

**UNIVERSIDADE ESTADUAL DE PONTA GROSSA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA**

KELLY LAIS WIGGERS

**ANÁLISE EM UMA IMAGEM ORBITAL DE ALTA RESOLUÇÃO PARA
CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA DE UMA ÁREA
DA BACIA DO PITANGUI - PR**

**PONTA GROSSA
2014**

KELLY LAIS WIGGERS

**ANÁLISE EM UMA IMAGEM ORBITAL DE ALTA RESOLUÇÃO PARA
CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA DE UMA ÁREA
DA BACIA DO PITANGUI - PR**

Dissertação apresentada ao Programa de
Pós-Graduação em Computação Aplicada
da Universidade Estadual de Ponta Grossa,
como requisito parcial para obtenção do tí-
tulo de Mestre.

Orientadora: Prof Dra. Selma Regina Aranha
Ribeiro

**PONTA GROSSA
2014**

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

Wiggers, Kelly Lais

W655 Análise em uma imagem orbital de alta
resolução para classificação do uso e
cobertura da terra de uma área da Bacia do
Pitangui - PR/ Kelly Lais Wiggers. Ponta
Grossa, 2014.
123f.

Dissertação (Mestrado em Computação
Aplicada - Área de Concentração:
Computação para Tecnologias em
Agricultura), Universidade Estadual de
Ponta Grossa.

Orientadora: Profª Drª Selma Regina
Aranha Ribeiro.

1.Sensoriamento remoto. 2.Processamento
digital de imagens. 3.Self-organizing
maps. 4.Análise de componentes principais.
I.Ribeiro, Selma Regina Aranha. II.
Universidade Estadual de Ponta Grossa.
Mestrado em Computação Aplicada. III. T.

CDD: 630.2

TERMO DE APROVAÇÃO

Kelly Laís Wiggers

"ANÁLISE EM UMA IMAGEM ORBITAL DE ALTA RESOLUÇÃO PARA CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA DE UMA ÁREA DA BACIA DO PITANGUI - PR"

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Orientador:


Dr.ª Selma Regina Aranha Ribeiro
UEPG


Dr. José Carlos Ferreira da Rocha
UEPG


Dr.ª Angelita Maria de Ré
UNICENTRO

Ponta Grossa, 16 de dezembro de 2014.

***Dedico:** Aos meus pais Luiz e Serlei, pelo apoio, paciência e incentivo aos estudos.*

AGRADECIMENTOS

Agradeço primeiramente a Deus pela minha vida, provendo-me de força e sabedoria para estar concluindo este curso.

À minha mãe Serlei Correia Wiggers e meu pai Luiz Auri Wiggers, que sempre me incentivaram e apoiaram de todas as formas possíveis.

Agradeço ao Fábio Leandro Janiszewski, pela paciência, apoio e por ter acreditado no meu potencial.

À minha orientadora Selma Regina Aranha Ribeiro, pela oportunidade, incentivo e contribuições no trabalho desenvolvido.

Aos professores e colegas que colaboraram significativamente no progresso da minha formação, em especial as minhas colegas do mestrado, Lays, Geisla e Suelyn pelas contribuições, conversas e conselhos durante esse tempo. Agradeço ao Giuvane pela amizade e cooperação nas pesquisas. Também aos Geotecs, Thays, Josilhane, Willian, Grazi e Joel pelos dias no laboratório, reuniões e auxílio. Em especial agradeço a Dinameres que colaborou para o desenvolvimento do trabalho e pelo apoio em momentos que precisei.

À Universidade Estadual de Ponta Grossa, pela oportunidade e estrutura cedida para os estudos e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de pós-graduação.

A todos que direta ou indiretamente contribuíram para a elaboração deste trabalho.

“Para realizar grandes conquistas, devemos não apenas agir, mas também sonhar; não apenas planejar, mas também acreditar.”

(Anatole France)

RESUMO

O Sensoriamento Remoto (SR) dispõe de tecnologias em constante crescimento e com grande potencial para a agricultura, tanto no gerenciamento de culturas, manejo de solo, bem como discriminações de feições da terra. Atualmente, há muitos métodos de análise e categorização de paisagens, que com a integração de dados de SR e técnicas de Sistemas de Informação Geográfica (SIG) apresentam alternativa promissora. Isto é, proporcionam maior facilidade na manipulação de dados geográficos, bem como otimização da validação a campo. Neste contexto, esta pesquisa foi realizada utilizando classificação digital não-supervisionada pela Rede Neural Artificial (RNA) Self-Organizing Maps (SOM) no reconhecimento de padrões de uso e cobertura da terra em um recorte de imagem orbital de alta resolução Rapideye pertencente à Bacia do Pitangui, o qual abrange o município de Ponta Grossa, localizado a centro-leste do Estado do Paraná. Primeiramente aplicou-se a técnica NDVI (Índice de Vegetação por Diferença Normalizada) para estimular a separação das classes, principalmente os diferentes tipos de cultivos agrícolas, bem como cobertura florestal. A imagem orbital e NDVI foram segmentadas por meio de Análise de Imagem Baseada em Objeto (GEOBIA), gerando descritores com propriedades espaciais, espectrais e de textura, culminando no banco de dados relacional (BDR) com tais descritores. Mediante Análise de Componentes Principais (ACP) reduziu-se a dimensionalidade dos dados do BDR, selecionando os descritores mais significativos. A dimensionalidade foi reduzida, sem perda de informação, de 42 descritores para 21, a saber 6 espaciais, 12 espectrais e 3 de textura. Após esta preparação dos dados, utilizou-se a RNA SOM para o reconhecimento dos padrões pré-determinados a campo. As classes de uso e cobertura da terra discriminadas pela RNA SOM foram cultivos (cultivo 1, 2, 3 e 4), estradas e construções, cobertura florestal e corpos d'água. A RNA SOM culminou no agrupamento das classes cultivos inclusive em relação ao seu ciclo fenológico. A associação da banda artificial NDVI, com seus descritores às bandas espectrais, incrementou a separabilidade entre classes, tais como cobertura florestal e corpos d'água. As classes de uso e cobertura da terra foram validadas a campo, a exatidão global foi de 91% de acerto, com índice kappa de 0,9, considerado resultado excelente em valores de referência. Também foi realizado o teste estatístico F, o qual satisfaz as hipóteses de nulidade nas áreas analisadas. Conclui-se que os métodos utilizados apresentaram eficácia, agilidade e baixo custo no mapeamento do uso e cobertura da terra em escala detalhada.

Palavras-chave: Sensoriamento Remoto, Processamento Digital de Imagens, *Self-Organizing Maps*, Análise de Componentes Principais.

ABSTRACT

Remote Sensing (RS) uses steadily growing technologies and presents great potential for agriculture, e.g. in crop and land management, as well as for discrimination of land features. Currently, there are many methods of analysis and landscape categorization that when integrated with RS data and Geographic Information Systems (GIS) techniques stage as promising alternatives. That is, they provide greater ease in handling spatial data as well as optimizing validation on the field. In this context, this study was carried out using unsupervised digital classification with Artificial Neural Network (ANN) Self-Organizing Maps (SOM), in order to recognize patterns of land cover and land use in part of a high-resolution Rapideye orbital image belonging to the Pitanguí River Basin, which encompasses the city of Ponta Grossa, located in the Central-Eastern portion of the State of Paraná. Initially, NDVI (Normalized Difference Vegetation Index) technique was applied to stimulate the separation of classes, especially to evidence different types of agricultural crops and forest cover. The orbital image and the NDVI were segmented through Geographic Object-Based Image Analysis (GEOBIA), generating descriptors with spatial, spectral and textural properties, culminating in the relational database (RDB) with such descriptors. With Principal Component Analysis (PCA) dimensionality of the BDR data was reduced, selecting the most significant descriptors. Dimensionality was reduced without information loss, from 42 descriptors to 21, namely 6 spatial, 12 spectral and 3 textural. After this data preparation, ANN SOM was used to recognize predetermined patterns in the field. The classes of land cover and land use discriminated by ANN SOM were crops (crop 1, 2, 3 and 4), roads and buildings; forest cover and water bodies. The ANN SOM culminated in the grouping of crop classes including in relation to its phenological cycle. The association of the NDVI artificial band with descriptors to spectral bands, increased the separability between classes, such as forest cover and water bodies. Classes of land cover and land use were validated in the field, the global accuracy was 91%, with kappa index of 0.9 and considered to be excellent as reference values. F statistical test was also carried out and showed satisfiability in the analyzed areas. It is concluded that the methods used were effective, agile and low-cost in detailed scale mapping of land use and coverage.

Keywords: Remote Sensing, Digital Image Processing, Self-Organizing Maps, Principal Component Analysis.

LISTA DE SIGLAS

AOO	Análise Orientada a Objeto
ACP	Análise de Componentes Principais
BP	Backpropagation
BMU	Best Matching Unit
CP	Componente Principal
ED	Escarpa Devoniana
FLSA	Full-Lambda Schedule Algorithm
FNEA	Fractal Net Evolution Approach
GEOBIA	Análise de Imagem Baseada em Objetos Geográficos
GL	Grau de Liberdade
IA	Inteligência Artificial
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
ITT VIS	Visual Information Solutions
MAXVER	Máxima Verossimilhança
ML	Merge Level
MLP	Multilayer Perceptron
NDVI	Normalized Difference Vegetation Index
NUCLEAM	Núcleo de Estudos em Meio Ambiente
OBIA	Object Based Image Analysis
PDI	Processamento de Imagens Digitais
PPP	Primeiro Planalto Paranaense
RNA	Rede Neural Artificial
RVI	Ratio Vegetation Index
SAR	Syntetic Aperture Radar
SIG	Sistemas de Informação Geográfica
SL	Scale Level
SOM	Self-Organizing Maps
SPP	Segundo Planalto Paranaense
SR	Sensoriamento Remoto
VT	Verdade Terrestre

LISTA DE ILUSTRAÇÕES

1	Passos fundamentais no processamento digital de imagens	19
2	Modelo não-linear de um neurônio	35
3	Rede alimentada adiante ou acíclica com uma única camada de neurônios .	37
4	Rede alimentada adiante ou acíclica totalmente conectada com uma ca- mada oculta e uma camada de saída	38
5	Fluxograma do algoritmo de treinamento da SOM	40
6	Diferentes funções de vizinhança	44
7	Diferentes funções de aprendizagem	46
8	Relação entre o mapa de característica Φ e o vetor de peso w_i do neurônio vencedor i	48
9	Área de estudo	51
10	Bandas espectrais monocromáticas da Rapideye	57
11	Composições coloridas das bandas espectrais da Rapideye	59
12	Diagrama de Blocos: etapas de desenvolvimento da pesquisa	60
13	Separação dos agrupamentos mediante u_matrix	64
14	Exemplos de vizinhança: Hexagonal e Retangular	66
15	Topologia da RNA SOM (plana, cilíndrica e toroidal, respectivamente) . .	66
16	Fluxograma para análise de testes	67
17	Exemplos de imagens para validação a campo (VANT e horizontal)	69
18	Amostras coletadas para validação	70
19	Áreas selecionadas para teste F	70
20	Área de estudo apresentada pela Banda Artificial NDVI (monocromática) .	73

21	Ilustração das variações de segmentação e seus respectivos vetores: (a) e (b) Segmentação 1, (c) e (d) Segmentação 2, (e) e (f) Segmentação 3, (g) e (h) Segmentação 4	74
22	Ilustração do banco de dados espacial e semântico gerados a partir da segmentação	76
23	Variância explicada das CPs	77
24	Gráfico de scores das duas primeiras CPs	78
25	Ilustração da influência dos descritores espaciais (a), espectrais (b), de textura (c) e NDVI (d) nas regiões da área de estudo	79
26	Figuras exemplificando a classe selecionada na imagem à esquerda e o neurônio na <i>u_matrix</i> à direita, mediante as funções de normalização: log (a), range (b), var (c), HistC (d) e HistD (e)	81
27	Ilustrações exemplificando a classe selecionada na imagem (a) e na <i>u_matrix</i> (b), com ACP e sem NDVI	83
28	Ilustrações exemplificando a classe selecionada na imagem (a) e na <i>u_matrix</i> (b), sem ACP e com NDVI	84
29	Ilustrações exemplificando a classe selecionada na imagem (a) e na <i>u_matrix</i> (b), sem ACP e sem NDVI	84
30	Ilustrações exemplificando a classe selecionada na imagem (a) e na <i>u_matrix</i> (b), com ACP e com NDVI	85
31	<i>U_matrix</i> - Resultado final dos agrupamentos	86
32	<i>U_matrix</i> do treinamento da SOM por descritores (21 selecionados por ACP e 4 do NDVI)	87
33	Imagem classificada do uso e cobertura da terra (com ACP e NDVI)	89
34	Ilustração de áreas demarcadas a campo	90
35	Ilustrações das classes de uso e cobertura da terra verificadas a campo . . .	91

