões territoriais e de difícil acesso. Para auxiliar nesta ação, é utilizada a classificação das imagens capturadas pelos sensores dos satélites. Classificação é o processo de extração de informações que abrange um conjunto de técnicas que podem ser matemáticas ou estatísticas, e que automatiza a categorização de todos os pixels de uma imagem em temas ou classes de uso e cobertura da terra (LIANG et al, 2012).

No contexto amazônico, o sensoriamento remoto é indispensável para monitorar o ambiente, detectar ações desmatamento e queimadas. Diante disso, métodos e ferramentas para classificar imagens de satélite têm sido o centro das atenções para estudar o uso e cobertura da terra, bem como as mudanças ocorridas ao longo dos anos. Esses estudos podem subsidiar políticas públicas para conter o desmatamento de forma eficiente, auxiliando famílias assentadas a utilizar a terra de forma sustentável.

É possível encontrar, na literatura especializada, diversos estudos que comparam o desempenho de diferentes técnicas de classificação aplicadas a diferentes ambientes. Com o intuito de tornar o estudo comparativo mais confiável, serão abordados trabalhos que possuam cenários com características semelhantes ao do proposto nesta dissertação.

Em (PRADHAN, 2013), a fim de mapear as áreas suscetíveis a deslizamentos de terra na região de Penang Hill (Malásia), no período compreendido entre 1981 e 2003, foi realizado um estudo comparativo entre as técnicas de árvore de decisão (DT – *Decision Tree*), máquina de vetores de suporte (SVM - *Support Vector Machine*) e sistema de inferência neuro-fuzzy adaptativo (ANFIS – *Adaptive Neuro-Fuzzy Inference System*). Para esta tarefa, foram utilizadas diferentes fontes de dados, tais como: mapas topográficos e geológicos, cobertura do solo, informações sobre drenagem e histórico de deslizamentos. Para cada técnica foi aplicada uma metodologia diferente, por exemplo, para a construção do modelo da árvore de decisão foi adotado o algoritmo CHAID (*chi-squared automatic interaction detector decision tree*) utilizando o software SPSS Clementine 12.0 (PERES, 2013), já para o modelo ANFIS, foram usados três ambientes computacionais, o primeiro, o ArcGIS (TIM et. al., 2010), foi utilizado para extrair os dados de entrada, tais como informações sobre tipo de solo, altitude, curvatura e etc, em seguida foi utilizado um programa feito em linguagem C que é responsável por converter as informações vindas do ArcGIS para o formato de matriz de dados. O último ambiente é o software MATLAB (AHLERSTEN, 2012), no qual são determinados a estrutura e o treinamento e realizada a validação do ANFIS. Várias combinações de dados de entrada foram testadas, sendo que a melhor combinação foi usando todas as variáveis disponíveis. A técnica ANFIS obteve o melhor desempenho, com uma taxa de acerto de 94.21%, seguido pelo SVM com 91.67% e DT com 88.36%.

O estudo realizado em (SZUSTER & BORGER, 2011), avaliou a eficácia da técnica SVM em regiões de costa tropical, em comparação com as técnicas de redes neurais artificiais (ANN – *Artificial Neural Networks*) e de máxima verossimilhança (MLC – *Maximum Likelihood Classifier*). Sua área de estudo é a ilha Thai de Koh Tao, localizada no leste da Tailândia, com uma área de cobertura de aproximadamente 19 km². Em decorrência disso, os autores destacam a dificuldade em classificar esse tipo de área, em razão do pequeno número de pixels e da pouca diversidade entre eles, o que limita a disponibilidade de classes e possíveis divisões em sub-classes. A imagem usada por este estudo foi adquirida pelo satélite NASA Terra, com o sensor ASTER (*Advanced Space borne Thermal Emission and Reflection Radiometer*) no dia 22 de junho de 2004. Foram adotados sete tipos de cobertura do solo como classes de saída do estudo, quais sejam: litoral rochoso, vegetação, águas profundas, águas rasas, areia da praia, areia do fundo do oceano, e construções. Como base de treinamento e teste foram utilizados 98 pontos georreferenciados. O modelo SVM foi criado usando o software LIBSVM (*Library for*

Support Vector Machines) (RONG et al, 2005), enquanto que os modelos das técnicas MLC e ANN, foram gerados com o apoio do software ENVI 4.2 (MORTON, 2009). Os resultados de taxa de acerto foram equilibrados, com um pequeno destaque para ANN, que obteve 94,99%, seguido pelo SVM com 94,15% e MLC com 93,95%.

Outro trabalho que também compara o desempenho entre as técnicas SVM, ANN e MLC como classificadores de imagens de satélite, foi apresentado por (SRIVASTAVA, 2012). Este estudo se difere de (SZUSTER & BORGER, 2011) principalmente pelo fato de utilizar imagens dos satélites Landsat 5 e 7, sensores TM (*Thematic Mapper*) e ETM+ (*Enhanced Thematic Mapper Plus*) e pelo fato do tamanho da região estudada ser bem maior, localizada na área de WalnutCreek em Iowa, nos Estados Unidos. Para minimizar os efeitos causados pela sazonalidade nas mudanças do uso e cobertura da terra, todas as imagens foram selecionadas com datas similares no intervalo dos meses de julho e agosto, nos anos de 2002, 2006 e 2010, totalizando três imagens com 0% de cobertura de nuvens. Como variáveis de entrada foram utilizadas as informações de intensidade espectral das bandas 2, 3, 4 e 5. Como saída, foram obtidas cinco classes: alfalfa, soja, milho, água e área urbana. O resultado deste estudo também aponta que a técnica ANN possui o melhor desempenho, com acurácia e índice kappa com valores de 84.9% e 0.74, respectivamente. Também foram avaliados diversos tipos de algoritmos SVN tais como, sigmoid, polynomial, RBF e linear, sendo que o último foi o melhor com 84,86% de acurácia e 0.7496 de índice kappa. A técnica MLC foi a que mais se distanciou das demais técnicas, com 82,87% de acurácia e 0.7171 de índice kappa.

Atualmente, técnicas de sensoriamento remoto estão sendo constantemente aplicadas para a extração de conhecimento sobre a dinâmica e monitoramento de mudanças no uso e cobertura da terra. Em (DEILMAI, 2014), técnicas supervisionadas (ANN e MLC) são empregadas com o objetivo de detectar mudanças na cobertura de florestas tropicais, e indicar qual delas é a mais adequada para classificação desse tipo de cenário. A área estudada está localizada no estado de Johor, na península da Malásia, com área total de 19,210 km². As imagens utilizadas foram dos anos 2000 (Landsat 7 ETM+) e 2009 (Landsat 5 TM), ambas com resolução espacial de 30 metros. Para a correção dos erros atmosféricos foi utilizado o software ERDAS Imagine (ERDAS, 2001), a fim de obter uma melhor acurácia nos resultados. Antes do processo de classificação, foi feita a definição das classes de cobertura da terra, que estão presentes na área de estudo, com o auxílio do mapa produzido pelo departamento de agricultura da Malásia, do ano de 2008. Após a definição das classes temáticas, a base de treinamento foi formada visando o balanceamento de

amostras de pixels por classes, com áreas correspondentes em ambas as imagens. O processo de classificação utilizou-se apenas das informações espectrais das seis bandas de cada imagem (visível, infravermelho próximo e infravermelho de ondas curtas), e seis classes de saída: floresta, óleo de palma, borracha, cidade, água e cobertura de nuvens. A técnica ANN mostrou-se melhor em relação à classificação para os dois anos (2000 e 2009), com taxas de acerto de 75% e 80%, respectivamente, enquanto que a técnica MLC obteve apenas 68% para o ano de 2000 e 75% para 2009.

Todos os trabalhos apresentados anteriormente empregam técnicas supervisionadas de inteligência computacional, para classificação e mapeamento do uso e cobertura da terra. Tendo em vista que a tarefa de classificação pode ser realizada também de forma não-supervisionada, ou seja, sem a necessidade de um especialista para a rotulação das classes, é importante também destacar trabalhos que apliquem tal técnica, em cenários semelhantes aos vistos.

No trabalho elaborado por (AL-AHMADI & HAMES, 2009), foi realizado um estudo comparativo entre uma técnica de classificação não-supervisionada e três técnicas de classificação supervisionada. As técnicas de classificação supervisionadas são: máxima verossimilhança, distância mahalanobis e distância mínima. A técnica de classificação não-supervisionada utilizada foi o método ISODATA. Esses quatro métodos de classificação de imagens de satélite foram aplicados em três regiões áridas e remotas, localizadas na Árabia Saudita, com áreas que vão de 100 à 300 km². As imagens foram obtidas através do sensor TM do satélite Landsat 5 e do sensor EMT+ do satélite Landsat 7. As imagens foram ortoretificadas por meio do software ArcGIS. Na metodologia deste estudo, a técnica não-supervisionada foi responsável pela identificação das classes temáticas presentes em cada região, formando grupos de pixels, baseando-se apenas em suas características espectrais. Esses grupos foram divididos e transformados em categorias. Todo o processo foi implementado com o auxílio do software ERDAS. Como a classificação supervisionada necessita de uma base de treinamento rotulada para a construção de seu modelo, o autor utilizou as classes criadas pelo método ISODATA para essa função, e a partir disso, foi avaliado o desempenho de classificação das demais técnicas. O método com melhor acurácia foi o de máxima verossimilhança com 80% de taxa de acerto, O método de distância mínima obteve o menor valor de acurácia, 67%.

O estudo conduzido em (RODRIGUEZ-GALIANO, 2012), aborda um dos principais desafios para aplicações de sensoriamento remoto para fins de classificação do uso e cobertura da terra - o tratamento de áreas de grande escala. Devido às várias limitações que

estão relacionadas principalmente à heterogeneidade das paisagens das áreas de estudo, ou seja, a grande diversidade de características ambientais (ex. temperatura, relevo e etc.), acaba tornando o processo de categorização de classes temáticas mais complexo e conseqüentemente, demandando um maior tempo. Além disso, faz-se necessário uma escolha consciente de diversos fatores, como por exemplo, a seleção do algoritmo que melhor se adapta às informações ruidosas e a capacidade do mesmo em trabalhar com um pequeno número de amostras de treinamento, quando comparado ao tamanho da área estudada.

Em (RODRIGUEZ-GALIANO, 2012), a técnica *Random Forest* (RF) foi selecionada para o processo de classificação aplicada na região da província de Granada, localizada no sul da Espanha. Foi realizado um estudo aprofundado sobre o comportamento do algoritmo RF em diferentes situações: com a variação do número de árvores, com a separação em relação ao número de variáveis, com a variação do número de dados de treinamento e adição de ruídos. Para este estudo, foram utilizados apenas as informações espectrais de duas imagens do satélite Landsat 5 TM como variáveis de entrada e 14 classes temáticas como saída. Como resultado do trabalho, destacou-se que quanto mais heterogêneas forem as categorias, mais difícil será o acerto na classificação. Também foi constatado que a redução do número de amostras não afeta, de forma significativa, a acurácia do modelo criado pelo algoritmo RF.

4.3. Considerações Finais

De acordo com o levantamento bibliográfico acerca da área de sensoriamento remoto, mais especificamente sobre as aplicações que estudam e monitoram o uso e cobertura da terra, ficou evidenciado o grande interesse por parte de vários grupos de pesquisa, em diferentes países, por este assunto. Entretanto, apesar disso, cada grupo adota uma abordagem diferente, não havendo uma padronização para a tarefa de classificação de imagens de satélites, para esses fins.

Esta dissertação tem o objetivo de apresentar uma metodologia inovadora e eficiente para classificação de imagens de satélite, para análise do uso e cobertura da terra em áreas de projetos de assentamentos, localizados na Amazônia brasileira, a qual, entretanto, pode ser generalizada para uso em áreas com outras características.