LISTA DE TABELAS

1	Bandas espectrais da imagem orbital Rapideye	57
2	Métodos de normalização da RNA SOM para Matlab	65
3	Elementos "chaves"de interpretação das classes de uso e cobertura da terra	68
4	Valores de referência índice kappa	71
5	Configurações da extração de características por GEOBIA	74
6	Parâmetros finais de treinamento na RNA SOM	83
7	Regiões da <i>u_matrix</i> em função das classes de uso e cobertura da terra . .	86
8	Matriz de confusão da classificação	92
9	Teste F - Classes: Estradas e construções, Corpos d'água, Cobertura flo- restal e Cultivo 3	93

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVO GERAL	14
1.2	OBJETIVOS ESPECÍFICOS	14
1.3	MOTIVAÇÃO	15
1.4	ORGANIZAÇÃO DO TRABALHO	16
2	REVISÃO DA LITERATURA	17
2.1	SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÃO GEOGRÁFICA	17
2.2	PROCESSAMENTO DE IMAGENS DIGITAIS	18
2.2.1	Detecção de descontinuidades	21
2.2.2	Detecção de similaridades	21
2.3	ANÁLISE DE IMAGENS BASEADA EM OBJETOS GEOGRÁFICOS	24
2.3.1	Descritores Espectrais	26
2.3.2	Descritores de Textura	27
2.3.3	Descritores Espaciais	28
2.4	ANÁLISE DE COMPONENTES PRINCIPAIS	30
2.4.1	Desenvolvimento matemático	31
2.5	CLASSIFICAÇÃO DE IMAGENS DIGITAIS	32
2.6	REDES NEURAIS ARTIFICIAIS	34
2.6.1	Neurônios biológicos	34
2.6.2	Arquitetura da rede	36
2.6.2.1	Redes com Camada Única	37
2.6.2.2	Redes com Múltiplas Camadas	37

2.6.3	SELF-ORGANIZING MAPS	39
2.6.3.1	Funcionamento do Algoritmo de Treinamento	40
2.6.3.2	Propriedades do mapa de características	47
2.6.4	APLICAÇÕES	49
3	ÁREA DE ESTUDO	50
3.1	Fisiografia da Bacia do Pitangui	52
4	PROCEDIMENTOS METODOLÓGICOS	56
4.1	MATERIAL E MÉTODOS	56
4.2	EXTRAÇÃO DE CARACTERÍSTICAS MEDIANTE GEOBIA	61
4.3	APLICAÇÃO DA ACP	62
4.3.1	Seleção de variáveis mediante ACP	62
4.4	TREINAMENTO DA SOM	63
4.5	TESTES DA SOM	66
4.6	VALIDAÇÃO A CAMPO	67
4.6.1	Matriz de confusão e índice kappa	71
4.6.2	Teste F para duas variâncias	71
5	EXPERIMENTOS, RESULTADOS E DISCUSSÃO	73
5.1	PRIMEIRO EXPERIMENTO: Segmentação da imagem orbital mediante GEOBIA	73
5.2	SEGUNDO EXPERIMENTO: Seleção de variáveis mediante ACP	77
5.3	TERCEIRO EXPERIMENTO: Análise da <i>u_matrix</i>	80
5.4	QUARTO EXPERIMENTO: Parâmetros de treinamento da SOM	82
5.5	QUINTO EXPERIMENTO: Classificação do uso e cobertura da terra	82
5.6	Validação	91
6	CONSIDERAÇÕES FINAIS	95
6.1	Trabalhos Futuros	96
	REFERÊNCIAS	98

APÊNDICE A – Composições coloridas da Rapideye	103
APÊNDICE B – Autovalores, variância explicada e acumulada	105
APÊNDICE C – Matriz de autovetores	107
APÊNDICE D – Ilustração dos atributos selecionados por ACP	110
APÊNDICE E – <i>Script</i> da ACP no software R	114
APÊNDICE F – Histogramas das funções de normalização	116
APÊNDICE G – Resultados de alguns testes na SOM	119
APÊNDICE H – Tabela da contribuição dos descritores na u_matrix . .	122

1 INTRODUÇÃO

Os processos de categorização do uso da terra envolvem fatores complexos para realizar a identificação e diferenciação das paisagens, principalmente quando são processos tradicionais de mapeamento temático, sendo criticados por serem caros, demorados e subjetivos.

O estudo de novas técnicas que incrementam pesquisas de mapeamento temático, utilizando os conhecimentos disponíveis em Sistemas de Informação Geográfica (SIG), Sensoriamento Remoto (SR), Geoestatística, dentre outros, é relevante, pois busca-se a melhoria no processo de coleta de dados e organização das etapas do mapeamento.

Muitas pesquisas que envolvem a evolução tecnológica estão relacionadas ao uso de sensores, o que facilita a instrumentação dos equipamentos agrícolas, em suas atividades de gerenciamento da cultura, manejo do solo ou mesmo aplicação de insumos de forma adequada. Desta forma, as imagens de sensores apresentam potencial para estudos da superfície terrestre, marítima, impactos ambientais, dentre outros.

Com a integração de técnicas matemáticas e estatísticas é possível discriminar as feições de superfícies mediante imagens de sensores remotos. Necessita-se, portanto, de análise quantitativa dos dados com o uso de sistemas computacionais, conhecida como classificação digital de imagens.

A grande quantidade de imagens que são coletadas por sistemas de sensores, cada vez mais sofisticados, requerem o desenvolvimento de metodologias de classificação digital inovadoras, tornando o processo de mapeamento menos subjetivo e com maior potencial de repetição em outras situações e/ou regiões.

O reconhecimento de padrões por meio de classificação digital em imagens orbitais com baixa resolução espacial, utilizando o nível de abstração de pixel é utilizado em diversas aplicações bem sucedidas em SR. No entanto, possui limitações em relação as imagens de alta resolução, que possibilita maior quantidade de dados e informações neste tipo de imagem. Muitas vezes, dependendo da complexidade da cena, somente dados espectrais da imagem não são suficientes para que o classificador digital atinja a separabilidade de cada classe, ou que reconheça os padrões da imagem. Assim, a técnica de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) realiza o processo de agregação de pixels ou segmentos em regiões mediante análise de textura, cor, tamanho e topologia. Como resultado, a técnica de GEOBIA possibilita a análise regional da cena e ainda, a geração de banco de dados relacional com descritores específicos (espacial, es-

pectral e de textura), que possuem diferentes escalas e origens, e representam as regiões da imagem. Para a classificação a nível de objetos (GEOBIA) é necessário buscar novas técnicas que permitam reconhecer os descritores (espacial, espectral e de textura), fato que não é possível nas técnicas convencionais que consideram o pixel como informação básica. Assim, um método conhecido de classificação de imagens digitais é a Rede Neural Artificial (RNA) não-supervisionada *Self-Organizing Maps* (SOM).

A RNA SOM tem como princípio a aprendizagem competitiva, simulando processos específicos do cérebro humano para fins de reconhecimento de padrões. Este se apresenta pertinente em estudos de classificação com áreas complexas e descritores de diferentes origens e escalas, uma vez que não necessite da análise "a priori" destes descritores.

Portanto, com imagem orbital de alta resolução Rapideye e classes de uso e cobertura da terra com resposta espectral semelhante, o objeto de estudo desta pesquisa é a utilização da GEOBIA, na extração das características baseada a objetos, com seus respectivos descritores espaciais, espectrais e de textura, dispostos em um banco de dados relacional, que será exportado para a classificação digital destes padrões mediante a RNA SOM.

1.1 OBJETIVO GERAL

Classificar o uso e cobertura da terra de uma área da Bacia do Pitangui - PR, Brasil mediante GEOBIA e RNA SOM em um recorte de imagem orbital de alta resolução.

1.2 OBJETIVOS ESPECÍFICOS

- Realizar levantamento do estado da arte das metodologias existentes em GEOBIA e classificação de imagens orbitais;
- Realizar o Índice de Vegetação por Diferença Normalizada (NDVI) para verificar a influência na classificação digital dos objetos;
- Realizar a redução da dimensionalidade e seleção de descritores por Análise dos Componentes Principais (ACP) para serem utilizados no aprendizado não supervisionado da RNA SOM;
- Treinar os descritores obtidos do banco de dados relacional da GEOBIA mediante RNA SOM;

- Validar a campo, matriz de erros, índice kappa e teste F, a classificação do uso e cobertura da terra.

Dessa forma, espera-se que esta pesquisa contribua com o entendimento da paisagem da Bacia do Pitangui, a partir da utilização adequada de técnicas de Processamento de Imagens Digitais (PDI), GEOBIA, juntamente com o método de estatística multivariada (Análise de Componentes Principais), Sistemas de Informação Geográfica e RNA SOM, auxiliando com eficácia, agilidade e baixo custo no mapeamento do uso e cobertura da terra em escala detalhada, o qual é de suma importância para gerenciamento e uso adequado do ambiente.

1.3 MOTIVAÇÃO

O uso inadequado da terra pode comprometer fontes e mananciais de água, degradação de habitats naturais, erosão, enchentes e assoreamento do solo. Estes estão diretamente ligados ao mau gerenciamento do espaço, pois não respeitam a capacidade de suporte da natureza (LEITE *et al.*, 2010). No Brasil, a carência de mapeamentos em escala detalhada é fato.

Desta forma, técnicas provenientes de geotecnologia, tais como geoprocessamento, SIG e SR, podem auxiliar na investigação do uso e cobertura da terra. Essas ferramentas de mapeamento e classificação do uso da terra, como o objetivo deste estudo, tornam-se cada vez mais úteis em análises ambientais com diversas finalidades, e tem papel fundamental nas transformações atuais e futuras das paisagens.

A GEOBIA, como método de geotecnologia, utilizada em reconhecimento de padrões, está sendo difundida em diversas aplicações, pois a interpretação visual de imagens pode se tornar inviável pela grande demanda de tempo, quando aplicado em áreas muito extensas, e a classificação a nível de abstração do pixel, é insipiente em imagens orbitais de alta resolução. Portanto, a alternativa é utilizar métodos de classificação digital, que baseados na segmentação de imagens e classificação por regiões produzem resultados muito mais precisos que baseado pixel a pixel (VASCONCELOS; NOVO, 2004). Entretanto, deve-se considerar na GEOBIA, métodos robustos de classificação digital, pois este novo paradigma possui dados de diferentes origens e escalas.

Como método de classificação digital, a RNA SOM não requer o conhecimento "a priori" das relações subjacentes entre as variáveis investigadas ou designação de padrões de saída. Os descritores obtidos da GEOBIA são de origens diferentes (espacial, espectral e

de textura), o que limita o uso de técnicas que necessitem de parâmetros de representação, tal como a média dos dados.

Desta forma, com uso adequado da GEOBIA juntamente com classificação digital mediante RNA SOM, pretende-se contribuir para mapeamento do uso e cobertura da terra.

1.4 ORGANIZAÇÃO DO TRABALHO

A organização do trabalho encontra-se dividida em 6 capítulos, além desse capítulo introdutório, No segundo capítulo apresenta-se a revisão da literatura referente ao trabalho, onde são exploradas as informações referentes SR e SIG, técnicas de PDI e RNA. No terceiro capítulo é identificada a área de estudo, detalhando a fisiografia da Bacia do Pitangui. No quarto capítulo estão os procedimentos metodológicos para a realização do trabalho, bem como suas etapas e técnicas. No quinto capítulo estão os resultados do trabalho, os quais atenderam os objetivos do trabalho. No sexto capítulo, tem-se as considerações finais do trabalho e comparações dos resultados com os objetivos determinados.

2 REVISÃO DA LITERATURA

2.1 SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÃO GEOGRÁFICA

O Sensoriamento Remoto (SR) é realizado utilizando um sensor a distância do objeto ou área de interesse, ou seja, sem contato com o objeto. Estes equipamentos são programados para coletarem dados sistematicamente (JENSEN, 2009).

SR é uma tecnologia em constante crescimento e de grande potencial para a agricultura. Por meio desta técnica é possível o levantamento de informações tais como: produção agrícola, a estimativa de área plantada em determinada região, vigor vegetativo das culturas, além de fornecer subsídios para o manejo agrícola em nível de país, estado, município ou ainda em nível de sub-bacia hidrográfica ou fazenda (RUDORFF; MOREIRA, 2002).

As imagens de SR devem ser vistas como documentos que representam, em escala e sobre um plano 2D, os acidentes e as feições naturais e artificiais da superfície terrestre, a partir da medição do processo físico da radiação eletromagnética (MENESES; ALMEIDA, 2012). Os dados que são extraídos a partir de imagens de SR podem ser trabalhados de forma organizada com o uso de SIG. Segundo Burrough (1992) o objetivo principal de SIG é servir de instrumento de apoio a todas as áreas de conhecimento que utilizem imagens e/ou mapas e banco de dados descritivos, por meio da integração das informações de diferentes origens referentes a uma região em uma única base de dados referenciada espacialmente.

O desenvolvimento de uma região depende de estudos básicos, incluindo o planejamento e monitoramento da cobertura/uso da terra. Neste sentido, o SR é reconhecido como importante técnica. O desenvolvimento de métodos automáticos e robustos tornou-se relevante tema de pesquisa quando a análise possibilita cobrir a grande variedade de paisagens, em nível nacional e até mesmo internacional. Tais métodos também são fundamentais para monitorar mudanças ao longo do tempo (AKSOY; AKÇAY; WASSENAAR, 2010)(DEMATTE *et al.*, 2012).

Devido as informações de SR e a capacidade de organização e manipulação dos SIGs, estas duas técnicas são complementares nos estudos regionais. A velocidade e a dinâmica da integração desses dois métodos, antes essencialmente separados, aumentou consideravelmente nos últimos anos. O desenvolvimento mais atual é a rápida mudança de Processamento Imagens Digitais (PDI), até então orientado fortemente ao pixel como

o menor elemento e portador exclusivo de informações espectrais. A mudança corresponde a novos procedimentos que consideram a delimitação de objetos homogêneos como a base para o processamento posterior.


Portanto, destaca-se especialmente para mapeamentos de uso da terra, um novo paradigma para análise de imagens, em que a interpretação dela não está presente no pixel, e sim em objetos e nas relações existentes entre eles (BLASCHKE; KUX, 2007). Além disso, a análise orientada a objeto permite a inserção do conhecimento do intérprete e a utilização de parâmetros espaciais, espectrais e de textura na classificação de imagens. Portanto, o PDI é ferramenta computacional crucial neste estudo e a seção 2.2 apresenta conceitos básicos sobre este tema.

2.2 PROCESSAMENTO DE IMAGENS DIGITAIS

O Processamento de Imagens Digitais (PDI) é certamente uma área em crescimento. Diversos temas científicos são abordados e em alguns casos de caráter interdisciplinar. O PDI consiste em um conjunto de técnicas para capturar, representar e transformar imagens com o auxílio de computador. O emprego dessas técnicas permite extrair e identificar informações das imagens, bem como melhorar a qualidade visual de certos aspectos estruturais, facilitando a percepção humana e a interpretação automática por meio de máquinas (GONZALEZ; WOODS, 2000). Para tanto, é necessário realizar algumas etapas de processamento, sendo representadas na figura 1 por Gonzalez e Woods (2000). O diagrama não significa que todo esse processo se aplique a uma imagem, essas metodologias podem ser aplicadas a imagens para diferentes propósitos e, possivelmente, com diferentes objetivos. No caso desta pesquisa, com o domínio do problema, serão utilizadas as metodologias de realce de imagens, segmentação, representação e descrição, reconhecimento de objetos e base de conhecimento.

- A aquisição de imagens é o primeiro processo da figura 1. Esta fase pode ser tão simples quanto receber uma imagem que já esteja em formato digital. Em geral, envolve pré-processamento, por exemplo, o redimensionamento de imagens.
- O realce de imagens é o processo de manipular a imagem de forma que o resultado seja mais adequado do que o original para uma aplicação específica.
- A restauração de imagens também trabalha com a melhora visual de uma imagem.
- O processamento de imagens coloridas é uma área que tem ganhado importância em virtude do aumento significativo da utilização de imagens digitais na internet.

Figura 1: Passos fundamentais no processamento digital de imagens



Fonte: Gonzales e Woods (2000)

- As *wavelets* constituem os fundamentos para representação de imagens em vários níveis de resolução. Pode ser utilizado para compressão de dados de imagens e representação piramidal, no qual as imagens são subdivididas sucessivamente em regiões menores.
- A compressão se refere a redução do armazenamento necessário para salvar a imagem, ou a largura de banda necessária para transmiti-la.
- O processamento morfológico tem ferramentas para extração de componentes de imagens úteis na representação e descrição da forma.
- A segmentação divide a imagem em suas partes ou objetos constituintes. A segmentação autônoma é uma das tarefas mais difíceis do PDI. Um processo de segmentação de imagens bem-sucedido aumenta as chances de sucesso na solução de problemas que requerem que os objetos sejam individualmente identificados.
- A representação e descrição quase sempre partem do resultado do estágio de segmentação, correspondendo tanto à fronteira de uma região como todos os pontos dentro dela. Em ambos os casos, é necessário converter os dados a uma forma adequada para o processamento computacional.
- O reconhecimento é o processo que atribui um rótulo a um objeto com base em seus descritores.
- O conhecimento sobre o domínio do problema está codificado em um sistema de processamento de imagens em forma de base de conhecimento (banco de dados). Esse

conhecimento pode ser tão simples quanto o detalhamento de regiões da imagem, que se sabe que a informação de interesse pode ser localizada. Pode ser complexa, como por exemplo, uma lista inter-relacionada de todos os principais defeitos possíveis em um problema de inspeção de materiais. Além disso, a base de conhecimento controla a interação entre os módulos.

Segundo Florenzano (2007) as imagens obtidas por sensores remotos, qualquer que seja o seu processo de formação, registram a energia proveniente dos objetos da superfície observada, e este fato pode levar a interpretação do mundo real na imagem, a partir de uma representação 2D. De acordo com Jensen (2009), para desenvolver análises regionais, observar o terreno em três dimensões, interpretar imagens obtidas de múltiplas regiões do espectro eletromagnético e detectar mudanças, é habitual o uso de princípios de interpretação de imagens.

Os princípios fundamentais são os elementos de interpretação de imagem, usados rotineiramente quando ocorre a fotointerpretação visual. Os elementos de interpretação incluem localização, tonalidade e cor, tamanho, forma, textura, padrão, sombra, altura e profundidade, volume, declividade, aspecto, sítio, situação e associação (GONZALEZ; WOODS, 2000).

Um intérprete de imagens bem treinado utiliza de forma integrada os elementos de interpretação de imagem, sem ter que pensar neles individualmente, sendo essa análise intitulada de qualitativa. Segundo Galo (2009) a interpretação de dados de SR via computador é chamada análise quantitativa, em função de sua habilidade em identificar pixels, com base nas suas propriedades numéricas e devido a sua capacidade de calcular o número de pixels, que determinam uma dada área homogênea na cena.

Os sistemas disponíveis para a implementação de técnicas de análise quantitativa e os aplicativos utilizados pelos computadores comerciais, complementam os processos iterativos de processamento de imagens por computador. Em alguns casos, os processos de análise quantitativa são baseados em classificação de imagens. Outras análises quantitativas são os realces de imagens, os pré-processamentos sendo elas correções atmosféricas, radiométricas e geométricas, bem como a segmentação de imagens digitais.

Em análise quantitativa, para realce de imagens orbitais, destaca-se os índices de vegetação, que são operações entre bandas do espectro eletromagnético. As bandas mais utilizadas para operações de realce são a banda do vermelho e a banda do infravermelho próximo. Desse modo, o emprego de índices de vegetação para o monitoramento pode distinguir diferentes tipos de vegetação e detectar problemas de crescimento (LIU, 2006).

Os índices de vegetação baseados em razão mais conhecidos são o Ratio Vegetation Index (RVI) e o Normalized Difference Vegetation Index (NDVI) (PEARSON; MILLER, 1972). O RVI foi formulado com a divisão da reflectância da banda do infravermelho próximo pela reflectância da banda do vermelho. Já o NDVI, foi formulado por Rouse *et al.* (1974), o qual utiliza a diferença da reflectância entre a faixa do infravermelho próximo e a reflectância da faixa de visível. Nesta pesquisa será utilizado o NDVI, visto que é um índice bastante utilizado em pesquisas de mapeamento temático. É importante no monitoramento de mudanças sazonais e interanuais no desenvolvimento da atividade da vegetação, e reduz muitas formas de ruídos presentes em múltiplas bandas de imagens (JENSEN, 2009). Este índice será melhor detalhado na seção 4.

Na próxima etapa de processamento de imagens, realiza-se a segmentação. De acordo com Gonzalez e Woods (2000) os algoritmos para segmentação de imagens geralmente são baseados nas propriedades básicas de valores de níveis digitais: descontinuidade e similaridade. A seguir são descritas, de forma breve, algumas das técnicas de segmentação mais utilizadas em PDI, bem como aquelas voltadas para imagens de SR. Não há um método comum de segmentação que pode ser utilizado para as imagens, visto que depende do objetivo proposto pelo analista. Será dada maior ênfase à técnica *Full-Lambda Schedule Algorithm* (FLSA), pois esta é utilizada nesta pesquisa.

2.2.1 Detecção de descontinuidades

A segmentação por detecção de descontinuidades refere-se às mudanças bruscas que ocorrem no valor de cinza. Esta técnica é utilizada quando se deseja detectar bordas ou pontos isolados.

- **Detecção de bordas:**

Define-se borda como a fronteira entre regiões cujos valores digitais predominantes são suficientemente diferentes. No entanto, as bordas não são perfeitamente caracterizadas sem que haja um tratamento posterior na imagem. Isto porque ruídos, não uniformidade da iluminação, dentre outros, introduzem descontinuidades na bordas.

2.2.2 Detecção de similaridades

Verifica o interior das regiões. Assim, a similaridade entre pixels vizinhos caracteriza uma região, pois a idéia básica é de que esta deva ter um grau de homogeneidade

relativo a alguma de suas propriedades. No caso de imagens digitais a característica observada é o valor do pixel. As principais técnicas são descritas a seguir:

- **Limiarização**

Matematicamente, a operação de limiarização pode ser descrita como uma técnica de PDI no qual a imagem de entrada $f(x, y)$ de N níveis digitais produz uma imagem de saída $g(x, y)$, chamada limiarizada, cuja quantidade de tons de cinza é menor que N . A técnica mais simples de limiarização é a do particionamento do histograma da imagem por um limiar único T . As equações a seguir denotam o funcionamento de limiarização. Seja:

$$g(x, y) = 1 \quad \text{se} \quad f(x, y) \geq T \quad (1)$$

$$g(x, y) = 0 \quad \text{se} \quad f(x, y) < T \quad (2)$$

onde os pixels poderão ser rotulados de 1 ou 0, sendo T um valor de nível digital predefinido, ao qual é chamado de limiar (GONZALEZ; WOODS, 2000).

A segmentação é realizada varrendo a imagem, pixel a pixel, e associando cada pixel a um determinado objeto, dependendo do nível digital, se for maior ou menor que T . Neste caso considera-se apenas a informação espectral de cada pixel para determinar as regiões homogêneas (ANTUNES, 2003).

- **Crescimento de regiões**

Segundo Gonzalez e Woods (2000) o crescimento de regiões é uma técnica de agrupamento espacial no qual somente os pixels adjacentes, contíguos na imagem, podem ser agrupados. Esta técnica consiste em partir de um ou vários pixels considerados uniformes, analisar os pixels na vizinhança e adicionar os vizinhos que forem similares ao grupo inicial, de maneira que a região formada cresça num processo iterativo, que termina quando as fronteiras naturais dos objetos presentes na cena forem atingidas. Ao final do processo, a imagem encontra-se dividida em várias sub-regiões. A região cresce por agregação de pixels com características similares, tipo cor e brilho.

- **Divisão e fusão**

O crescimento de regiões aumenta o tamanho das regiões a partir de um conjunto de pontos-semente. Uma alternativa é subdividir uma imagem inicialmente em conjunto

de regiões distintas e arbitrárias e, sem seguida, fundir e/ou dividir as regiões na tentativa de satisfazer as condições de segmentação. Uma maneira de realizar esse processo é inicialmente subdividir a imagem pela técnica de *quadrees*, em que cada região quando não atende ao critério de homogeneidade, é subdividida em outras quatro. Assim, o fim do processo é quando não há mais subdivisões a serem feitas, iniciando o processo de fusão.