CAPÍTULO 5 – ClasSIS: METODOLOGIA PARA CLASSIFICAÇÃO SUPERVISIONADA DE IMAGENS DE SATÉLITE

5.1. Considerações iniciais

Neste capítulo, a partir do entendimento do fenômeno a ser estudado, propõe-se uma metodologia, denominada ClasSIS, com potencial para sistematizar o processo de classificação de imagens de sensoriamento remoto, com a finalidade de categorizar o uso e cobertura da terra, por meio da associação de cada pixel a uma classe temática pré-definida.

5.2. Metodologia ClasSIS

A ClasSIS é uma metodologia para a Classificação Supervisionada de Imagens de Satélite, composta essencialmente por dois módulos. O primeiro possui duas fases, que são executadas semiautomaticamente; e o segundo módulo se subdivide em três fases, as quais são executadas de forma automatizada. A Figura 6, apresenta o detalhamento da metodologia ClasSIS e seus respectivos módulos e fases.

Para a classificação temática do uso e cobertura da terra é necessário o estrito cumprimento das cinco fases, que deverão ser executadas de forma sequencial.

5.2.1. Módulo de Tratamento de Imagem

O primeiro módulo é responsável pelo levantamento e respectivo tratamento das imagens de satélite que serão utilizadas no estudo de interesse.

5.2.1.1. 1ª Fase – Aquisição de Dados

O início do Módulo de Tratamento de Imagens se dá pela fase de aquisição dos dados, correspondendo ao processo de definição dos requisitos mínimos que a(s) imagem(ns) deve(m) conter para ser(em) selecionada(s) para o estudo. Tal definição depende das características da região em que a área de interesse está inserida e dos objetivos do estudo.

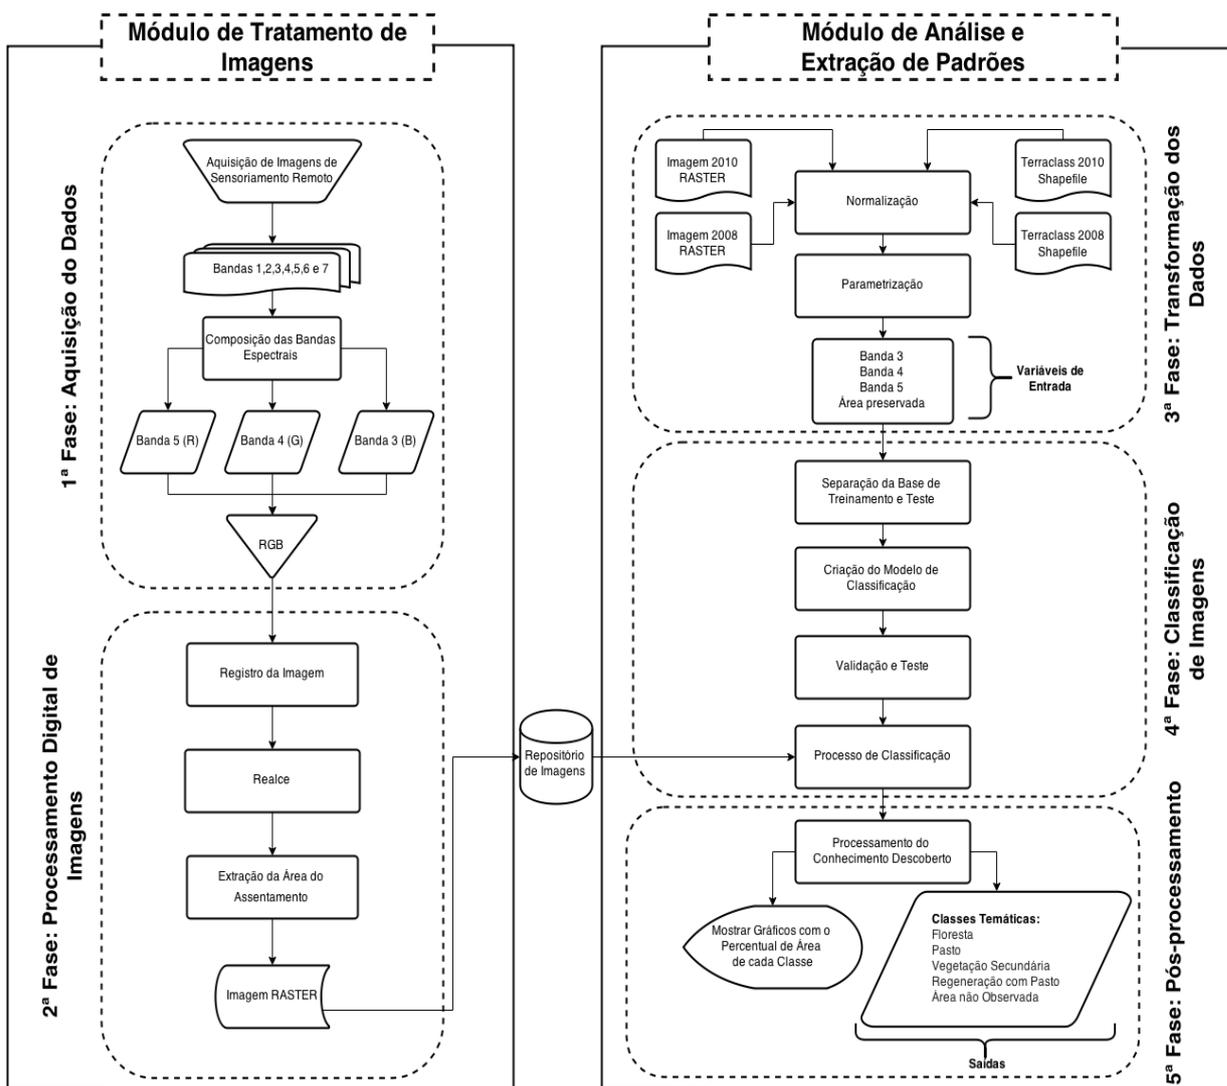


Figura 6. Metodológico ClasSIS. Fonte: Autor.

Um desses requisitos é a disponibilidade das imagens, que leva em consideração, principalmente, quais satélites capturam imagens da região de interesse, assim como quais

as resoluções temporais, espaciais e espectrais correspondentes, ou seja, é importante realizar um levantamento da melhor combinação entre a oferta de recursos e as necessidades do estudo. Outro fator importante, que se deve empenhar a devida atenção, é o nível da cobertura de nuvens na região, já que, dependendo do tamanho da área de interesse, a qualidade dos resultados será inversamente proporcional à quantidade de ruídos que serão inseridos no processo de classificação. Todos os fatores anteriormente destacados, também influenciam diretamente na escolha do intervalo de tempo entre as imagens que irão compor a série histórica.

Ainda nesta fase, é necessário que sejam definidas as bandas que melhor representam a descrição visual para as classes temáticas de interesse, que, no caso desta dissertação, visa à qualificação do uso e cobertura da terra.

Ao final da **fase de aquisição dos dados**, tem-se como produto um conjunto de imagens que deverão passar, posteriormente, por um processo de eliminação de imperfeições e ruídos causados por fatores técnicos e ambientais.

5.2.1.2. 2ª Fase – Processamento Digital de Imagens

A segunda fase será responsável por corrigir típicos tipos de erros e recuperar informações perdidas, resultando no aumento da confiabilidade e da qualidade das imagens. Isto é feito com o auxílio de uma ferramenta de GIS (*Geographic Information System*).

Esta fase consiste, basicamente, na aplicação de técnicas de pré-processamento e de realce. O primeiro passo desta fase é o registro da imagem, que é necessário para a correção geométrica das bandas espectrais que, a partir da definição de pontos de controle, fixam a imagem à base cartográfica de referência, possibilitando a integração da mesma com outras fontes de dados.

Tal integração é necessária para a realização do próximo passo, o processo de extração da área do assentamento, por intermédio de um arquivo do tipo *shapefile* (dados vetoriais) dos limites do assentamento estudado.

O próximo passo é o processo de realce de contraste, também denominado realce radiométrico, aplicado com a finalidade de redistribuir linearmente os níveis de cinza dos *pixels* da imagem, sem a alteração do formato do histograma de entrada, realçando características espectrais.

Ao término dessas duas fases, ter-se-á um repositório que, com todas as imagens envolvidas no estudo, serão utilizadas no segundo módulo de ClasSIS.

5.2.2. Módulo de Análise e Extração de Padrões

5.2.2.1. 3ª. Fase – Normalização dos Dados

O segundo módulo da ClasSIS inicia com a implementação do método responsável por realizar a **fase de normalização dos dados**. Esta fase se caracteriza pela conversão dos arquivos do formato de imagem *raster* e de dados vetoriais (*shapefile*), em um formato que permita que sejam reorganizados, para compor apenas um único arquivo de dados. O arquivo resultante desta fase é utilizado como entrada para o próximo passo, a parametrização dos dados.

No processo de parametrização dos dados, são definidas as variáveis de entrada utilizadas pela fase de classificação de imagens. A saída desse método corresponde a um arquivo no formato matricial, no qual cada coluna corresponde a uma informação diferente e as linhas se referem a cada *pixel*, iniciando com as coordenadas de localização (x e y), seguindo-se com os níveis de cinza de cada banda RGB. As informações de localização dos *pixels* não são consideradas como variável de entrada, pois são usadas apenas como índices da matriz. Já na fase de pós-processamento, a localização dos *pixels* será utilizada na construção da imagem classificada.

A última variável de entrada é denominada de “área preservada” e seu processo de composição é um pouco mais complexo, sendo necessária a utilização da classificação dos *pixels* da imagem do ano anterior ao que está sendo classificado. Assume-se que as imagens serão classificadas da mais antiga à mais recente. Tal atributo é do tipo booleano, assumindo o valor verdadeiro somente se o *pixel* correspondente, da imagem anterior, tiver sido

classificado como floresta; e o valor falso, nos demais casos. Para a primeira imagem, a variável “área preservada” assume o valor verdadeiro para todos os *pixels*.

O uso desta variável se faz necessário para satisfazer a premissa que diz que se uma área deixa de ser floresta, ela não retornará mais para esse estado, já que não voltará a ter a mesma quantidade de carbono e de biodiversidade característicos de uma floresta nativa (CAMARA et al., 2013).

Ao final da fase de normalização de dados, tem-se a formação de uma base de amostras que será utilizada na penúltima fase de ClasSIS - a fase de classificação de imagens.

5.2.2.2. 4ª. Fase – Classificação de Imagens

O primeiro passo desta fase é dividir o banco de amostras em uma base destinada ao treinamento e uma outra destinada ao teste do classificador. Esse processo separa 70% das amostras de forma aleatória com a finalidade de treinar o modelo, e os 30% restantes para o processo de validação do mesmo. Esses valores foram definidos, na tentativa de melhorar o balanceamento das amostras por classes (SZUSTER & BORGER, 2011).

De acordo com o comportamento do número de amostras disponíveis na imagem da área de interesse, é possível definir o número de classes temáticas de saída do modelo de classificação, pois, como é usado o tipo de aprendizagem supervisionada, para ter-se um bom nível de confiabilidade na classificação é necessário que o número de amostras por classe seja balanceado.

Com a definição da base de treinamento, é possível ensinar a uma técnica de classificação supervisionada a reconhecer padrões e, posteriormente, aplicar esse modelo na classificação das demais imagens presentes no repositório.

5.2.2.3. 5ª. Fase – Pós-Processamento

A última fase do Módulo de Análise e Extração de Padrões é denominada de pós-processamento, pois ela transforma os resultados obtidos na fase anterior em planos de

informações do tipo temático, permitindo, desta maneira, a visualização em forma de imagem e em tabelas de porcentagem de áreas de cada classe.

5.3. Considerações Finais

Neste capítulo, detalhou-se a metodologia proposta por esta dissertação - ClasSIS, definindo-a minuciosamente, desde os processos responsáveis pela aquisição e tratamento das imagens de satélite até a construção dos modelos de classificação supervisionada. Também foi enfatizada a importância da seleção das imagens que irão compor a série histórica, a escolha correta dos parâmetros de entrada e a formação da base de treinamento, a fim de garantir a qualidade e confiabilidade dos resultados obtidos.