O processo de segmentação é somente a agregação dos níveis digitais e região, ou seja, a região será descrita espectralmente como a média dos níveis digitais ou o valor mínimo deles, abordando somente com dados estatísticos da radiância refletida. Entretanto com os métodos *Fractal Net Evolution Approach* (FNEA) e FLSA, além dos dados espectrais, são utilizados os descritores de forma e textura bem como a topologia mediante o banco de dados relacional.

- ***Fractal Net Evolution Approach (FNEA)***

O FNEA é um segmentador multiresolução, desde uma escala menor até uma escala maior, que permite segmentar a imagem em diferentes níveis hierárquicos, fazendo o uso de conceitos da lógica *fuzzy* e de semântica (BLASCHKE; LANG; HAY, 2008)(ANTUNES, 2003). A hierarquia permite diferenciar classes de objetos em diferentes escalas e a semântica permite inserir o conhecimento do usuário (BLASCHKE; LANG; HAY, 2008).

Este tipo de segmentador está disponível no *software* comercial e-Cognition, e utiliza descritores espectrais, de forma, de posição e textura. Maiores informações sobre este tipo de segmentador pode ser encontrado em (ANTUNES, 2003), (BLASCHKE; LANG; HAY, 2008) e (BAATZ; SCHAPE, 2000).

- ***Full Lambda Schedule Algorithm (FLSA)***

O FLSA foi proposto por (ROBBINSON; REDDING; CRISP, 2002), para ser utilizado com imagens SAR (*Syntetic Aperture Radar*), porém tem aplicabilidade em diversas situações. É um meio altamente eficiente para encontrar o limite de segmentação com as melhores partições da imagem em regiões homogêneas (HE; HUANG, 2012).

Com a abordagem de detecção de bordas e depois fusão de regiões, este algoritmo divide a imagem em regiões (objetos) O_i para depois fundir regiões conexas, quando o valor do custo de fusão (c) superar um limite estabelecido, o parâmetro de escala λ_{limite}

O valor que é calculado para o custo da fusão considera variáveis espectrais e espaciais, sendo o custo maior quanto mais heterogêneos e maiores foram os segmentos,

e menor quanto maior for a fronteira entre estes segmentos. Desta forma, segmentos que possuem menor diferença espectral e áreas menores serão mais fáceis de fundir, conforme pode ser observado na equação (3):

$$c(O_i, O_j) = \frac{|O_i| |O_j|}{|O_i| + |O_j|} \frac{\|u_i - u_j\|^2}{l(\delta(O_i, O_j))} \quad (3)$$

em que:

- $c(O_i, O_j)$ = custo de fusão para unir as regiões conexas O_i e O_j ;
- $|O_i|$ = área da região i da imagem e $|O_j|$ = área da região j da imagem;
- u_i = valor espectral médio da região i e u_j = valor espectral médio da região j ;
- $\|u_i - u_j\|^2$ = distância euclidiana entre os valores espectrais das regiões i e j ;
- $\delta(O_i, O_j)$ = comprimento da fronteira entre O_i e O_j .

O algoritmo irá percorrer todas as vizinhanças do segmento, e aquela que obter menor custo (λ -*schedule*) sendo representada por $0 < \lambda_1 < \lambda_2 < \lambda_3 < \dots < \lambda_n$, será realizada a fusão. Este procedimento é realizado até o momento que toda a vizinhança possua custo superior que o parâmetro escala limite $c(O_i, O_j) < \lambda_{limite}$ (KOEPLER; LOPES; MOREL, 1994). As técnicas de segmentação, como simples pré-classificação, desenvolveram-se e culminaram na segmentação multiresolução e na análise orientada a objetos geográficos, a qual é apresentada a seguir.

2.3 ANÁLISE DE IMAGENS BASEADA EM OBJETOS GEOGRÁFICOS

Segundo Blaschke (2010) o paradigma baseado a pixel pode ser base para milhares de aplicações bem sucedidas em SR. No entanto, ele tem limitações em relação à escala relativa, contexto e transições difusas ou lisas. A partir do ano 2000, com o lançamento de sensores de alta resolução espacial e a disseminação de fontes de dados digitais para aumentar dados detalhados por satélite, houve forte aumento no uso de técnicas de segmentação de imagens e crescente uso do termo "análise orientada a objetos".

Blaschke, Lang e Hay (2008) comentam que o termo OBIA (Object Based Image Analysis) é utilizado em muitas disciplinas diferentes (Biomedicina, Astronomia, Visão computacional, etc.), então o termo GEOBIA com prefixo "geo" enfatiza o componente geográfico como foco principal em SR e SIG.

Procedimentos de classificação baseada a pixel apresenta dificuldades com reconhecimento automático de padrões, principalmente pela variabilidade fenológica das culturas ou diferentes sistemas de cultivo. Neste contexto, a GEOBIA parece promissora para ser utilizada (VIEIRA *et al.*, 2012).

Com imagens de baixa resolução espacial é frequente o uso da análise baseada na assinatura do pixel (*pixel - based method*). Já em imagens de média e alta resolução, a GEOBIA tem sido sugerida na literatura como a mais indicada, já que é possível obter não só as características espectrais dos alvos bem como suas variantes geométricas, topológicas e de textura.

A GEOBIA utiliza dos dados do SR e gera saídas prontas, banco de dados relacional para SIGs. Representa uma "ponte" entre o domínio raster (imagem) do SR e o domínio vetor do SIG. A "ponte" é a geração dos segmentos, representando os objetos geográficos (BLASCHKE; LANG; HAY, 2008).

Segundo Assad e Sano (1998), a GEOBIA prepara as imagens de satélite para uma futura classificação temática em nível de segmentos, ou orientação a objetos, em que os elementos analisados e utilizados na classificação são as regiões do agrupamento de pixels, especialmente próximos e com características espectrais similares.

Destaca-se que, o termo objeto caracteriza-se como peça chave neste tipo de análise, visto que a interpretação da imagem não está inserida no pixel e sim no objeto, produzido sobre a imagem, que pode ser segmentos ou polígonos. As feições do terreno também podem ser chamadas de objetos pois podem ser reconhecidos no domínio da imagem. Assim, a GEOBIA utiliza os mesmos princípios de segmentação de imagens em PDI para gerar os objetos ou polígonos.

Não há um método comum de segmentação que pode ser utilizado para as imagens, pois há diversidade nas técnicas de PDI e também depende muito do objetivo proposto pelo analista. Portanto, é necessário ter conhecimento prévio sobre a imagem e assim realizar a GEOBIA de acordo com seu objetivo de estudo.

De acordo com Robinson, Redding e Crisp (2002), a principal tarefa da segmentação de imagens é realizar a extração de objetos de interesse conforme tarefa determinada. A escala e critérios de semelhança controlam o resultado da segmentação, criando objetos maiores ou menores, homogêneos ou não homogêneos, ou ainda, suavizados ou não. A escolha do parâmetro escala e critérios de semelhança estão relacionados com as resoluções espacial e espectral da imagem.

Neste sentido, a GEOBIA surgiu para otimizar a tradicional interpretação visual, restando apenas para o analista a associação dos polígonos gerados pelo segmentador com suas respectivas classes temáticas. Após finalizado o processo de GEOBIA é obtido um banco de dados contendo os descritores para cada segmento (objeto). Estes descritores são espaciais, espectrais e de textura, discriminados a seguir.

No estudo utiliza-se o método baseado em segmentos, isto é, GEOBIA, e é pertinente a explicação sobre os descritores gerados na segmentação e alocados no banco de dados relacional. Esta explicação está presente nas subseções 2.3.1, 2.3.2 e 2.3.3.

2.3.1 Descritores Espectrais

A caracterização espectral de um alvo, também conhecida como assinatura espectral, é a representação gráfica da reflectância em faixas de comprimento de onda bem estreitas e adjacentes. Ela representa de forma detalhada o resultado da interação da energia radiante com o objeto em estudo. As variações de amplitude na caracterização espectral são indicadoras das propriedades espectrais dos objetos (STEFFEN; MORAES, 1993).

Os descritores espectrais são calculados em cada banda da imagem de entrada e estão relacionados às características dos pixels que estão dispostos no segmento (FACON, 2002). Estas características são chamadas de descritores, e são detalhados a seguir (ITT VIS (VISUAL INFORMATION SOLUTIONS), 2008):

- **Média dos valores digitais (AVGBAND):** corresponde ao valor médio dos pixels de um objeto compreendidos em cada banda;
- **Desvio padrão dos valores digitais (STDBAND):** corresponde ao desvio padrão da média dos valores digitais dos pixels de um objeto em cada banda;
- **Valor Máximo de pixel (MAXBAND):** corresponde ao maior valor digital observado nos pixels do objeto em cada banda;
- **Valor Mínimo de pixel (MINBAND):** corresponde ao menor valor digital observado nos pixels do objeto em cada banda;
- **Razão entre bandas (BANDRATIO):** corresponde em um valor determinado pela razão dos valores digitais de duas bandas espectrais. Este valor digital descreverá o objeto, conforme equação (31):

$$NDVI = \frac{AVGBAND(IRn) - AVGBAND(R)}{AVGBAND(IRn) + AVGBAND(R) + eps} \quad (4)$$

- **Matiz ou Tonalidade (HUE):** corresponde a matiz ou tonalidade do sistema de cores HSI (Hue, Saturation, Intensity) que descreve o objeto;
- **Saturação (SATURATION):** corresponde a saturação do sistema de cores HSI que descreve o objeto;
- **Intensidade (INTENSITY):** corresponde a intensidade do sistema de cores HSI que descreve o objeto.

2.3.2 Descritores de Textura

Com o intuito de mensurar a textura de um segmento da imagem é analisado a distribuição ou frequência de níveis digitais dentro deste. Conforme Sonka, Hlavac e Boyle (1998) a textura refere-se a propriedades referentes às superfícies ou estruturas dos objetos, tais como suavidade, rugosidade e regularidade. Segundo Facon (2002) a segmentação por textura deve permitir a colocação em evidência dos motivos da imagem considerando as propriedades de regularidade e de repetição. Em GEOBIA, o valor da textura é calculado para o pixel central de uma matriz quadrada móvel (se desloca na imagem) de tamanho $n \times n$ chamado de *kernel*, em que o valor do nível digital central é modificado em função dos pixels compreendidos na janela. São detalhados os descritores de textura a seguir (ITT VIS (VISUAL INFORMATION SOLUTIONS), 2008):

- **Intervalo de textura (TX-RANGE):** corresponde ao intervalo de valores dos pixels compreendidos dentro da janela;
- **Textura média (TX-MEAN):** corresponde à media dos valores dos pixels compreendidos dentro da janela;
- **Variância da textura (TX-VARIANC):** corresponde à variância dos valores dos pixels compreendidos dentro da janela;
- **Entropia da textura (TX-ENTROPY):** corresponde ao valor médio da entropia¹ dos valores dos pixels compreendidos dentro da janela.

¹A entropia pode ser definida como um número quantificador da randomicidade da imagem, ou seja, quanto maior for este número, mais irregular, atípica ou despadronizada será a imagem analisada.

2.3.3 Descritores Espaciais

Os descritores espaciais podem ser considerados como uma expressão do contorno dos objetos. Objetos formados por culturas ou construções observadas na paisagem urbana, normalmente tendem a apresentar formas regulares, enquanto feições naturais tendem a apresentar formas irregulares (GARCIA, 1982). Para discriminar feições que possuem a mesma aparência espectral, a análise de forma e tamanho apresenta-se como processo relevante. Desta forma, para analisar a forma é necessário conhecer os limites do objetos, até então desconhecidos. Este processo pode ser obtido a partir da etapa de segmentação.

Em GEOBIA, os descritores espaciais são calculados a partir da forma do objeto (polígono) que define o limite do conjunto de pixels. São definidos os descritores espaciais contemplados no ENVI EX a seguir (ITT VIS (VISUAL INFORMATION SOLUTIONS), 2008):

- **Área (ÁREA):** é o valor da área do polígono, em unidade de mapa. Caso o segmento possua um furo, esta área será descontada;
- **Comprimento (LENGHT):** é o valor do comprimento dos limites de cada segmento, somados os perímetros de possíveis furos que estejam dentro deste segmento;
- **Compacidade (COMPACT):** valor que indica quão compacto é o segmento, calculado pela equação (5):

$$Compacidade = \frac{\sqrt{4 \times \frac{Área}{\pi}}}{Perimetro} \quad (5)$$

- **Convexidade (CONVEXITY):** corresponde quanto um polígono pode ser dito convexo ou côncavo. Para um polígono convexo sem furos o valor da convexidade é 1, já para polígonos côncavos é menor que 1. Ou seja, em um polígono convexo, unindo-se quaisquer dois de seus pontos, o segmento de reta obtido está sempre contido no polígono. Já em um polígono Côncavo existem pelo menos dois pontos que unidos formam um segmento de reta que não se encontra contido no polígono. Segue a equação (6):

$$Convexidade = \frac{ComprimentoFechoConvexo}{Comprimento(Lenght)} \quad (6)$$

- **Solidez (SOLIDIT):** compara a área do polígono com a área do fecho convexo no entorno do polígono. O valor de solidez para um polígono convexo, sem furos, é 1, e para um polígono côncavo é menor que 1. Segue a equação (7):

$$Solidez = \frac{\textit{ÁreaPoligono}}{\textit{ÁreaFechoConvexo}} \quad (7)$$

- **Redondeza (ROUNDNESS):** compara a área do polígono com o quadrado do diâmetro máximo do polígono. O diâmetro máximo é o comprimento do eixo maior de uma caixa envolvente em torno do polígono. O valor da redondeza para um círculo é 1. Segue a equação (8):

$$Redondeza = \frac{4 \times \textit{Área}}{\pi \times (\textit{EixoMaior})^2} \quad (8)$$

- **Fator de forma (FORMFACTOR):** compara a área do polígono com o quadrado do seu perímetro. O valor do fator forma para um círculo é 1. Segue a equação (9):

$$FatorDeForma = \frac{4 \times \textit{Área}}{(\textit{Perimetro})^2} \quad (9)$$

- **Alongamento (ELONGATION):** resulta na razão entre o eixo maior e menor do polígono. Tais eixos são obtidos a partir de uma caixa envolvente em torno do polígono. Para um quadrado o valor é 1 e para um retângulo é maior que 1. Segue a equação (10):

$$Alongamento = \frac{\textit{EixoMaior}}{\textit{EixoMenor}} \quad (10)$$

- **Retangularidade (RECT_FIT):** se refere ao quanto um polígono se aproxima da forma retangular, pela comparação da área do polígono com a área de uma caixa envolvente ao polígono. Para um retângulo o valor é 1 e para uma forma não retangular é menor que 1. Segue a equação (11):

$$Retangularidade = \frac{\textit{Área}}{\textit{EixoMaior} \times \textit{EixoMenor}} \quad (11)$$

- **Direção Principal (MAINDIR):** indicará a direção, em graus, do eixo maior do polígono em relação ao eixo x. Os valores variam de 0 a 180 graus.
- **Eixo Maior (MAJAXISLEN):** o comprimento do eixo maior de uma caixa envolvente em torno do polígono. O valor é baseado no tamanho do pixel no terreno, no caso da imagem ser georreferenciada. Caso não seja, o valor é dado em pixels.
- **Eixo menor (MINAXISLEN):** o comprimento do eixo menor de uma caixa envolvente em torno do polígono.

- **Número de furos (NUMHOLES):** representa o número de furos inseridos no polígono.
- **Relação área/furos (HOLESOLRAT):** é a razão entre a área do polígono e a área de contorno. Caso o polígono não possua furos o valor é 1, senão é calculado pela equação (12):

$$RelaçãoÁrea/Furos = \frac{ÁreaTotalPoligono}{ÁreaContorno} \quad (12)$$

Conforme os objetivos desta pesquisa, é essencial o conhecimento desses descritores (espaciais, espectrais e textura), uma vez que os descritores espectrais permitem trabalhar com as diferenças espectrais existentes dentro de um objeto ou feição do terreno. Já os descritores espaciais e de textura permitem melhorar a classificação automática da imagem. Entretanto, a quantidade destes gerados na segmentação é grande, podendo dados redundantes interferir negativamente no processo de classificação. Assim, optou-se pela Análise de Componentes Principais (ACP) no que tange a seleção de descritores.

2.4 ANÁLISE DE COMPONENTES PRINCIPAIS

A ACP é parte de métodos estatísticos, mais especificamente, multivariados. Estes métodos foram desenvolvidos com o objetivo de realizar análise em medidas simultâneas em muitas variáveis, conhecida como análise multivariada de dados (JOHNSON; WICHERN, 2007).

Os principais objetivos conforme Johnson e Wichern (2007) em se utilizar análise multivariada de dados são:

- Redução de dados, porém sem perda significativa do valor da informação;
- Ordenação e agrupamento: grupos de objetos ou variáveis com características similares são criados;
- Investigação das dependências entre as variáveis, e se existem, como elas são;
- Criação e teste de hipóteses: hipóteses estatísticas formuladas em função de uma população de parâmetros multivariados são testados, com o objetivo de validar suposições ou reforçar convicções anteriores;
- Previsão: a relação das variáveis é estudada a fim de prever os valores de uma ou mais variáveis observadas.

Assim, a ACP contempla os 4 primeiros objetivos supracitados. A ACP é considerada a técnica mais antiga e conhecida de análise multivariada (JOLLIFFE, 1986), foi introduzida primeiro por Pearson em 1901 e desenvolvida independentemente por Hotelling em 1933. A idéia central da ACP é reduzir a dimensionalidade dos dados que contém grande número de variáveis do conjunto correlacionadas. A ACP trata-se de uma técnica estatística multivariada com o objetivo de condensar a informação contida de conjunto de variáveis originais em um novo conjunto de variáveis estatísticas, sem perda de informação significativa. Assim, há interesse na melhor combinação linear de variáveis, no sentido de que a primeira componente é o melhor resumo de relações lineares exibidas nos dados. A segunda componente é obtida a partir da variância inexplicada após o efeito da remoção da primeira componente dos dados. O processo se repete extraindo componentes que explicam quantias cada vez menores de variância até que toda variância seja explicada (HAIR *et al.*, 2009).

2.4.1 Desenvolvimento matemático

A ACP consiste em uma transformação de coordenadas de um conjunto de variáveis originais correlacionadas em um novo sistema de variáveis descorrelacionadas, denominadas Componentes Principais (CPs). Cada componente é formada a partir de uma combinação linear das variáveis originais.

Para aplicação do método ACP, primeiro passo é o cálculo da matriz de covariância C , conforme a equação (13). Cada elemento desta matriz representa a covariância $s^2(x_i, x_j)$ entre duas coordenadas do vetor x (JR; COSTA, 2007):

$$s^2(x_i, x_j) = \sum_{n=1}^N x_i[n] x_j[n] - \frac{\sum_{n=1}^N x_i[n] \sum_{n=1}^N x_j[n]}{N} \quad (13)$$

em que x_i e x_j são coordenadas do vetor x e N é o número de exemplos apresentados.

Para Jolliffe (1986) a ACP depende unicamente da matriz de variância-covariância $x_1, x_2, \dots, x_p$. Seja um vetor $x' = \{x_1, x_2, \dots, x_p\}$ tem a matriz de variância-covariância Σ com autovalores $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$.

Desta modo, obtém-se em (14):

$$\begin{aligned} Var(\gamma_i) &= a_i' \sum a_i & i &= 1, 2, \dots, p \\ Cov(\gamma_i) &= a_i' \sum a_i k & i, k &= 1, 2, \dots, p \end{aligned} \quad (14)$$

O segundo passo é a determinação dos autovetores v_n de C . Os autovetores formam as colunas de uma matriz P conforme em (15):

$$P = \{v_1, v_2, \dots, v_n\} \quad (15)$$

Os elementos dos autovetores, chamados de *loadings* na terminologia ACP, representam a contribuição de cada um dos eixos originais na composição dos novos eixos. Já os autovalores representam a quantidade de variância original de seus respectivos autovetores, então chamados de *scores*.

Desta forma, o novo conjunto de dados, as CPs, se tornam descorrelacionados, e são ordenados de forma que a primeira componente retém a maior variação presente em todas as variáveis originais (JOLLIFFE, 1986).

Assim, a ACP é aplicada no estudo, para reduzir a dimensionalidade do dados, e selecionar variáveis a serem utilizadas no processo de classificação digital da imagem orbital. A etapa de seleção de variáveis é detalhada em Procedimentos Metodológicos na seção 4.3. Na próxima seção, a classificação de imagens digitais é abordada, uma vez que este é o assunto crucial do estudo, o qual definirá as classes de uso e cobertura da terra.

2.5 CLASSIFICAÇÃO DE IMAGENS DIGITAIS

A classificação de uma imagem passa necessariamente por um processo de interpretação, também conhecido por reconhecimento de padrões. Esta é uma tarefa inerente ao ser humano, que inconscientemente, no momento que visualiza uma imagem qualquer procura entender quais informações estão nela presentes.

Com o intuito de realizar o reconhecimento de padrões, que inclui o reconhecimento de objetos na superfície terrestre de imagens digitais, é indicada a técnica de Classificação de Imagens Digitais. Nesta técnica, cada pixel ou região da imagem é associado a uma classe que descreve algum tipo de cobertura e uso da terra, como agricultura, reflorestamento, vegetação, tipos de solos, área urbana, dentre outros.

Com o novo paradigma de GEOBIA, comumente é realizada a Classificação Orientada a Objeto, com base nos segmentos gerados pela técnica, com as características espaciais, espectrais e de textura. Neste estudo, o método de classificação escolhido apenas utilizará a base de dados dos objetos gerados pela segmentação mediante GEOBIA, que serão os padrões a serem reconhecidos (classificados).

Cada região da imagem que será associada a uma classe é chamado de padrão. Um padrão é um arranjo de descritores e uma classe de padrões é uma família de padrões que compartilham algumas propriedades comuns. O reconhecimento de padrões por máquina envolve técnicas de atribuição de padrões às suas respectivas classes, de forma automática e com a menor intervenção humana possível (GONZALEZ; WOODS, 2000).

Segundo Tso e Mather (2009), um padrão é um vetor de características que descreve um objeto, e o principal objetivo do reconhecimento de padrões é estabelecer o relacionamento entre o objeto e uma classe (categoria). O objeto pode ser um pixel sozinho ou um conjunto de pixels adjacentes formando uma entidade geográfica que irá ser associado a uma classe. Os rótulos das classes podem ser conhecidos ou desconhecidos. Em caso de conhecidos, o investigador pode determinar o número de categorias presentes na área de estudo, e em caso de desconhecidos, o investigador pode determinar categorias separadas, sem relação com a área de estudo, para o reconhecimento dos padrões da imagem. Estes dois métodos de determinação de rótulos são conhecidos como abordagem supervisionada ou não supervisionada, respectivamente.

Na abordagem supervisionada, segundo Lillesand, Kiefer e Chipman (2007) e Tso e Mather (2009), é necessário que o usuário colete amostras para treinar ou ensinar o classificador, ou seja, deve supervisionar o processo de categorização do pixel, especificando para o algoritmo do computador, atributos numéricos dos descritores espectrais de cada tipo de cobertura do solo de interesse na cena, que contêm os descritores de cada feição de interesse. Cada pixel no conjunto de dados não utilizado para treinamento é comparado com esses descritores e então classificado com o nome da classe que mais se assemelha.

Na abordagem não-supervisionada, os autores supracitados explicam que não são utilizados dados de formação, é um processo independente da interação com o usuário como na classificação supervisionada. Assim, os classificadores envolvem algoritmos que examinam os pixels desconhecidos da imagem e os agregam a várias classes. A ideia básica define que os valores semelhantes dentro de um tipo de cobertura do solo devem ser aproximados no espaço, e os dados de classes diferentes devem ser comparativamente separados, no processo de classificação.

Para Centeno (2004) na classificação não-supervisionada, o usuário define algumas características como a quantidade de classes, as bandas analisadas, o tamanho mínimo dos grupos. Os algoritmos de classificação não-supervisionada analisam os pixels ou regiões e os dividem em agrupamentos predominantes na imagem. Posteriormente, o analista pode classificar esses agrupamentos como classes de cobertura do solo, seja por meio de

conhecimento prévio da área ou através de visitas para verdade de campo.

Entre os algoritmos de classificação não-supervisionada mais conhecidos são o K-means e o ISODATA que podem ser consultados em Richards e Jia (2006).