Tal metodologia é uma proposição original e inovadora que, no contexto desta dissertação, é aplicada ao estudo de uso e cobertura da terra em regiões de assentamentos, mas é imprescindível ressaltar que, pelo alto grau de generalização intrínseco à ClasSIS, tal metodologia pode ser instanciada para diversos outros domínios de aplicação, notadamente no que tange ao estudo de fenômenos ambientais.

CAPÍTULO 6 – ESTUDO DE CASO: USO E COBERTURA DA TERRA NO ASSENTAMENTO 26 DE MARÇO

6.1. Considerações iniciais

O objetivo deste capítulo é aplicar passo a passo a metodologia ClasSIS, por intermédio de um estudo de caso no Projeto de Assentamento (PA) 26 de Março, em Marabá/PA. Inicia-se com uma contextualização acerca das características da região alvo. Em seguida, definem-se todos os requisitos necessários, e o processo de classificação de imagens é levado a cabo, fazendo uso de quatro técnicas de classificação supervisionada, quais sejam: árvore de decisão, redes neurais artificiais, máquina de suporte de vetores (SVM), e o método de máxima verossimilhança, para que seja escolhida a técnica que obtiver o melhor desempenho. Ao final de todas as etapas da metodologia proposta, os modelos de classificações gerados são validados e seus desempenhos avaliados, para que seja apontada aquela mais adequada ao cenário estudado nesta dissertação.

6.2. Localização e caracterização da área de estudo

A área de estudo corresponde ao Assentamento 26 de Março, criado no dia 19 de dezembro de 2008, localizado no município de Marabá, mesorregião do Sudeste Paraense (Figura 7). De acordo com a classificação de Köppen, o clima é do tipo Af_i (chuvas relativamente abundantes durante todo o ano com quantidades acima de 60 mm) no limite de transição para Aw_i (regime pluviométrico anual relativamente elevado, mas com nítida estação seca) e temperatura média de 28°C (ALMEIDA, 2007), com relevo predominantemente plano.

O Assentamento 26 de Março foi criado na área da antiga Fazenda Cabaceiras, pertencente ao polígono dos castanhais. Possui predomínio de pastagens, com poucos

fragmentos de floresta e capoeira, relativas à área de pousio (prática de interrupção temporária de atividades ou usos agrícolas, para possibilitar a recuperação da capacidade da estrutura do solo, com o objetivo de melhorar sua fertilidade). Contando com uma área de 11.919,36 ha, o projeto de assentamento pode ser acessado a partir da BR-155, que corta a área na direção norte-sul, com o rio Sororó sendo em grande parte sua rede de drenagem subordinada, constituindo seu limite a oeste do mesmo (CASTRO & WATTRIN, 2013).

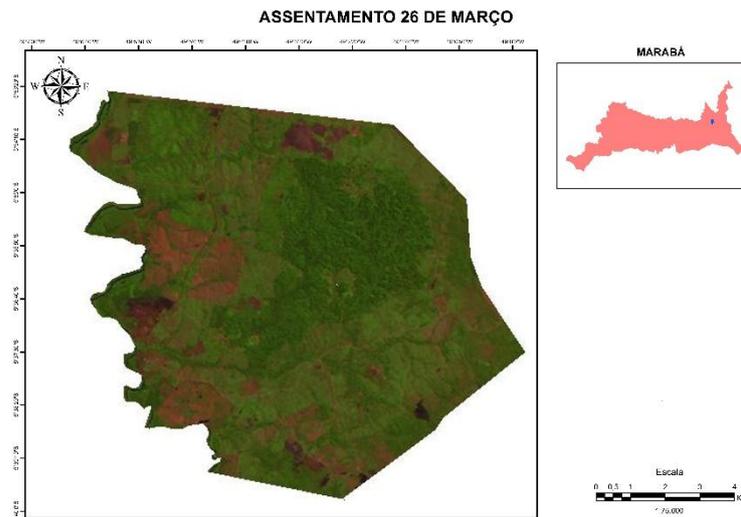


Figura 7. Área de estudo, PA 26 de Março. Fonte: Autor

A disposição espacial dos lotes no Assentamento 26 de Março segue o modelo conhecido como “raio-de-sol” (Figura 8) que se caracteriza por apresentar áreas comuns nas quais são construídas as casas dos assentados com lotes próximos às mesmas (BERTOLINI; CARNEIRO, 2007). A área em estudo apresenta seis núcleos de moradia e duas sedes, além de 207 lotes familiares.

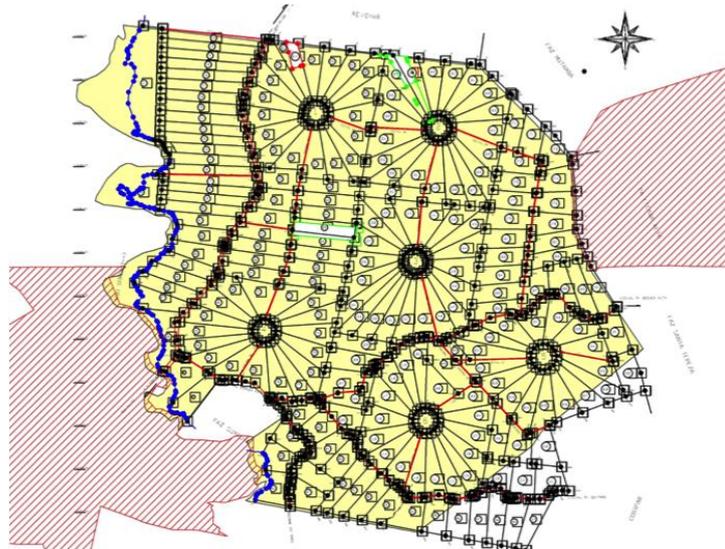


Figura 8. Disposição dos lotes no PA 26 de Março.

6.3. Aplicação da Metodologia ClasSIS

Com o intuito de demonstrar e validar a aplicabilidade e a eficiência da metodologia proposta, foi realizada uma análise do uso e cobertura da terra, a partir de imagens classificadas de acordo com os passos da ClasSIS.

6.3.1. Módulo de Tratamento de Imagens

6.3.1.1. Aquisição de dados

O produto orbital utilizado para a classificação temática foram as imagens digitais do sensor TM (*Thematic Mapper*), do satélite Landsat 5, referente à órbita 223, ponto 64. As imagens obtidas, a partir do banco de imagens do INPE¹ já estavam corrigidas geométrica e radiométricamente.

¹

Obtida em <http://www.dgi.inpe.br/CDSR/>

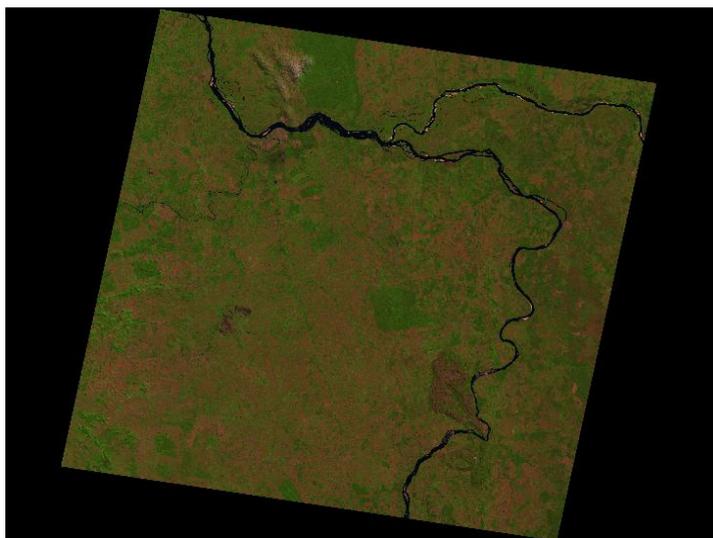


Figura 9. Composição colorida R5G4B3 da órbita/ponto 223/64 do satélite Landsat 5,

As imagens coletadas foram selecionadas de acordo com a porcentagem de cobertura de nuvens na área do assentamento, não permitindo que o limiar de 5% de nuvens em cada quadrante fosse ultrapassado, sob pena de não ser possível a plena visualização do PA, por tratar-se de uma área relativamente pequena e de uma região com grande quantidade de nuvens. Devido a essa restrição e visando a reduzir os efeitos causados pela sazonalidade das mudanças do uso e cobertura da terra, o número de imagens disponíveis para a construção da série histórica ficou reduzido.

Desta forma, foram escolhidas 12 imagens de 1986 até 2010, com um intervalo entre 2 e 3 anos, nos meses de junho à agosto, conforme Tabela 1.

Tabela 2. Banco de imagens utilizado no estudo de caso do Assentamento 26 de Março.

Dia	Mês	Ano
02	Agosto	1986
07	Agosto	1988
28	Julho	1990
10	Agosto	1992
23	Julho	1994
28	Julho	1996
06	Agosto	1999
26	Julho	2001
16	Julho	2003
24	Julho	2006
28	Junho	2008
03	Julho	2010

Após o processo de formação da série histórica, é necessário ainda que as mesmas passem por uma fase de tratamento e correções, por meio de técnicas de processamento digital de imagens.

6.3.1.2. Processamento digital de imagens

Após o processo de aquisição das imagens, foi criado um banco de dados, adotando uma escala de 1:25.000, com coordenadas geográficas SIRGAS 2000, utilizando o *software* ArcGIS em sua versão 10.0. As imagens originais obtidas por esta fase já vêm calibradas radiométricamente e com correções geométricas no nível G1, mas ainda apresentam alguns ruídos ocasionados por fatores de variação de altitude, velocidade e condições atmosféricas nos sistemas de sensores do satélite (CRA/INPE, 2010). Com isso, ainda se faz necessário que elas passem pela etapa de pré-processamento, para que as mesmas não sofram com perda de qualidade e de confiabilidade de suas informações.

Visando a melhorar a qualidade da imagem, a etapa de realce de contraste foi aplicada para permitir uma melhor diferenciação entre os elementos presentes na imagem. De forma empírica, foi definida a opção Minimum-Maximum para a manipulação do histograma das imagens, funcionalidade disponível no *software* ArcGIS.

Para uniformizar a resolução espacial dos *pixels* em 30 metros, foi aplicado o método de reamostragem conhecido como o “Vizinho mais próximo” (*K-Nearest Neighbor*, KNN) (FISCHER; GETIS, 2010), fixando o erro igual a 0.5 *pixels*, sem alterar os valores radiométricos da imagem original, podendo, contudo, gerar descontinuidade na imagem reamostrada.

Os valores radiométricos se referem à capacidade do sistema sensor em detectar as variações da radiância espectral recebida. A radiância de cada *pixel* passa por uma codificação digital, obtendo um valor numérico, expresso em bits, denominado de Número Digital (DN – *Digital Number*). Este valor é facilmente traduzido para uma intensidade visual ou ainda em nível de cinza, localizado num intervalo finito (0, K-1), onde K é o número de valores possíveis, denominados de níveis de quantização (SCHOWENGERDT, 1983).

A seleção das bandas e das cores, para a composição colorida, está diretamente ligada à resposta espectral dos alvos e à percepção visual. Esses atributos irão definir a sequência de bandas que serão atribuídas aos canais RGB. Para este trabalho, foram utilizadas as bandas 3

(0,63 – 0,69 μm), 4 (0,76 – 0,90 μm) e 5 (1,55 – 1,75 μm), do sensor TM, para o processo de composição, por realçar os alvos de interesse, além da boa separabilidade de classes como: hidrografia, queimadas e áreas de vegetação secundária (CREPANI; DUARTE; SHIMABUKURO, 2001). Com a finalidade de minimizar os efeitos causados pelo uso de combinações de diferentes bandas, utilizou-se o mesmo número de bandas para todas as imagens adquiridas.

Após a finalização da etapa de pré-processamento, é extraída apenas a área correspondente ao Assentamento 26 de Março. A imagem resultante deste procedimento é depositada em um repositório, que posteriormente será utilizado pelo segundo módulo da metodologia. Este módulo foi implementado por um programa desenvolvido em Python (LUTZ, 2013).