Nesse contexto, considera-se que, os métodos de classificação não-supervisionados são menos subjetivos que os métodos supervisionados, visto que não existe interação com o usuário, operando independente e automaticamente. No entanto, é necessário ter conhecimento que os resultados podem ser aceitos ou rejeitados, com acurácia inferior aos métodos supervisionados, considerando-se a complexidade da área de estudo, a experiência do intérprete, a técnica utilizada para a classificação e os dados de entrada. Em se tratando de avaliação da acuracidade, para a validação dos resultados da classificação pode-se realizar a matriz de confusão e índice kappa ou ainda, testes estatísticos de significância. Maiores detalhes sobre a validação e análise dos resultados estão apresentados na seção 4 em Procedimentos Metodológicos.

Na seção 2.6, é feita a abordagem sobre RNA quando da utilização desta técnica para reconhecimento de padrões de uso e cobertura da terra.

2.6 REDES NEURAIS ARTIFICIAIS

As RNAs são um instrumento desenvolvido na década de 40 por Pitts e McCulloch, o primeiro matemático e o segundo neurofisiologista. A ideia era fazer uma analogia entre os neurônios biológicos e circuitos eletrônicos, capazes de simular conexões sinápticas pelo uso de resistores variáveis e amplificadores (JR; COSTA, 2007).


Conforme definição de Teuvo Kohonen, uma RNA "é uma rede massivamente paralela interconectada de elementos e suas organizações hierárquicas que estão intencionadas para interagir com objetos do mundo real do mesmo modo que um sistema biológico faz" (TAFNER; XEREZ; FILHO, 1995).

Para compreender o funcionamento das RNAs é de suma importância definir alguns conceitos básicos deste método.

2.6.1 Neurônios biológicos

Um neurônio é a unidade de processamento fundamental para o funcionamento de uma RNA. A figura 2 mostra o modelo de um neurônio, que forma a base para o projeto de RNA, conforme descrito em Haykin (2001).

Figura 2: Modelo não-linear de um neurônio



Fonte: Adaptado de Haykin (2001)

1. Um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . É importante notar a maneira como são escritos os índices do peso sináptico w_{kj} ;
2. Um somador para os sinais de entrada, ponderado pelas respectivas sinapses do neurônio;
3. Uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

A inteligência requer conhecimento, desta forma, a fim resolver problemas, no caso por técnicas que utilizem RNAs, é necessário encontrar estruturas adequadas para expressar o tipo de conhecimento da aplicação, que facilitem a resolução do problema em questão.

• Representação do conhecimento

Seguindo a definição genérica de Fischler e Firschein (1987), o conhecimento se refere à informação armazenada ou a modelos utilizados por uma pessoa ou máquina para interpretar, prever e responder apropriadamente ao mundo exterior.

São duas as principais características da representação do conhecimento: (1) que informação é realmente tornada explícita; e (2) como a informação é codificada fisicamente

para o uso subsequente. Portanto, a representação do conhecimento é direcionada a um objetivo. Tipicamente, as formas possíveis de representação desde as entradas até os parâmetros internos da rede são muito diversificadas, o que tende a tornar o desenvolvimento de uma solução satisfatória utilizando uma rede neural um desafio real de projeto.

O conhecimento acumulado em uma máquina pode assumir contexto declarativo ou procedimental. Em uma representação declarativa o conhecimento é armazenado na forma de coleção de fatos e relações entre fatos, os quais são manipulados por algum tipo de motor de inferência. A representação é procedimental, quando o conhecimento é acumulado na forma de um conjunto de ações ou comandos que, encadeados, apresentam um significado específico. As duas formas de conhecimento são necessárias na maioria dos domínios de problemas de interesse. Neste contexto, a representação declarativa é a qual será utilizada nesta pesquisa.

- **Função de ativação e de transferência**

A função de ativação antecede a função de transferência, e tem por atribuição, repassar o sinal para a saída do neurônio. É uma função de ordem interna, cuja atribuição é fazer acontecer um nível de ativação dentro do próprio neurônio, ou seja, é uma decisão tomada pelo neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas (TAFNER; XEREZ; FILHO, 1995).

A função de transferência pode ter muitas formas e métodos, podendo ser simples ou complexa. Esta função é que define e que envia para fora do neurônio o valor passado pela função de ativação (TAFNER; XEREZ; FILHO, 1995).

O tipo de conexão, de treinamento bem como o número de camadas de neurônios são configurações que fazem a diferenciação entre os tipos de RNAs. A escolha depende da tarefa a ser realizada. Os diferentes tipos de conexões entre neurônios determinam a topologia (arquitetura) da rede.


2.6.2 Arquitetura da rede

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Em geral, são identificados duas classes de arquiteturas de rede fundamentalmente diferentes (HAYKIN, 2001), explicitadas nas próximas subseções a seguir.

2.6.2.1 Redes com Camada Única

Em uma rede neural em camadas, os neurônios estão organizados na forma de camadas. Na forma mais simples de uma rede de camadas, tem-se uma camada de entrada de neurônios de entrada que se projeta sobre uma camada de saída de neurônios, mas não vice-versa. Ela é ilustrada na figura 3 para o caso de quatro nós tanto na camada de entrada como na de saída. Esta rede é chamada de rede de camada única, sendo que a designação “camada única” se refere à camada de saída de nós computacionais (neurônios).

Figura 3: Rede alimentada adiante ou acíclica com uma única camada de neurônios



Fonte: Haykin (2001)

2.6.2.2 Redes com Múltiplas Camadas


Esta rede distingue-se pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas. Adicionando-se uma ou mais camadas ocultas, torna-se a rede capaz de extrair estatísticas de ordem elevada. A habilidade dos neurônios ocultos extraírem estatísticas de ordem é particularmente valiosa quando o tamanho da camada de entrada é grande.

Os nós de entrada, como mostrado na figura 4, da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem os sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada. Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante para o resto da rede.

O grafo arquitetural da figura 4 ilustra a planta de uma rede neural de múltiplas camadas para o caso de uma única camada oculta. Por concisão, esta rede é referida como uma rede 10-4-2 porque tem os 10 neurônios de entrada, 4 neurônios ocultos e 2 neurônios de saída.

A rede neural da figura 4 é dita totalmente conectada, no sentido de que cada um dos nós de uma camada da rede está conectado a todos os nós da camada adjacente seguinte.

Figura 4: Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída



Fonte: Haykin (2001)

• Treinamento

O processo de treinamento consiste no ajuste de pesos das conexões entre os neurônios, em que a base de dados é apresentada à RNA diversas vezes até que satisfaça uma condição determinada pelo analista. Desta forma, a RNA é otimizada no processo de aprendizado.

A escolha do algoritmo de aprendizado para treinamento é conforme o tipo de RNA a ser utilizada bem como os dados que serão ajustados. Assim, os parâmetros de treinamento devem ser definidos criteriosamente a fim de obter o resultado satisfatório. Assim, o algoritmo escolhido para o estudo, sendo SOM, está detalhado na subseção 2.6.3, o qual abrange o seu funcionamento, bem como os processos de aprendizado.

2.6.3 SELF-ORGANIZING MAPS

O princípio do desenvolvimento da rede SOM é motivado por uma característica do cérebro humano, o qual consegue organizar informações em regiões, de maneira que as entradas sejam representadas por mapas topologicamente ordenados. Desta forma, os resultados de aprendizagem por meio de respostas sensoriais retomam ao encontrado no cérebro humano, o que constitui justificativa suficiente para os mapas serem chamados de redes neurais.

O processo de aprendizagem funciona de maneira competitiva, preservando a topologia de auto-organização. Os neurônios são colocados em nós de uma grade uni ou bidimensional e se tornam seletivamente sintonizados aos padrões de entrada no decorrer do processo de aprendizagem. As localizações destes neurônios sintonizados se tornam ordenadas entre si, criando sobre a grade um sistema de coordenadas para diferentes características de entrada (HAYKIN, 2001).

Os neurônios da grade são completamente conectados com todos os neurônios da camada de entrada. Os padrões de entrada são apresentados à rede, os neurônios da grade competem entre si para serem ativados, sendo que apenas um neurônio de saída será considerado o "vencedor". Será considerado vencedor o neurônio que é mais semelhante ao padrão de entrada. Todos os neurônios devem ser expostos a um número suficiente de diferentes padrões de entrada, garantindo apropriado processo de auto-organização.

A rede possui duas camadas de neurônios conectados por pesos. A camada de entrada é conectada a um vetor de todo o conjunto de dados, e a camada de saída forma o mapa ordenado em forma de grade onde são dispostos vários neurônios.


Por ser uma rede não-paramétrica, Lu *et al.* (2011) enfatiza que este tipo de rede muitas vezes exige mais tempo para otimizar os parâmetros utilizados em um algoritmo específico, e os resultados dependem dos parâmetros identificados e dos conjuntos de dados utilizados.

O algoritmo responsável pela organização da rede inicia o processo arbitrando pequenos valores aleatórios aos pesos sinápticos, para que nenhuma organização prévia seja imposta ao mapa. Em seguida dar-se-ão os processos de competição, cooperação e adaptação conforme descritos em Jr e Costa (2007) e Haykin (2001). Na subseção 2.6.3.1 é apresentado o fluxograma do algoritmo da RNA SOM, bem como maiores detalhes sobre o funcionamento dos processos de treinamento.

2.6.3.1 Funcionamento do Algoritmo de Treinamento

A seguir é apresentado o funcionamento do algoritmo de treinamento da SOM conforme Chon *et al.* (1996). O fluxograma apresentado na figura 5 explicita as etapas de treinamento.

Figura 5: Fluxograma do algoritmo de treinamento da SOM



Fonte: A autora

Estes passos descrevem:

1. No início são declarados os dados de entrada:
 - Iniciar a taxa de aprendizagem;

- Iniciar o raio de vizinhança;
 - Informar o número máximo de épocas a serem executadas;
 - Inicializar a matriz de pesos.
2. Para o critério de parada é considerado:
- Comparar o número de épocas e a alteração da matriz de pesos.
3. A fase de treinamento é dada por:
- Para cada vetor x_i :
- (a) Fase Competitiva:
- Calcular as distâncias de cada vetor de entrada (linhas) com todas as colunas de matriz de pesos;
 - Encontrar o índice j tal que a distância seja a menor (neurônio vencedor).
- (b) Fase Cooperativa:
- É realizada em todas as colunas da matriz de pesos;
 - Localiza os vizinhos do neurônio vencedor conforme o raio de vizinhança.
- (c) Fase Adaptativa:
- Atualizar toda a matriz de pesos.
 - Isto é realizado para todos os vetores de entrada.
4. Em Atualização é necessário:
- Atualizar a taxa de aprendizagem;
 - Atualizar o raio de vizinhança.

A seguir, são detalhados os processos competitivo, cooperativo e adaptativo da etapa de treinamento.

• Processo Competitivo

1. Considera-se um vetor de entrada, representado por $x_i = [x_1, x_2, \dots, x_n]^T$ sendo este vetor, um dos exemplos de treinamento, apresentado à rede sem que se especifique a saída desejada. O neurônio y que melhor responda a esta entrada, será o neurônio vencedor. O critério para a escolha do neurônio vencedor pode se basear em qualquer

métrica que informe a distância entre o vetor de entrada e o vetor de pesos dos neurônios, e geralmente é utilizada a Distância Euclidiana. Assim, o neurônio que apresenta a menor distância entre o vetor de entrada e o seu vetor de pesos é o vencedor.

2. Considera-se que o vetor $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ represente os valores dos pesos sinápticos de um neurônio i no instante t e o vetor $x_i = [x_1, x_2, \dots, x_n]^T$ represente um exemplo de treinamento apresentado à rede no mesmo instante t , a Distância Euclidiana entre w_{ij} e x , será dada pela equação (16):

$$d_i(t) = a_0 + \sum_{j=1}^N x_j(t) - w_{ij}(t)^2 \quad (16)$$

em que:

- $d_i(t)$ = Distância Euclidiana entre o vetor de pesos do neurônio i e o vetor de entrada, na iteração t ;
- i = índice do neurônio;
- j = índice do nó de entrada;
- N = número de sinais de entrada (números de dimensões do vetor x);
- $x_j(t)$ = sinal de entrada do nó j na iteração t ;
- $w_{ij}(t)$ = valor do peso sináptico entre o nó de entrada j e o neurônio i na iteração t .

A equação (16) resume a essência do processo de competição entre os neurônios.

• Processo Cooperativo

O processo cooperativo estabelece que o neurônio vencedor representado na grade, irá determinar o centro da vizinhança topológica de neurônios cooperativos. Assim, um neurônio considerado vencedor, tende a excitar mais os neurônios que estão dentro do seu raio de vizinhança do que aqueles neurônios que estão mais distantes.

Seja h_{ij} a vizinhança topológica centrada no neurônio vencedor i que contenha um conjunto de neurônios excitados, e um neurônio típico é denotado por j . Considere d_{ij} a distância lateral entre o neurônio vencedor i e o neurônio excitado j . Pode-se então assumir que a vizinhança topológica h_{ij} é uma função unimodal da distância lateral d_{ij} , tal que satisfaça duas exigências distintas:

1. A vizinhança topológica h_{ij} é simétrica ao redor do ponto máximo definido por $d_{ij} = 0$, ou seja, atinge seu valor máximo no neurônio vencedor i , para o qual a distância d_{ij} é zero.
2. A amplitude da vizinhança topológica h_{ij} decresce monotonicamente com o aumento da distância lateral d_{ij} , decaindo a zero para $d_{ij} \rightarrow \infty$; condição necessária para convergência.

As funções (17), (18), (19) e (20) satisfazem as exigências para a vizinhança topológica h_{ij} e são apresentadas graficamente na Figura 6 (VESANTO *et al.*, 2000):

$$h_{ji}(t) = (\sigma_t - d_{ji}) \quad (17)$$

$$h_{ji}(t) = e^{\frac{-d_{ji}^2}{2\sigma_t^2}} \quad (18)$$

$$h_{ji}(t) = e^{\frac{-d_{ji}^2}{2\sigma_t^2}} (\sigma_t - d_{ji}) \quad (19)$$

$$h_{ji}(t) = \text{Max} \{0, 1 - (\sigma_t - d_{ji})^2\} \quad (20)$$


onde:

- σ_t é o raio da vizinhança topológica no tempo t ;
- t representa o número de iterações, e mede o grau com que os neurônios excitados e vizinhos do neurônio vencedor, participam do processo de aprendizagem.

Para que a cooperação entre os neurônios seja mantida, é necessário que a vizinhança topológica h_{ji} seja dependente da distância lateral d_{ji} entre o neurônio vencedor i e o neurônio excitado j no espaço de saída. Isto foi representado na equação (19), no caso de grade unidimensional.

Por outro lado, no caso de uma grade bidimensional, ela é definida por $d_{ji}^2 = |r_j - r_i|^2$, em que o vetor discreto r_j define a posição do neurônio excitado j e r_i define a posição discreta do neurônio vencedor i .

Figura 6: Diferentes funções de vizinhança



Fonte: Vesanto et al., 2000

A mais utilizada é a função de vizinhança gaussiana, conforme equação (19) , a qual é invariante à translação, isto é, independente da localização do neurônio vencedor. Ela mede o grau com o qual os neurônios excitados na vizinhança do neurônio vencedor participam do processo de aprendizagem.

O parâmetro σ_t , raio de vizinhança, deve diminuir com o passar do tempo, o que implica em valores de h_{ji} menores ao longo do tempo, caracterizando uma vizinhança mais restrita, e, portanto, mais especializada. O valor de σ_t (t representa o número de iterações) é, normalmente, uma função exponencial conforme a equação (21) (JR; COSTA, 2007):

$$\sigma_t = \sigma_{t_0} \cdot e^{\frac{-t}{t_1}} \quad (21)$$

• Processo Adaptativo

Da mesma forma que as demais RNAs, para que o aprendizado de um mapa auto-organizável seja efetivado, é necessário realizar o ajuste de pesos sinápticos. No postulado de Hebb, um peso sináptico é aumentado quando há ocorrência simultânea de atividades pré e pós sinápticas.

Para este tipo de aprendizado não-supervisionado, entretanto, a hipótese de Hebb em sua forma básica é insatisfatória pela seguinte razão: mudanças nas conectividades ocorrem em apenas uma direção, o que acabaria por levar todos os pesos sinápticos à saturação.

Com o propósito de superar esta dificuldade, a hipótese de Hebb é modificada incluindo um "termo de esquecimento", dado por $g(y_j)w_{ij}$, em que w_{ij} é o vetor peso sináptico do neurônio j e $g(y_j)$ é uma função escalar positiva da resposta y_j , de modo que

pode-se escrever em (22):

$$g(y_j) = 0 \quad (22)$$

Dada esta função, pode-se expressar a atualização do vetor peso do neurônio j da grade como segue a equação (23):

$$\Delta w_{ij} = \eta y_j - g(y_j) w_{ij} \quad (23)$$

onde $\eta(t)$ é o parâmetro da taxa de aprendizagem do algoritmo. O primeiro termo do lado direito da equação (23) é o termo hebbiano e o segundo é o "termo do esquecimento". Para satisfazer a exigência dessa equação, escolhe-se a função linear para $g(y_j)$ conforme mostrado em (24):

$$g(y_j) = \eta y_j \quad (24)$$

A equação pode ser simplificada em (25)

$$y_j = h_{ij}(t) \quad (25)$$

Substituindo as funções (24) e equação (25) tem-se:

$$\Delta w_{ij} = \eta_t \cdot h_{ij}(t) \cdot (x_i - w_{ij}) \quad (26)$$

onde o termo $h_{ij}(t)$ é o parâmetro vizinhança topológica na iteração t , no qual o índice k se refere ao neurônio melhor classificado k .

Finalmente, dado o vetor de pesos sinápticos $w_{ij}(t)$ do neurônio ij no instante t , o vetor de pesos atualizado $w_{ij}(t+1)$ no tempo $(t+1)$ é definido por:

$$\Delta w_{ij}(t+1) = w_{ij}(t) + \eta_t \cdot h_{ij}(t) \cdot (x_i - w_{ij}(t)) \quad (27)$$

A equação (27) tende a mover o vetor de pesos sinápticos na direção do vetor de entrada. Com repetidas apresentações dos dados de treinamento, os vetores de pesos tendem a seguir a distribuição dos vetores de entrada, devido a atualização da vizinhança. Assim, produz uma ordenação topológica em que os neurônios adjacentes tendem a ter vetores com pesos sinápticos similares.

O parâmetro taxa de aprendizagem, $\eta(t)$, como ocorre com o raio topológico, deve variar com o tempo, decrescendo gradualmente com o aumento do tempo t . Geralmente o parâmetro é definido pelas expressões (28), (29) ou (30).

$$Linear : \eta(t) = \eta(0) \left(1 - \frac{t}{T_2} \right) \quad (28)$$


$$\text{Recíproca} : \eta(t) = \frac{\eta_0}{\left(1 + \frac{100t}{T_2}\right)} \quad (29)$$

$$\text{Exponencial} : \eta(t) = \eta_0 \cdot e^{\frac{-t}{t_2}} \quad (30)$$

onde t_2 é uma constante de tempo e η_0 é o valor inicial adotado, o qual deve ser maior que zero e menor que um.

A equação (30) é exponencial, a qual é a mais utilizada, que juntamente com a função (19) reduz o raio topológico e, são adequados para a formação do mapa de características de maneira auto-organizada (HAYKIN, 2001).

Figura 7: Diferentes funções de aprendizagem



Fonte: Vesanto et al., 2000

A figura 7 exibe graficamente as diferenças entre as equações de aprendizado da rede, em que a cor vermelha representa a função linear, a preta a exponencial e a azul a recíproca.

Desta forma, no estágio de treinamento há competição com neurônios vizinhos, escolhendo-se o neurônio vencedor, o qual representa a menor distância ao vetor de entrada. Em seguida, o peso de sua vizinhança topológica é atualizado, conforme o princípio de aprendizagem da rede. Desta forma, os agrupamentos serão gerados e cada grupo está associado aos vetores de peso (os neurônios da camada de saída).

Sendo o estágio inicial de desordem completa, o algoritmo da rede SOM conduz para uma organização dos padrões de ativação extraídos dos dados de entrada. Este processo de adaptação dos pesos sinápticos em duas fases: ordenação e convergência, descritas em 1 e 2:

1. Fase de ordenação:

- Ocorre a ordenação topológica dos vetores de peso. Deve-se levar em conta as considerações sobre o parâmetro de aprendizagem e função de vizinhança.

2. Fase de convergência:

- O parâmetro taxa de aprendizagem deve iniciar com valor próximo a 0,1, decrescendo gradualmente, mas deve permanecer acima de 0,01. Estes valores são satisfeitos por $\eta_0 = 0,1$ e $t_2 = 1000$.
- A função de vizinhança deve primeiramente incluir quase todos os neurônios da grade centrados no neurônio vencedor i , e então decrescer lentamente com o tempo. Permite-se que o valor do raio topológico reduza a um valor pequeno de apenas um par de neurônios vizinhos em torno do neurônio vencedor ou ao próprio vencedor. Com o uso de uma grade bidimensional, pode-se igualar o tamanho inicial do raio de vizinhança ao raio da grade. Assim, pode-se especificar a constante de tempo por (31) :

$$t_1 = \frac{1000}{\log \sigma_0} \quad (31)$$

2.6.3.2 Propriedades do mapa de características

As propriedades do mapa de características seguem as definições de Haykin (2001). Após a finalização da etapa de convergência, o mapa de características calculado pelo algoritmo mostra características estatísticas importantes do espaço de entrada.

Seja χ um espaço de entrada contínuo, cuja topologia é definida pela relação métrica dos vetores $x \in \chi$. E seja ainda A um espaço de saída discreto, cuja topologia é definida dispondo-se um conjunto de neurônios como os nós computacionais de uma grade. Suponha que Φ represente uma transformação não-linear chamada de *mapa de características*, que mapeia o espaço de entrada χ para o espaço de saída A , como mostrado pela equação (32) :


$$\Phi : \chi \rightarrow A \quad (32)$$

A equação (32) define a localização de um neurônio vencedor $i(x)$ surgido em resposta ao vetor de entrada x .

Dado um vetor de entrada x , o algoritmo SOM primeiro identifica um neurônio que tenha o melhor neurônio vencedor $i(x)$ no espaço de saída A , de acordo com o mapa de características Φ . O vetor peso sináptico w_i do neurônio $i(x)$ pode então ser visto como

um ponteiro para aquele neurônio no espaço de entrada χ ; isto é, os elementos sinápticos do vetor w_i podem ser vistos como as coordenadas da imagem do neurônio i projetada no espaço de entrada. Estas duas operações são vistas na figura 8.

Figura 8: Relação entre o mapa de característica Φ e o vetor de peso w_i do neurônio vencedor i



Fonte: Haykin (2001)

O mapa de características Φ tem algumas propriedades importantes:

1. Aproximação do espaço de entrada. O mapa de características Φ , representado pelo conjunto de vetores de pesos sinápticos w_i , fornece boa aproximação para o espaço de entrada A .
2. Ordenação Topológica. O mapa de características Φ calculado pelo algoritmo SOM é ordenado de modo topológico, no sentido de que a localização espacial de um neurônio na grade correspondente a um domínio particular ou características dos padrões de entrada.
3. Casamento de densidade. O mapa de características Φ reflete variações na estatística de distribuição de entrada: regiões no espaço de entrada χ de onde vetores de amostra x são retirados com uma alta probabilidade de ocorrência, são mapeadas para domínios maiores do espaço de saída A , e portanto com melhor resolução que regiões em χ das quais vetores de amostra x são retirados com uma baixa probabilidade de ocorrência.
4. Seleção de características. A partir dos dados do espaço de entrada com uma distribuição não-linear, o mapa auto-organizável é capaz de selecionar um conjunto das melhores características para aproximar a distribuição subjacente.

2.6.4 APLICAÇÕES

Como parte do levantamento bibliográfico, foram encontrados alguns trabalhos referentes ao uso de RNAs com dados de SR. Foi possível verificar que todos obtiveram resultados satisfatórios em suas técnicas aplicadas, destacando que é possível realizar a integração de RNA com dados de SR.

- Vicente *et al.* (2013) realizaram a pesquisa voltada para aplicação de espectroscopia de reflectância na medida da utilização de bibliotecas espectrais com ênfase no algoritmo SOM.
- Gonçalves *et al.* (2008) apresentam uma metodologia que realiza a classificação automática de imagens empregando a SOM em conjunto com método de agrupamento hierárquico.
- Lopes (2008) teve objetivo de caracterizar o uso e ocupação do solo utilizando ISO-DATA como algoritmo de agrupamento.
- Yuan, Wiele e Khorram (2009) utilizaram SOM e MLP com o módulo BP para classificação do uso e cobertura da terra.
- Freitas *et al.* (2009) objetivaram aplicar SOM como método de seleção de atributos e análise exploratória de dados de SR em áreas de expansão de cana de açúcar.
- Weiss *et al.* (2013) realizaram o mapeamento do uso e ocupação do solo mediante a ferramenta SOM no *software* Idrisi Selva®.
- Hu e Weng (2009) utilizaram SOM e MLP para classificação de estimativas de áreas impermeáveis urbanas. Analisou-se que a SOM pode gerar melhor a estimativa destas áreas do que a MLP.
- Jiang *et al.* (2010) utilizaram o BP na classificação de imagens de SR de alta resolução.