6.3.2. Módulo de Análise e Extração de Padrões

6.3.2.1. Transformação dos dados

O processo de transformação dos dados é um dos mais importantes na ClasSIS, pois consiste em um conjunto de passos que tornam os dados inteligíveis para o ambiente computacional, além de proporcionar o armazenamento eficiente dos mesmos, influenciando, diretamente, no bom andamento das fases posteriores. Entretanto, no âmbito desta dissertação, esta fase tem como principal objetivo converter os dados que estão dispostos em formato de imagem, para um arquivo no formato adequado à leitura pelo programa desenvolvido em linguagem Python. Para essa tarefa, foi desenvolvido um código programa computacional que é responsável pela realização do processo de normalização e parametrização dos dados.

Para o processo de normalização, foi criado um arquivo no formato CSV (*Comma-Separated Values*) contendo informações de posicionamento do *pixel* no plano cartesiano e as intensidades espectrais das bandas 3, 4 e 5, com valores que variam de 0 a 255.

Com os dados no formato adequado, o processo de parametrização pode ser iniciado e nele são definidas as variáveis de entrada e as classes temáticas de saída. As variáveis de entrada selecionadas foram as bandas (3, 4 e 5) do tipo inteiro e o atributo “área preservada”, do tipo booleano.

Como as técnicas de classificação supervisionadas necessitam que as classes de saída sejam conhecidas para que possam adquirir conhecimento por meio do processo de treinamento, foram selecionadas as classes temáticas de acordo com o projeto TerraClass (EMBRAPA & INPE, 2011) e com a quantidade disponível de amostras por classe presentes na região estudada. Diante desse cenário, foi definida a utilização das classes: floresta, vegetação secundária, pasto, regeneração com pasto e área não observada (nuvens e regiões de queimadas).

6.3.2.2. Classificação Supervisionada de Imagens

Para o acompanhamento e mapeamento do uso e cobertura da terra, diversas técnicas de mineração de dados vêm sendo aplicadas em escalas local, regional e global, devido ao elevado grau de detalhes obtidos com estas ferramentas de classificação (SESNIÉ et al., 2012; POULIOT et al., 2009; DAVRACHE et al., 2012).

A classificação supervisionada consiste basicamente duas fases: a primeira, responsável por gerar a base de treinamento e a segunda, a fase de classificação propriamente dita (MOREIRA, 2005).

Antes da realização da classificação, foi selecionada a base de treinamento supervisionado, utilizando-se o ArcGIS. A escolha foi baseada no resultado do mapeamento do uso e cobertura da terra realizado pelo projeto TerraClass, referente aos anos de 2008 e 2010.

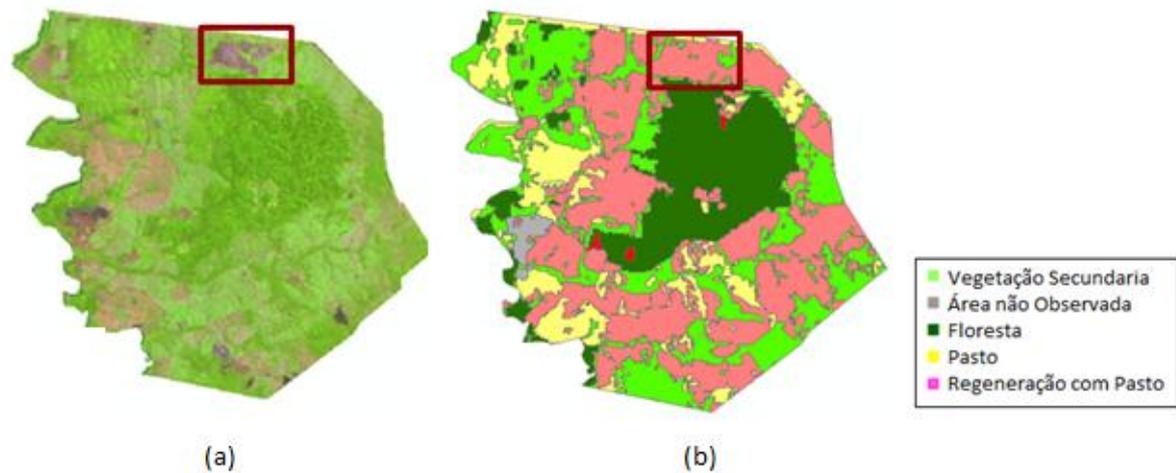


Figura 10. Inconsistências na classificação do projeto TerraClass encontradas na região do assentamento 26 de Março. (a)Imagem original e (b) TerraClass 2010. Fonte: Autor.

Como o projeto TerraClass mapeia toda a Amazônia Legal, é esperado que a classificação apresente algumas inconformidades quando a área de interesse é muito pequena, como é o caso do Assentamento 26 de Março. A Figura 11 mostra um exemplo de uma inconsistência na classificação do TerraClass. A região marcada na imagem original (A) representa uma área de queimada, que, no TerraClass, foi classificada como regeneração com pasto (B). Isso pode ser explicado pelo fato de que o *pixel* da imagem do Landsat 5 TM é de 30m, logo o valor de reflectância atribuído a ele corresponde àquele de maior intensidade. Para minimizar essas inconsistências, foram retiradas amostras, em forma de polígonos, daquelas regiões, cuja correspondência entre a imagem original e a classificada pelo projeto TerraClass fossem verdadeiras. Esse processo foi realizado apenas nas imagens que seriam utilizadas para geração da base de treinamento e teste.

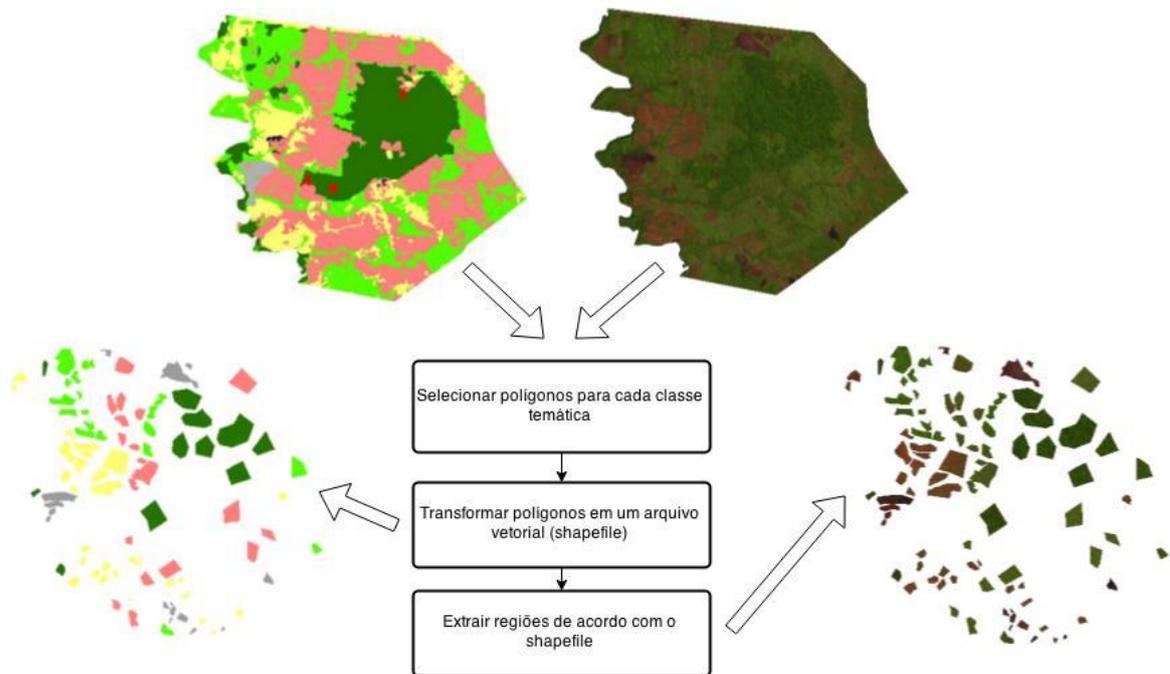


Figura 11. Processo de geração da base de treinamento.

ClasSIS não determina a técnica de classificação que deverá ser utilizada, pois, de acordo com as características do que se quer estudar, uma técnica pode apresentar um desempenho melhor que a outra.

Para definir a técnica que melhor se adequava a este estudo de caso, buscou-se modelos de classificação supervisionados que associassem, pelo menos, duas das seguintes características: precisão, rapidez e simplicidade. Para essa tarefa foram escolhidas quatro técnicas: árvore de decisão, máxima verossimilhança, máquina de vetores de suporte e redes neurais artificiais. Tais escolhas se devem à maior prevalência dessas técnicas constatadas a partir do levantamento bibliográfico realizado. Ressalta-se que não há a intenção de esgotar tal assunto nesta dissertação, mas sim tão somente apresentar uma breve descrição das técnicas utilizadas no âmbito deste trabalho. Para maiores detalhes acerca do assunto, sugere-se consultar em (FACELI et al., 2011).

As Árvores de Decisão (DT) são representações simples do conhecimento e um meio eficiente de construir classificadores que predizem classes baseadas nos valores de atributos de um conjunto de dados. Em uma árvore de decisão, o conhecimento é testado e representado em cada nó, que pode conduzir a busca a um de seus filhos, descendo da raiz em direção às folhas da árvore. Os algoritmos de DT apresentam vantagens para a classificação da cobertura da terra. Entre as quais, podem ser citadas: a facilidade de

interpretação dos resultados, o baixo tempo de processamento, a capacidade do modelo trabalhar com dados medidos em distintas escalas, o fato de não demandar distribuição normal dos dados e a capacidade em processar as relações não lineares entre os preditores e as classes de cobertura da terra (FRIEDL & BRODLEY, 1997).

Os algoritmos de DT selecionados para a avaliação foram: o CART (*Classification and Regression Trees*) e o *Random Forest* (RF). O algoritmo proposto por (BREIMAN et al, 1984), possui uma das principais vantagens almejadas, que é a grande capacidade de pesquisar relações entre os dados e a geração de resultados em árvores de decisão simples e com legibilidade.

O algoritmo *Random Forest* é uma combinação de predições de diversas árvores, em que cada árvore depende dos valores de um vetor independente, amostrados aleatoriamente e com a mesma distribuição para todas as árvores da floresta. Uma série de árvores de decisão é chamada de floresta (BREIMAN, 2001).

A técnica estatística de máxima verossimilhança (MAXVER) foi utilizada neste estudo apenas com o objetivo de comparar a acurácia entre este método, presente na ferramenta ArcGIS, e os demais algoritmos avaliados. O MAXVER é o método de classificação *pixel a pixel* mais comum, que considera a ponderação das distâncias entre médias dos níveis digitais das classes, a partir de parâmetros estatísticos. Assim sendo, é necessário um número razoavelmente elevado de *pixels*, para cada conjunto de treinamento, para que o método possua maior eficiência (ERBERT, 2001).

A técnica *Support Vector Machine* (SVM) é uma técnica de aprendizado de máquina, que busca minimizar o erro com relação ao conjunto de treinamento, assim como o erro com relação ao conjunto de teste. Tem como objetivo obter um equilíbrio entre esses erros, minimizando o excesso de ajustes com respeito às amostras de treinamento (*overfitting*) e aumentando, conseqüentemente, a capacidade de generalização (VAPNIK, 1999).

A técnica de redes neurais artificiais (ANN) tem sido aplicada com sucesso nas áreas de processamento de imagens e reconhecimento de padrões. A ANN usa elementos de computação não-linear (chamados neurônios) organizados como redes, de maneira análoga ao funcionamento do cérebro humano (GONZALES et al., 2000).

Com o objetivo de obter resultados confiáveis para comparação de diferentes técnicas, foi utilizado o método de classificação *pixel a pixel*. Outro forte motivo para a escolha deste método foi pela razão do pequeno tamanho da região de estudo, o que aumenta a

sensibilidade ao erro de classificação, pois cada *pixel* classificado erroneamente corresponde a uma área considerável. Com isso, a precisão assume um papel de grande importância para este estudo.

Com exceção da técnica de máxima verossimilhança, que foi aplicada através da ferramenta ArcGIS, todos os algoritmos de classificação foram desenvolvidos na linguagem Python, utilizando a biblioteca *scikit-learn* em sua versão 0.15 (SCIKIT-LEARN, 2014).

6.3.2.3. Escolha da Técnica de Classificação

O processo de avaliação da qualidade dos resultados de uma classificação é de grande importância, uma vez que respalda a confiabilidade do classificador em sua capacidade de extrair os padrões pretendidos, a partir dos dados de entrada. Neste estudo, foram utilizados dois fatores para expressar a precisão das técnicas de classificação: a matriz de confusão e o coeficiente Kappa. A matriz de confusão facilita o entendimento do comportamento do classificador, de como ele reage aos efeitos de previsões erradas, sendo que as linhas representam os valores previstos para o modelo e as colunas equivalem aos valores reais.

Além da exatidão do mapeamento por meio da matriz de confusão, foram calculadas também as porcentagens de acerto por classe e com os coeficientes Kappa de cada classificador. O coeficiente Kappa é utilizado para quantificação de quanto o modelo está bom, sendo uma técnica multivariada discreta que qualifica o nível de precisão assumindo valores na faixa de 0 à 1 (sendo que quanto mais próximo de 1, melhor é o resultado do classificador).

Tabela 3. Avaliação do índice Kappa.

Valor do Kappa	Concordância
0	Pobre
0 – 0.20	Ligeira
0.21 – 0.40	Considerável
0.41 – 0.60	Moderada
0.61 – 0.80	Substancial
0.81 – 1	Excelente

As amostras de teste utilizadas para classificação do uso e cobertura da terra obtiveram um melhor resultado a partir do uso da técnica *Random Forest* com uma taxa de acerto igual a 98 % e com um índice kappa de 0.975. Os modelos gerados pelas técnicas CART e SVM também obtiveram um bom nível de classificação, sendo menos eficiente apenas por 0.3 % do RF.

Tabela 4. Comparativo da acurácia e do índice Kappa das técnicas estudadas.

Técnicas	Acurácia	Índice Kappa
AD – Random Forest	98%	0.975
AT – CART	97.7%	0.964
SVM	97.7%	0.968
RNA	95%	0.968
MAXVER	82.75%	0.78

A técnica ANN, utilizando quatro neurônios na camada de entrada, sete neurônios na camada escondida e cinco para camada de saída, obteve uma taxa de acurácia de 95 % e índice kappa de 0.968.

A técnica de máxima verossimilhança obteve a pior acurácia dentre as técnicas testadas, pelo motivo da mesma necessitar de um grande volume de dados para treinamento, o que não é o caso da área de estudo em questão. Esta técnica, foi a única que foi usada por meio de uma ferramenta comercial, o ArcGIS, com a finalidade de ser utilizada apenas com o objetivo de comparar a eficácia da ferramenta computacional desenvolvida por este trabalho. Por este motivo, a técnica MAXVER não estará presente no capítulo de Resultados.

Tabela 5. Matriz de precisão (%) da classificação do uso e cobertura da terra.

Classes (%)	Técnicas de Classificação				
	RF	CART	SVM	ANN	MAXVER
Floresta	99,68	98,75	99,67	99,83	83.53
Vegetação Secundária	98,05	97,76	98,85	85,32	76.67
Pasto	97,82	97,80	96,03	96,80	66.92
Regeneração com Pasto	98,68	98,33	98,68	97,25	91.30
Área não Observada	95,20	94,66	94,40	86,97	92.06

Os resultados apontados na tabela 5, demonstram que a técnica *Random Forest* teve maior precisão na classificação na maioria das classes temáticas, com exceção apenas da classe **Floresta**, que foi inferior 0,15 % em relação a classificação realizada pela técnica ANN. Comparando os resultados obtidos pela MAXVER com as outras técnicas avaliadas, podemos identificar que no caso da classe **Área não Observada**, ocorreram comportamentos opostos, pois obteve um melhor rendimento na identificação desta classe, diferenciando das demais técnicas que perderam precisão na mesma.

A partir da análise das matrizes de confusão fica evidente o comportamento do classificador em relação a cada classe de saída, permitindo extrair informações importantes para o melhoramento da configuração e aplicação da técnica.

Tabela 6. Matriz de confusão da RF.

Classes (%)	Floresta	Vegetação Secundária	Pasto	Regeneração com Pasto	Área não Observada
Floresta	99,68	0	0,88	0	0
Vegetação Secundária	0	98,05	0	0	3,54
Pasto	0,32	0	97,82	0,48	0,18
Regeneração com Pasto	0	0	1,16	98,68	1,08
Área não Observada	0	1,95	0,14	0,84	95,20

Na matriz de confusão do algoritmo *Random Forest* é possível perceber que o modelo apresenta um maior erro na determinação da classe **Área não observada**, classificando-a, cerca de 2,79 % das vezes, com **Vegetação Secundária** ou **Regeneração com Pasto**.

Tabela 7. Matriz de confusão da RNA.

Classes (%)	Floresta	Vegetação Secundária	Pasto	Regeneração com Pasto	Área não Observada
Floresta	99,83	11,08	0	0	0
Vegetação Secundária	0,08	85,32	0,22	2,02	0
Pasto	0	0	96,80	0,73	11,44
Regeneração com Pasto	0,08	3,60	2,20	97,25	1,59
Área não Observada	0	0	0,78	0	86,97

De acordo com a tabela 7, a técnica de redes neurais obteve um erro maior na classificação de *pixels* correspondentes às áreas de **vegetação secundária**, com 14,68 %, com maior dificuldade para a distinção da classe de **Floresta** com 11,08 % de *pixels* categorizados erroneamente.

Tabela 8. Matriz de confusão da técnica SVM.

Classes (%)	Floresta	Vegetação Secundária	Pasto	Regeneração com Pasto	Área não Observada
Floresta	99,67	0	1,42	0	0
Vegetação Secundária	0	98,85	0,88	0	4,62
Pasto	0,33	0,05	96,03	0,48	0,18
Regeneração com Pasto	0	0	1,07	98,68	0,80
Área não Observada	0	1,10	0,60	0,84	94,40

Já a técnica de SVM obteve um comportamento bastante semelhante ao do algoritmo RF, com a melhor taxa de acerto na classe **Floresta** (99,67%) e o pior, na classe **Área não observada** (94,40%). O mesmo comportamento foi encontrado com a utilização do algoritmo CART, com um erro de 5,34 % na distinção entre a classe **Área não Observada** e as classes de **Vegetação Secundária** e **Regeneração com Pasto**.

Tabela 9. Matriz de confusão do algoritmo CART.

Classes (%)	Floresta	Vegetação Secundária	Pasto	Regeneração com Pasto	Área não Observada
Floresta	98,75	0	0,89	0	0
Vegetação Secundária	0	97,76	0	0	3,89
Pasto	1,10	0	97,80	0,89	0,37
Regeneração com Pasto	0,15	0	1,24	98,33	1,08
Área não Observada	0	2,24	0,07	0,78	94,66

Com a análise das matrizes de confusão, foi possível notar que o melhor rendimento do algoritmo *Random Forest* se deu pelo fato do mesmo conseguir distinguir melhor as diferenças espectrais entre as classes “Área não Observada” e “Vegetação Secundária”.

Pelos resultados de acurácia e coeficiente Kappa, a técnica escolhida para classificação foi a *Random Forest*. As imagens classificadas e o gráfico com a série histórica do uso e cobertura da terra serão apresentados na fase de pós-processamento.

6.3.3. Pós-processamento dos dados

Com a validação das técnicas de classificação foi constatado que os modelos gerados estão aptos para o último passo da fase de classificação de imagens, que consiste no processo de qualificação do uso e cobertura da terra das imagens que formam a série histórica estudada por este trabalho. Os resultados obtidos deverão passar pela fase de pós-processamento dos dados, pois os mesmos ainda estarão na forma matricial.

A fase de pós-processamento é responsável pelo tratamento do conhecimento obtido pelo processo de classificação e tem como objetivo facilitar a interpretação dos dados pelo usuário, seja por meio da elaboração de gráficos, diagramas, tabelas, entre outros.

Em ClasSIS, esta fase é responsável pela conversão dos dados matriciais em informações que são apresentadas em formato de tabela e gráfico. Essas informações são compostas pelo resultado do cálculo das porcentagens de áreas referentes a todas as classes temáticas de interesse do estudo.

A Figura 6 apresenta as imagens classificadas do PA 26 de Março. O gráfico com a dinâmica do uso e cobertura da terra é mostrado na Figura 7.

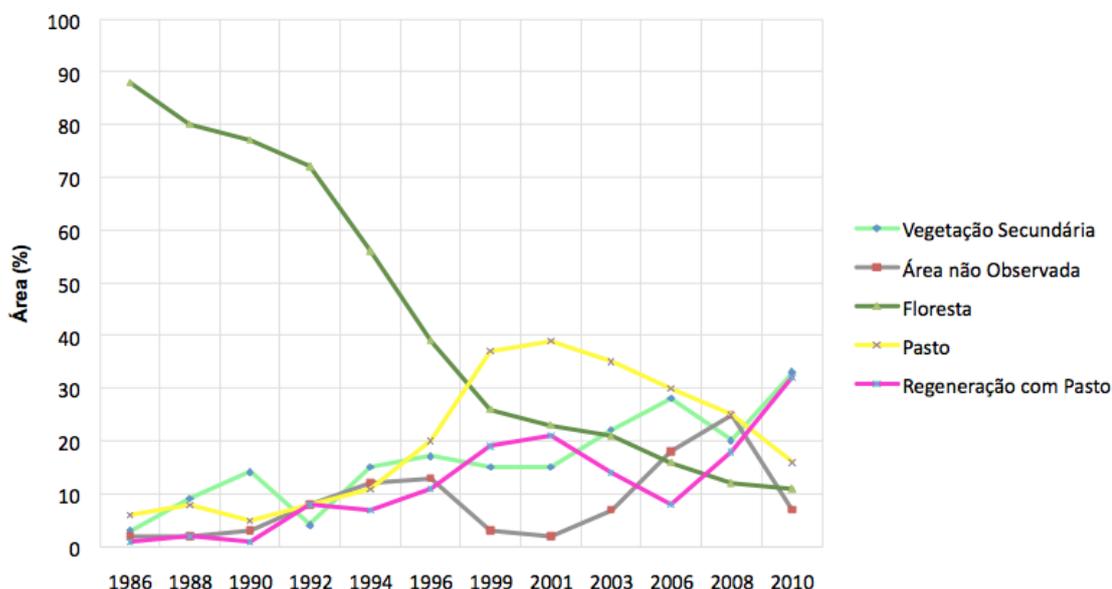


Figura 12. Gráfico da dinâmica do uso e cobertura da terra do PA 26 de Março.

O comportamento apresentado pela figura 12 será explicado com detalhe no próximo capítulo.

6.4. Considerações finais

No decorrer deste capítulo, demonstrou-se a aplicabilidade metodologia ClasSIS, definindo passo a passo todos os procedimentos e métodos aplicados no caso de estudo. Também foi enfatizada a importância da escolha correta das técnicas necessárias para a realização do estudo, juntamente com a definição dos parâmetros de entrada e saída e a formação da base de treinamento para o classificador.

Foram apresentados quatro diferentes técnicas de classificação de imagens, os algoritmos de árvore de decisão *Random Forest* e *CART*, redes neurais artificiais, *Support Vector Machine* e o método de máxima verossimilhança. Baseando-se nos resultados gerados por este estudo, para as respectivas especificidades, pode-se apontar que a técnica de árvore de decisão, seja com o algoritmo *Random Forest* ou com o *CART*, obteve melhor desempenho para a tarefa de classificação multi-temporal da região estudada, oferecendo

confiabilidade para os estudos sobre a dinâmica de uso e ocupação do solo para áreas de assentamento, em especial, ao Assentamento 26 de Março.

CAPÍTULO 7 – RESULTADOS

7.1. Considerações Iniciais

Neste capítulo, apresenta-se uma análise dos resultados obtidos a partir da classificação das imagens, realizada no capítulo anterior, enfatizando a dinâmica do uso e cobertura da terra no PA 26 de Março.

7.2. Análise dos resultados

Com a análise dos resultados obtidos pela avaliação das técnicas de classificação, é possível destacar o bom desempenho dos algoritmos de árvore de decisão.

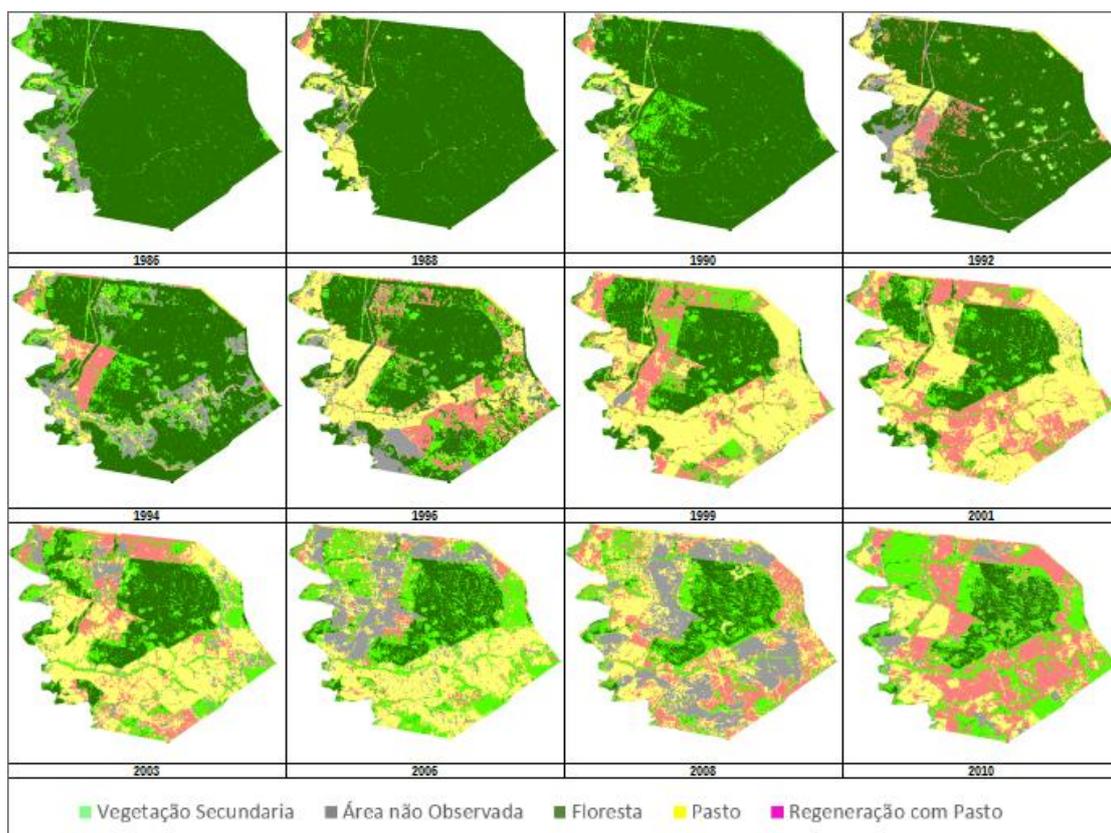


Figura 13. Classificação das imagens da série temporal do assentamento 26 de Março. Fonte: Autor.

Os estudos apontam que mesmo as técnicas de redes neurais e SVM tendo alcançado uma excelente taxa de precisão na classificação da classe Floresta, com 99,83% e 99,67% respectivamente, as mesmas não conseguem refletir o comportamento exigido ao estudo de caso; no qual se assume que áreas que passaram por processo de degradação ambiental, deixando de ser classificadas como **Floresta**, voltem a pertencer a esta classe.

Além das diferenças em relação à classe temática **Floresta**, ambas as técnicas também destoam dos algoritmos de árvore de decisão, no que tange à discriminação das classes **Pasto** e **Regeneração com Pasto** no ano de 1992. Isto pode ser explicado pelo fato da imagem obtida no ano de 1992 (figura 13) estar com um alto índice de incidência de cobertura de nuvens, muito próximo ao limite máximo de 5% adotado como limite neste estudo, aumentando, assim, a porcentagem de área classificada como **Área não Observada**. O comportamento esperado em tal situação é que o modelo trate esses casos como ruídos, que posteriormente virão a propagar-se ao longo da série histórica. Para este estudo, o acompanhamento da dinâmica de desmatamento na região é de grande importância para traçar o comportamento do uso e cobertura da terra.

Para a validação dos resultados obtidos pelos modelos de classificação, foi realizada uma pesquisa sobre o contexto histórico da área de estudo, objetivando-se comprovar que os valores de porcentagem de área de cada classe estão coerentes os acontecimentos históricos. Como ambos os algoritmos da técnica de árvore de decisão apresentaram tendências bastante semelhantes, ao longo da série histórica, a escolha do modelo de classificação se deu pela comparação das métricas de acurácia, sendo que, com base em tal critério, o algoritmo *Random Forest* foi selecionado para essa tarefa, pois alcançou uma taxa de acerto de 98% e um índice Kappa de 0.975.

Com isso, a classificação da série histórica do Assentamento 26 de Março foi realizada pelo uso do modelo de classificação supervisionada *Random Forest*. Na figura 14, é apresentado o resultado da dinâmica de uso e cobertura da terra com a aplicação da técnica, utilizando a variável “área preservada”. Neste gráfico, é possível identificar que no período de apenas 10 anos entre os anos (de 1990 a 1999), houve uma queda brusca, quase que constante, na cobertura florestal nativa. Também é possível verificar que essa queda foi consequência do aumento das áreas das classes **Pasto** e **Vegetação Secundária**.

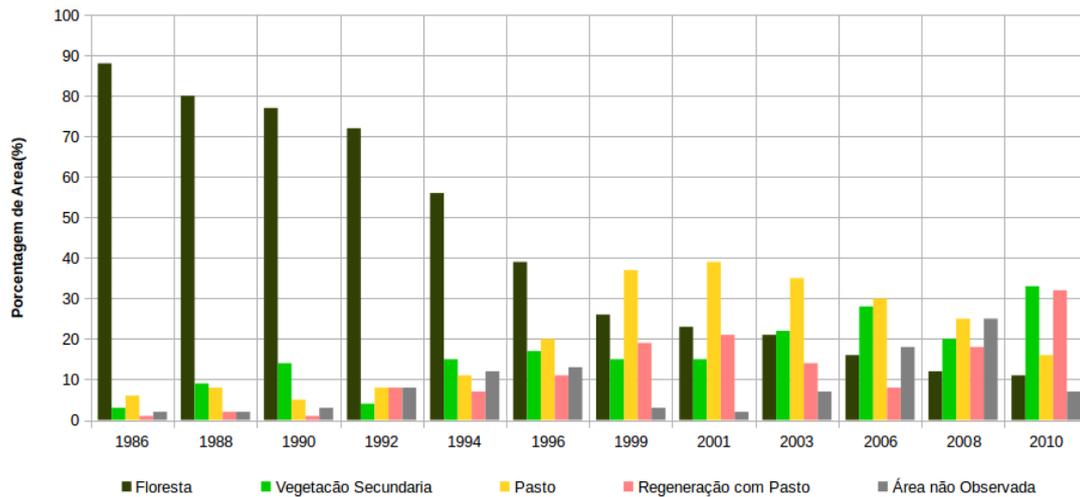


Figura 14. Dinâmica de uso e cobertura da terra no assentamento 26 de Março. Utilizando a técnica Random Forest com a variável “área preservada”.

Já na figura 15, o gráfico resultante das classificações de LULC se comporta de maneira análoga aos resultados obtidos pelas técnicas de ANN e SVM, por razão do mesmo não usar a variável “área preservada” na construção de seus modelos. Tal fato evidencia a importância e o impacto que este atributo gera nos estudos de análise multi-temporal do uso e cobertura da terra.

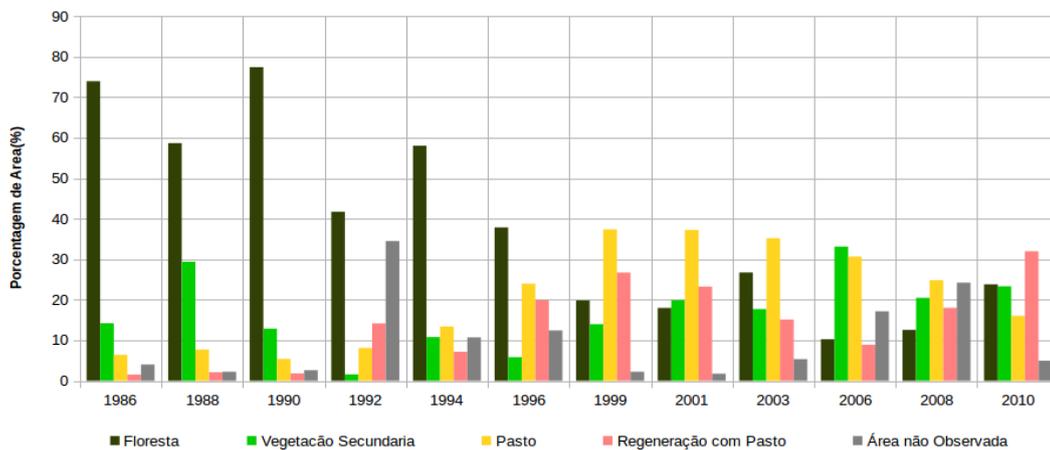


Figura 15. Dinâmica de uso e ocupação da terra no assentamento 26 de Março. Utilizando a técnica Random Forest não utilizando a variável “área preservada”.

Analisando as Figuras 13 e 14, percebe-se que a cobertura vegetal do assentamento 26 de Março sofreu uma degradação bastante elevada, dando lugar a grandes áreas de pastagem. Deve-se frisar que a Fazenda Cabaceiras, até meados da década de 1990, era

predominantemente um castanhal. Somente após o declínio econômico da extração da castanha, os proprietários iniciaram a derrubada da mata nativa para dar lugar à pecuária (BARROS, 2011). A porcentagem de área de floresta sofreu uma queda abrupta entre os anos 1992 e 1999, caindo de 72% para 26% a cobertura vegetal nativa. Isso é indicativo que quando o PA 26 de Março foi efetivamente criado, a área já estava bastante antropizada. Mas se percebe ainda que as ações de desflorestamento continuaram a acontecer, entretanto em um ritmo mais lento.

Com base em levantamentos de campo preliminares, nota-se que a causa principal para manter essa prática é a técnica utilizada para plantar culturas de milho, arroz e mandioca, nas quais a derrubada da mata precede o cultivo de tais espécies, além da formação de pastos para a criação de gado. Observa-se também o crescimento de áreas de regeneração com pasto e vegetação secundária, devido à falta de recursos financeiros dos donos dos lotes para realizar a limpeza das áreas de pasto e de lavoura, além da prática de queimadas nos períodos de seca, prejudicando substancialmente o solo. Via de regra, após esse processo, tais áreas são abandonadas, originando pasto sujo, evoluindo para regeneração com pasto e assim por diante.

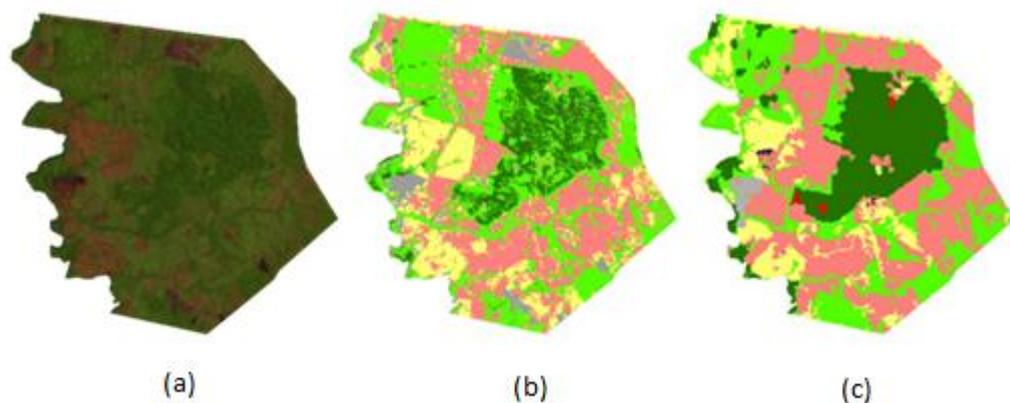


Figura 16. Comparação entre (A) imagem original, (B) resultado da técnica RF e (C) Projeto TerraClass no ano de 2010.

Analisando-se o gráfico apresentado pela figura 16, pode-se destacar que com a melhor técnica apontada pelo estudo, *Random Forest*, a proporção da área de **Floresta** teve uma diminuição de 9% em relação à classificação realizada pelo projeto TerraClass do ano de 2010, o que caracteriza aproximadamente 1072.74 ha, os quais não possuem mais sua vegetação original. Também pode ser notado que o modelo de classificação utilizado nesta

dissertação identificou com mais precisão as regiões da classe **Área não Observada**, com um aumento de 6.19% em relação ao TerraClass. Comportamentos também observados na imagem da Figura 17.

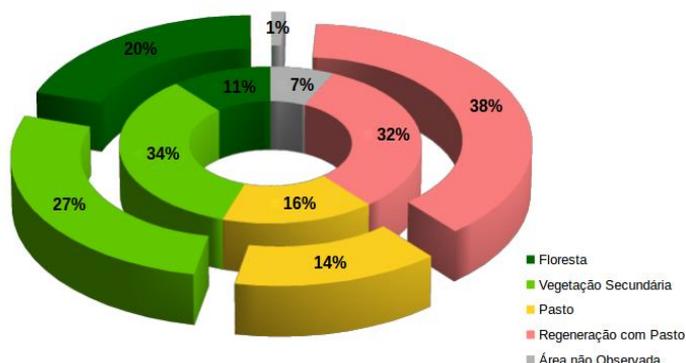


Figura 17. Comparação entre o mapeamento temático do TerraClass (externo) e da técnica Random Forest (interno) no ano de 2010.

7.3. Considerações Finais

Pode-se perceber, pelos resultados obtidos, que o estabelecimento de uma sistematização para classificação de imagens de satélite, bem como a escolha da técnica de classificação mais adequada ao estudo pretendido, influencia diretamente na qualidade do produto final, assim como na precisão das análises a serem realizadas. Percebe-se também que o uso da variável "área preservada" permite uma correspondência mais clara com a realidade da área de interesse.

Os refinamentos propostos pela metodologia proposta proporcionam uma maior eficácia tanto na qualidade do tratamento das imagens, quanto (e principalmente!) na precisão das análises realizadas a partir das imagens em questão.

CAPÍTULO 8 - CONCLUSÃO

Pesquisas sobre uso e cobertura da terra apontam que as práticas e processos de uso da terra praticados na região amazônica, destacando a degradação das florestas, podem afetar o clima regional, ecossistemas e, em última análise, o clima global (OLIVEIRA & MORAES, 2013).

O processo de classificação de imagens de satélite auxilia na obtenção de dados para a análise do uso e cobertura da terra, por conta disso, quanto mais precisa for a classificação, tanto melhor a análise.

Este trabalho apresentou uma metodologia inovadora, chamada de ClasSIS - Metodologia de Classificação Supervisionada de Imagens de Satélite, para a avaliação multitemporal da dinâmica do uso e cobertura da terra, voltada para o estudo do comportamento dos projetos de assentamentos na região amazônica. Para isso, fez-se uso de recursos de inteligência computacional associado à tecnologias de sensoriamento remoto.

A metodologia ClasSIS é composta por dois módulos, o primeiro voltado para a tarefa de tratamento de imagens e o segundo para análise e extração de padrões, por intermédio de técnicas de classificação de imagens de satélite. Baseando-se nos resultados alcançados, foi possível analisar de forma multitemporal, a dinâmica do uso e cobertura da terra do Assentamento 26 de Março, em Marabá/PA, desde o ano de 1986 até 2010. Mostrando de forma inequívoca a influência decisiva do homem na degradação do meio ambiente, seja por questões econômicas ou propriamente de subsistência, comprovando por meio de análise da série histórica de imagens, fatos ocorridos no município de Marabá.

Todas as fases presentes em cada módulo da metodologia ClasSIS, possuem seu grau de importância para a qualidade dos resultados a serem obtidos. Destacando-se a fase de transformação de dados, que por meio da definição do atributo “área preservada”, possibilita que os modelos de classificação aprendam que uma área degradada, não possa ser classificada como floresta (CÂMARA et al., 2013).

Além disso, foi abordada de maneira detalhada a fase de aquisição e classificação de imagens de satélite, enriquecida com uma discussão acerca do desempenho de técnicas de classificação de imagens de satélite, aplicadas a pequenas áreas, se comparadas à Amazônia Legal, em particular, áreas de projetos de assentamentos na região amazônica.

Por fim, ressalta-se que a metodologia apresentada neste trabalho é parte integrante de um arcabouço de software, denominado MAPS (*Methodology for Assessing Projects of Settlements*), que mapeia o processo desde a obtenção dos dados, a partir de diferentes fontes, em formatos distintos, até a análise dos resultados gerados pelo uso de métodos probabilísticos e de inteligência computacional. Tal *framework* está sendo desenvolvido totalmente sob a égide de padrões abertos e interoperáveis, o que permite a utilização em estudos e contextos diversos dos apresentados neste trabalho.

8.1. Contribuições da Dissertação

Como principais contribuições desta dissertação, destacam-se:

- Proposta de uma metodologia inovadora para análise multitemporal da dinâmica de uso e cobertura da terra, por meio de dados adquiridos a partir de sensoriamento remoto;
- A metodologia proposta comporta-se de forma ágil e flexível para classificação de imagens de satélite, podendo ser aplicada em diversas regiões da Terra;
- Apresentação de um profundo levantamento da literatura referente às principais técnicas utilizadas para classificação de imagens de satélite;
- Caracterização da problemática que envolve os projetos de assentamentos na região da Amazônia Legal;
- Criação do atributo “área preservada”, capaz de validar o comportamento característico do domínio de estudo, no qual uma região degradada nunca volta a ser classificada como floresta nativa;
- Estudo comparativo de diferentes técnicas de inteligência computacional para a tarefa de classificação de imagens.
- Determinação da técnica mais eficiente e precisa para o mapeamento temático de uso e cobertura da terra, em áreas projetos de assentamento, e com perfil de agricultura familiar e pecuária.
- A divulgação do trabalho por meio de publicação de artigos em conferências internacionais, nos quais foram apresentados a proposta e os resultados do estudo de caso desta dissertação. Estes artigos foram aceitos e publicados no primeiro semestre de 2015. São eles:

- **MOMTEIRO, F. P.**; ARANHA, P. S.; PONTES, P. A.; SOUZA, A. M. De.; VIJAYKUMAR, N. L.; MONTEIRO, M. A; FRÂNCES, C. R. L. **A comparative study of supervised classification techniques for dynamics assessment of land use and land cover in the Brazilian Amazon.** Aceito para publicação no ASET 2015: International Conference On Advances in Applied science and Environmental Technology. Thailand (Bangkok), 2015.
- ARANHA, P. S.; **MOMTEIRO, F. P.**; PONTES, P. A.; SOUZA, A. M. De.; VIJAYKUMAR, N. L.; MONTEIRO, M. A; FRÂNCES, C. R. L. **Supervised Classification of Satellite Images to Analyze Multi-Temporal Land Use and Coverage: A Case Study for the town of Marabá, State of Pará, Brazil.** Aceito para publicação no COSIT-2015: Second International Conference on Computer Science and Information Technology. Geneva (Switzerland), 2015.

8.2. Trabalhos Futuros

Como possíveis desdobramentos deste trabalho, podem ser destacados os seguintes aspectos:

- Realizar estudos em diferentes assentamentos, a fim de verificar similaridades entre as regiões;
- Realizar automatização do módulo de Tratamento de Imagens;
- Realizar novos estudos comparativos com diferentes técnicas de classificação supervisionada de imagens.
- Desenvolver um processo de padronização de imagens de diferentes satélites, com diferentes resoluções, para que seja possível aumentar a série histórica a ser estudada.

8.3. Dificuldades Encontradas

Durante o desenvolvimento desta dissertação foram encontradas diversas dificuldades, que serão relatadas com o objetivo de auxiliar novos estudos nesta mesma linha de pesquisa, que venham utilizar este trabalho como ponto de partida.

Entre as principais dificuldades podem-se destacar:

- A dissertação necessitou de um levantamento bibliográfico detalhado sobre conceitos que são comuns para área de geoprocessamento de dados, sensoriamento remoto e processamento de imagens de satélite. Conhecimentos não contemplados pela formação da autora.
- Um estudo aprofundado sobre as principais ferramentas SIG para tratamento das imagens de satélite.
- A região estudada por esta dissertação - Assentamento 26 de Março, está situada em uma área com constante cobertura de nuvens, dificultando e limitando o processo de construção da série histórica a ser estudada.
- A falta de um especialista de domínio para auxiliar na caracterização das classes temáticas, fez com que se fizesse necessário a utilização de mapas temáticos disponíveis em domínio público.

REFERÊNCIAS

- AHLERSTEN, K. An Introduction to Matlab. First Edition. 978-87-403-0283-7. 2012.
- AL-AHMADI, F., HAMES, A. Comparison of Four Classification Methods to Extract Land Use and Land Cover from Raw Satellite Images for Some Remote Arid Areas, Kingdom of Saudi Arabia. *Journal of King Abdulaziz University-Earth Sciences*, 20(1), 167–191. 2009.
- AWAD, M. ;CHEHDI, K.;NASRI, A. “Multi Component Image Segmentation Using Genetic Algorithm and Artificial Neural Network,” *Computer Journal of Geosciences and Remote Sensing Letters*, vol. 4, no. 4, pp. 571-575, 2007.
- BAHR H.P., KARLSRUHE.GIS Introduction.In: Bahr H.P. e Vogtle T. (eds.). *GIS for Environmental Monitoring*.Germany, 1999, p.1-9.
- BARROS, C. J. O sonho se faz a mão e sem permissão – “Escravidão temporária” e reforma agrária no sudeste do Pará. 2011. 217f. Dissertação de mestrado. Departamento de Geografia da FFLCH da Universidade de São Paulo.
- BENEDIKTSON, J. A; SWAIN, P. H.; ERSOY, O K.Neural Network Approaches versus Statical Methods in Classification of Multisource Remote Sensing Data. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 28, No. 4, julho de 1990, p. 540-552.
- BIGUS, J. P. Data mining with neural networks: solving business problems from application development to decision support. McGraw-Hill, 1996.
- BINAGHI, E. ;RAMPINNI, A. Fuzzy Decision Making in the Classification of Multisource Remote Sensing Data *Optical Engineering*, Vol.32, No.6, 1993.
- BRANDALIZE, A. A. Cartografia: Modernizando Conceitos. Curitiba. *Fator GIS*, Curitiba, Ano I, n. 1, p. 26, 1993.
- BREIMAN, L., FRIEDMAN, J. H., OLSHEN, R. A., & STONE, C. J. *Classification and Regression Trees*. Wadsworth. 1984.
- CÂMARA, G. Anatomia de um SIG. Curitiba. *Fator GIS*, Curitiba, Ano I, n. 4, p. 58, 1994.
- CÂMARA, G.; MEDEIROS, J. S. de. Mapas e suas representações computacionais. In ASSAD, E. D.; SANO, E. E. (Orgs.) *Sistemas de Informações Geográficas: Aplicações na Agricultura*. 2 ed. Brasília: EMBRAPA, 1998. p. 13 – 29.
- CARPENTER, G.A.; GOPAL, S.; MACOMBER, S.; MARTENS, S.; WOODCOCK, C.E. A Neural Network Method for Mixture Estimation for Vegetation Mapping, *Remote Sens. Environ.*, (1999). pp. 138-152. 70.

CHAKRABARTI, S.; BINDAL, N. ; THEAGHARAJAN, K. Robust Radar Target Classifier Using Artificial Neural Networks. IEEE Transactions on Neural Networks, Vol. 6, No. 3, maio de 1995, p.760-767.

CHAVES, F. T. Uso do geoprocessamento para o planejamento de corredores de biodiversidade na bacia hidrográfica do Rio Caraíva em um modelo de gestão compartilhada. 2005. 42f. Monografia- Especialização em Geoprocessamento. Universidade Federal de Minas, Belo Horizonte.

CUTLER, R., EDWARDS, T. C., BEARD, K. H. CUTLER, A., HESS, K. T., GIBSON, J., LAWLER, J. J. Random Forests For Classification in ecology. Ecology 88 (11), 2783-2792. 2007.

DEILMAI, B. R., KANNIAH, K. D., RASIB, A W., ARIFFIN, A. Comparison of pixel - based and artificial neural networks classification methods for detecting forest cover changes in Malaysia. IOP Conference Series: Earth and Environmental Science, 2014.

ERBERT, M. Introdução ao Sensoriamento Remoto. Master Tesis, Universidade Federal do Rio Grande do Sul. 2001.

ERDAS IMAGINE Tour Guides: ERDAS IMAGINE V8.5. Editora ERDAS, 2001.

FACELI, K. ; LORENA, A.; GAMA, J. ; CARVALHO, A. P. L. Inteligência Artificial – Uma Abordagem de Aprendizado de Máquina, LTC, 1a Edição, 2011.

FEARSLIDE, P. M, "Greenhouse gas emissions from land use change in Brazil's Amazon region", In: Lal, R.; Kimble, J.M.; Stewart, B.A. Ed. Global climate change and tropical ecosystems. Boca Raton: CRC Press, 2000. p. 231-249. Advances in Soil Science.

FLORENZANO, Tereza Gallotti. Imagens de satélites para estudos ambientais. São Paulo: Oficina de Textos, 2002.

FOODY, G. M, Status of land cover classification accuracy assessment. Remote Sensing of Environment. 2002 , 80(1). pp. 185-201.

FOODY, G. M.; CAMPBELL, N.A ; TRODD, N.M.; WOOD, T.F.. Derivation and applications of probabilistic measures of class membership from maximum likelihood classification, Photogramm. Eng. Remote. Sens. 58(9) 1992. pp. 1335-1341.

FOODY, G. M.; MCCULLOCH M. B. ; YATES, W. B. Classification of Remotely Sensed Data by an Artificial Neural Network: Issues Related to Training data Characteristics. Photogrammetric Engineering & Remote Sensing, Vol. 61, No. 4, abril de 1995, p. 391-401.

FRIEDL, M.A.; BRODLEY, C.E. Decision tree classification of land cover from remotely sensed data. Remote Sensing of Environment, v.61, p.399-409, 1997.

GARCIA, G. J. Sensoriamento remoto: Princípios e Interpretação de Imagens. São Paulo: Nobel, 1982.

GISLASON, P. O., BENEDIKTSSON, J.A, SVEINSSON. Random Forest for Land Cover Classification. Pattern Recognition Letters 27, 294-300. 2005.

HAN, J.;KAMBER, M. Data Mining: Concepts and Techniques. 2000.

HEPNER, G. F. Artificial Neural Networks Classification using a Minimal Training Set: Comparison to Conventional Supervised Classification. Photogrammetric Engineering and Remote Sensing, v. 56, n. 4, p.469-473, 1990.

HOSOKAWA, E. O. Técnica de Árvore de Decisão em Mineração de Dados. 2011. 40 p. Monografia – Faculdade de Tecnologia de São Paulo, São Paulo, 2011.

IMAZON.. Desmatamento nos Assentamentos de Reforma Agrária na Amazônia. <http://imazon.org.br/>. Disponível em: 11/12/2003.

INCRA.. Plano Nacional de Reforma Agrária, Projeto de Assentamento Florestal. <http://www.incra.gov.br/Consulta%20Publica.pdf> .Disponível em: 03/12/2003

INPE - Manuais: tutorial de geoprocessamento SPRING. 2008.

JENSEN, J. R., & TULLIS, J. A. Object-based change detection using correlation image analysis and image segmentation techniques. International Journal of Remote Sensing, 29, 399–423. 2008.

KAVZOGLU, T.; MATHER, P. M. The use of backpropagating artificial neural networks in land cover classification. 2003 International Journal of Remote Sensing 24(23):4907-4938.

KOHONEN, T. Self-Organizing Map. 3 ed., Springer-Verlag, Berlin, 2001 pp. 113.

KUSHADORNO, D.; FUKUE, K.; SHIMODA, H.; SAKATA, T.A Spatial Land Cover Classification with the Aid of Neural Network. Proceedings of SPIE - The International Society for Optical Engineering, Vol. 2315, 1994, Society of Photo-Optical Instrumentation Engineers, Bellingham, WA, USA, p.702-710.

LEITE M. E. Geografia e Geotecnologias no Estudo Urbano, Instituto de Geografia UFU, PPG em Geografia, Uberlândia, MG, 2006.

LIANG, Z.; JINPING,S.; HUIYOND,S.; GANG,Y.; YI,J. Large area Land Cover Classification with LANDSAT ETM+ Images based on Decision Tree., 2012 [International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XXXIX-B7].

LOPES, A.; NEZRY, E.; TOUZI R., LAUR, H. “Maximum A Posteriori Speckle Filtering and First Order Textural Models in SAR Images,” in Proceedings of International Geoscience and Remote Sensing Symposium, Maryland, pp. 2409-2412, 1990.

LUGER, G. L., STUBBLEFIELD, W. A., Artificial Intelligence : Structures and Strategies for Complex Problem Solving, Addison-Wesley, 1997.

MACHADO, R. J.; BARBOSA, V. C. ; LIPORACE, F. S. Applying Neural Networks for Deforestation Monitoring of the Amazon Region. Versãorevisada do artigo “Monitoring the Deforestation of the Amazon Region with Neural Networks”, publicadonos Proceedings of The Interantional Joint Conference on Neural Networks (IJCNN’93), Nagoya-Japan, 1993, p. 1239-1242.

MEDEIROS, J. S. Banco de dados Geográficos e Redes Neurais Artificiais: Tecnologias de Apoio à Gestão do Território. 221 f. Tese (Doutorado em Geografia Física) – FFLCH, Universidade de São Paulo, São Paulo, 1999.

MELGANI, F.; BRUZZONE, L.; Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. IEEE Transactions on Geoscience and Remote Sensing, vol.42, no8, pp 1778- 1790, agosto de 2004.

MINAI, A.A; WILLIAMS, R.J. Back-propagation heuristics: A study of the extended delta-bar-delta algorithm. IEEE International Joint Conference on Neural Networks vol. I (1990).pp. 595-600.

MIRKIN, B. Core Concepts in Data Analysis: Summarization, Correlation and Visualization. Springer. 2011.

MITCHELL, T. (1997). Machine Learning. McGraw-Hill, 1.ed. Rezende, S. O. (2003). Sistemas Inteligentes – Fundamentos e Aplicações. Editora Manole.

MITRA, S; ACHARYA, T. Data Mining: multimídia, soft computingandbioinformatics . New Jersey: John Willey & Sons, 2003.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. In: REZENDE, S. O. (Ed.). Sistemas inteligentes: fundamentos e aplicações. São Carlos: Manole, 2003. p. 89-114. cap. 4.

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. 250 p. (ISBN 901991).

MORTON, J. C. Image Analysis, Classification, and Change Detection in Remote Sensing: With Algorithms for ENVI/IDL, Second Edition. CRC Press. December 15, 2009. ISBN-10: 1405159685.

OLIVEIRA, G; MORAES, E.C. Classificação Digital do Uso e Cobertura da Terra na Amazônia com Base em Dados Orbitais ASTER. 2003.

PAL, M. and MATHER, P. M. Support vector machines for classification in remote sensing.2005. International Journal of Remote Sensing 26:1007-1011.

PERES, C. DATA MINING with IBM SPSS MODELER (IBM SPSS CLEMENTINE). CreateSpace Independent Publishing Platform. June 14, 2013.

PRADHAN, B. .A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS. Computers&Geosciences, 51, 350–365. 2013.

- QUADROS, E. Q. Geoprocessamento aplicado a elaboração do plano diretor de desenvolvimento rural Bento Gonçalves. 2004. Dissertação (Mestrado em Geomática) - Universidade Federal de Santa Maria, Santa Maria.
- QUINTANILHA, J. A. Entrada e conversão de dados: processos de construção de bases de dados espaciais, In: S IMPÓSIO B RASILEIRO DE GEOPROCESSAMENTO , 3. 1995, São Paulo. Anais ..., São Paulo: USP, p. 29-58.
- REBOUÇAS, P.S.M.D; "Metodologias de Classificação Supervisionada para Análise de Dados de Microarrays." Doutorado em Estatística e Investigação Operacional (Especialidade de Probabilidades e Estatística). 2011.
- ROCHA, C.H.B. Geoprocessamento: Tecnologia Transdisciplinar. Juíz de Fora: Ed do Autor, 2000. 220p.
- RODRIGUEZ-GALIANO, V. F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M., & RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. 2012.
- RONG, E. F.; PAI-HSEN, C.; CHIH, J. L. Working set selection using second order information for training SVM. *Journal of Machine Learning Research* 6, 1889-1918, 2005.
- RUSSEL S. J., NORVIG P. 2003. *Artificial Intelligence, A Modern Approach*, Second Edition. Prentice Hall.
- SAFAVIAN, S. R. and LANDGREBE, D., A Survey of Decision Tree Methodology, *IEEE Trans. Systems, Man and Cybernetics*, vol. 21, no. 3, May/Jun 1991. p. 660-674.
- SILVA, A. DE B. *Sistemas de informações geo-referenciadas: conceitos e fundamentos*. Campinas: Editora da Unicamp, 1999. 236 p.
- SOUTO, M. C. P., LORENA, A. C., DELBEM, A. C. B. e de CARVALHO, A. C. P. L. F. Técnicas de Aprendizado de Máquina para Problemas de Biologia Molecular in III Jornada de Mini-Curso de Inteligência Artificial - Livro Texto, pp. 103-152. SBC. 2003.
- SRIVASTAVA, P. K., HAN, D., RICO-RAMIREZ, M. A., BRAY, M., ISLAM, T. Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50(9), 1250–1265. 2012.
- SZUSTER, B. W.; CHEN, Q.; BORGES, M. (2011). A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Applied Geography*, 31(2), 525–532. 2011.
- TIM, N.; EILEEN, J.; BURKE, O. *Getting to Know ArcGIS Desktop 10*. Second Edition. Esri Press. August, 2010.
- VAPNIK, V. *The Nature of Statistical Learning Theory*. New York: Editora Springer. 1995.

WATRIN, O. dos S.; VENTURIERI, A.; VALENTE, M. A. Levantamento da vegetação e do uso da terra em áreas de remanescentes de quilombos na bacia do rio Trombetas, PA. Belém, PA: EMBRAPA-CPATU, 1998. 31 p. il. (EMBRAPA-CPATU. Documentos, 126).

YOSHIDA, T. O MATU, S. Neural Network Approach to Land Cover Mapping. IEEE Transactionson Geoscienceand Remote Sensing, vol. 32 No. 5, setembro de 1994, p. 1103-1109.