3 ÁREA DE ESTUDO

O Paraná é um Estado que apresenta características físicas diversificadas. É formado por um relevo particular, onde nota-se um escalonamento de leste para oeste, destacando-se o Primeiro Planalto Paranaense (PPP), a Escarpa Devoniana (ED), o Segundo Planalto Paranaense (SPP) e o Terceiro Planalto Paranaense (TPP).

A área de estudo está localizada na Bacia Hidrográfica do Pitangui, no estado do Paraná, o qual compreende uma rede de drenagem que segue em direção ao interior do estado (oeste). A Bacia Hidrográfica do Pitangui possui uma área de $927,3 \text{ km}^2$, situando-se na porção centro-leste do Estado do Paraná, entre as latitudes $25^\circ 46' 40''$ e $25^\circ 49' 06'' S$ e as longitudes $49^\circ 46' 40''$ e $50^\circ 17' 38'' W$.


O rio Pitangui é o principal rio da bacia e provém do PPP, atravessando a ED por meio de vale encaixado e em seguida sendo barrado artificialmente, formando o reservatório de Alagados, utilizado para produção de energia hidrelétrica e abastecimento de água para o município de Ponta Grossa. Extravassando a Represa, o rio Pitangui segue seu curso em direção à foz, no rio Tibagi.

A Bacia Hidrográfica do Pitangui possui um terço da área no PPP e dois terços no relevo de transição (ED) e SPP. A hidrografia da bacia é caracterizada por assimetrias justificada pela complexidade morfológica da área. Na margem esquerda de maior parte em SPP e boa parte da margem direita abrange PPP, parte do SPP e ED.

Para eleger a unidade de paisagem deste estudo, foram analisados alguns atributos físicos distintos da região, a fim de determinar e classificar diferentes tipos de cultivos e cobertura da terra. Desta forma, a área de estudo abrange o SPP, no norte da cidade de Ponta Grossa e situa-se entre as coordenadas médias aproximadas $582.600\text{m E } 7.230.800\text{m N}$ à $585.400\text{m E e } 7.232.400\text{m N}$, meridiano 51, totalizando 6.352m^2 .

Na figura 9 está ilustrada a localização da área de estudo. Nela encontra-se o mapa do Paraná, com enfoque na região de Ponta Grossa. Também destacou-se em uma imagem Resourcesat-1, composição colorida falsa cor para evidenciar a abrangência da área de estudo. Por fim, há a imagem Rapideye (composição azul, verde e vermelho), com as respectivas coordenadas e escala. No item 3.1 há informações sobre a fisiografia da Bacia do Pitangui.

Figura 9: Área de estudo



Fonte: A autora

3.1 Fisiografia da Bacia do Pitangui

O relevo, as formas e feições observadas na Bacia do Pitangui são resultados da ação combinada de vários fatores endógenos e exógenos, que, passiva ou ativamente, influenciam a evolução, a ornamentação e a forma final das esculturas naturais observadas nas rochas.

A hidrografia, no PPP, apresenta a drenagem com direção nordeste-sudoeste, controlada pela estrutura da Bacia do Paraná. A margem esquerda no SPP é caracterizada por afluentes com padrão de drenagem dentrítica (forma ramificada). No relevo de transição (ED) os rios são controlados por estruturas geológicas relacionadas ao Arco de Ponta Grossa.

Com relação ao clima, devido a localização geográfica na Zona Subtropical ao Sul do trópico de Capricórnio, sofre a ação das massas de ar quente e frias, em especial, as massas de ar tropical marítima e polar. O choque entre essas duas massas de ar gera uma zona de descontinuidade, tornando o tempo instável e geralmente chuvoso. O clima é do tipo Cbf da classificação de Koeppen (MAACK, 2002), ou seja, zona temperada sempre úmida, com temperatura média do mês mais frio inferior a 18 graus, temperatura do mês mais quente inferior a 22 graus e inexistência de estação seca definida. A precipitação média é de 1.400mm a 1.800 mm, com período mais seco de junho a agosto e período mais chuvoso é dezembro a fevereiro.

Os solos predominantes são encontrados Cambissolos (hápticos e húmicos), nas áreas com relevo em entalhamento, sobre substrato chuvoso de diversas unidades. São solos heterogênicos, pouco profundos (até 130 cm). Também são encontrados Neossolos Litófico que tem formação favorecida pelas altas declividades do relevo. Resultam as classes de Organossolos e Gleissolos, essencialmente orgânicos, provenientes de depósitos de restos vegetais em grau variável de decomposição, acumulados em ambientes mal drenados (BOGNOLA *et al.*, 2002). Outra classe é de Latossolos, sendo latossolos vermelho-escuros, latossolos roxos e latossolos vermelho-amarelos. Aparecem em áreas de topos aplainados, preservados da erosão (EMBRAPA, 2006).

De acordo com a classificação da vegetação brasileira do IBGE, o PPP é caracterizado por vegetação relacionada à zona fitoecológica Floresta Ombrófila Mista Montana. E no SPP tem-se a zona fitoecológica Estepe Gramínea Lenhosa (VELOSO; FILHO; LIMA, 1991). Ao todo foram identificadas 18 unidades de paisagem com características definidas pela presença de fragmentos de vegetação nativa. No PPP tem-se várzeas, campos higró-

filos, campos secos e formações florestais. Nas cabeceiras do rio Pitangui são encontradas áreas com remanescentes de Floresta Ombrófila Mista (GEALH; MELO; MORO, 2010).

Os brejos são encontrados em locais planos, de umidade constante de correnteza muito lenta ou mesmo estagnada, muitas vezes em forma de U, ligadas a uma várzea ou pequeno regato. O solo hidromórfico suporta uma vegetação característica de ervas mais altas: ciperáceas, juncáceas, eriocauláceas, compostas e verbenáceas (MORO, 2001).

O uso da terra na bacia do rio Pitangui tanto no PPP como no SPP é caracterizada por intensas atividades agropastoris cultivo intensivo e semi-intensivo, entre porções de vegetação nativa (ROCHA; NETO, 2010), ou mesmo em áreas de reflorestamento de espécies exóticas, assim como em áreas de preservação permanente (ZILLER; GALVÃO, 2002). As principais culturas na área são: soja, milho, feijão, aveia, trigo e triticales, caracterizadas por cultivo mecanizada e larga utilização de insumos agrícolas. São encontradas monoculturas de *Pinus* e Eucalipto. Julga-se que as espécies de *Pinus* cultivadas na região são extremamente prejudiciais ao equilíbrio ecológico das comunidades vegetais da bacia, especialmente as campestres rochosas.

Na região da bacia é empregado o sistema de plantio direto sobre a palha (NUCLEAM, 2002). O curso do rio é cortado por estradas cascalhadas, que servem às propriedades rurais como vias de escoamento de produção, inclusive a rodovia PR - 090, também conhecida como Estrada do Cerne.

Com base nas características da área de estudo, a utilização de plantio direto incrementado da utilização do SR para análise em imagem orbital, é interessante obter informações a respeito da cobertura vegetal de uma região da superfície terrestre devido a variedade de cultivos, levando em consideração a interação da energia solar com a comunidade de plantas, que define uma superfície denominada dossel (JENSEN, 2009).

Na estrutura da vegetação, segundo Rudorff e Moreira (2002), o dossel é o estrato superior da formação vegetal. É a camada de folhagem contínua de uma floresta, arvoredos ou cerradão, composta pelo conjunto das copas das plantas lenhosas mais altas. Assim, o dossel vegetativo pode ser entendido como o conjunto de todas as copas da vegetação, em determinada área, independentemente da espécie. De acordo com a porcentagem de cobertura do solo pelas plantas, o dossel pode ser classificado em duas categorias: incompleto e completo.

O dossel é considerado incompleto quando apresenta baixa porcentagem de cobertura do solo, como é o caso de uma cultura agrícola no início do desenvolvimento vegetativo. Nesta fase de crescimento da cultura, a energia refletida da área é composta

de uma parte proveniente das plantas e outra do solo onde foi implantada. A medida que a vegetação ou a cultura atinge o seu desenvolvimento máximo, o dossel é considerado completo, correspondendo a uma cobertura vegetal próximo a 100%.

A morfologia das folhas que compõem o dossel vegetativo exerce forte influência na reflectância (RUDORFF; MOREIRA, 2002). As reflectâncias de um alvo, como vegetação, é um conjunto resultante da reflectância bidirecional da copa da vegetação, que é uma mistura dos diferentes componentes listados (LIU, 2006):

- transmitância de folha;
- quantidade e orientação da folha;
- características dos componentes da planta, tais como caules, galhos, troncos e sua arquitetura;
- características de fundo, tais como reflectância do solo, folhas caídas, sombras e outras;
- ângulo zenital do Sol;
- ângulo de elevação do Sol;
- ângulo de visada dos sensores do satélite.

Segundo Jensen (2009), as comunidades podem ser quase homogêneas, como as áreas agrícolas ou bastante heterogêneas, como no caso de uma área ocupada por uma mata natural, onde se tem árvores de diferentes portes e espécies.

É importante salientar que, mesmo em uma comunidade bastante homogênea, sempre há outros tipos de vegetação que ocupam o estrato inferior do solo e que, em certas fases do ciclo de crescimento e desenvolvimento, disputam água e nutrientes com as plantas predominantes.

O entendimento da interação da radiação solar com os dosséis vegetativos tem sido bem explorado em culturas agrícolas, que, por serem de porte mais baixo e de ciclo mais curto, permitem mais facilmente os componentes da energia refletida e transmitida no dossel.

Outro fator importante a ser analisado na área de estudo, são as características temporais, com objetivo de identificar diferentes tipos de vegetação ou extrair informações biofísicas da vegetação a partir de dados de SR. Entretanto, segundo (RUDORFF;

MOREIRA, 2002) a única possibilidade de discriminar entre duas culturas é usando dados de resolução relativamente larga:

- as culturas tiverem sido plantadas em datas ligeiramente diferentes (p.ex. 10 dias);
- uma cultura tenha recebido irrigação significativamente diferente do que a outra;
- uma cultura tenha maturado mais rapidamente do que a outra;
- o espaçamento entre linhas de plantio, ou a orientação da parcela, for significativamente diferente de uma para outra cultura; ou
- uma cultura tiver uma estrutura de dossel diferente da outra.

As culturas agrícolas têm ciclos fenológicos bem conhecidos para cada região, sendo que pode haver algumas variações de tipos de manejos entre fazendeiros. Como a área de estudo utiliza o Sistema de Plantio Direto na Palha (SPDP), há contribuição para que o solo não seja levado pelas erosões e armazene mais nutrientes, fertilizantes e corretivos. E desta forma, a "palha"seca interfere na radiância refletida em imagens de SR.

4 PROCEDIMENTOS METODOLÓGICOS

4.1 MATERIAL E MÉTODOS

- **Hardwares utilizados:**

- Notebook MacBook Air 4.2, com processador Intel Core i5, 1.7 Ghz, 4 Gb de memória, APPLE SSD TS128C com 121,33 GB.
- Computador com processador AMD Phenon(tm) II X4 965 Processor, 3.4 ghz, 8 Gb memória, Windows 7 Ultimate 64 bits.

- **Softwares utilizados:**

- ENVI 4.7: *software* comercial desenvolvido pela *ITT Visual Information Solutions*, para o processamento de imagens digitais. Utilizado para realizar visualizações da área de estudo, recortes e adição de banda com NDVI.
- ENVI EX: aplicativo complementar ao ENVI, utilizado para aplicar o método de GEOBIA, extraindo os atributos espectrais, espaciais e de textura.
- R: é uma linguagem e um ambiente de desenvolvimento integrado, para cálculos estatísticos e gráficos incluindo a ACP para seleção de atributos.
- Geosom Suite: ferramenta baseada na somtoolbox do Matlab, pela equipe do Laboratório de Informação e Ciência da Computação da Universidade de Tecnologia de Helsinki, na tentativa de adaptar a SOM, a fim de considerar a natureza espacial de dados geográficos.
- Arcgis 9: versão lançada em 2004, e foi utilizada para visualização dos shapefiles, criação do mapa da área de estudo, adição e visualização do resultado de treinamento da SOM.

- **Imagem orbital utilizada:**

- Imagem Rapideye ortorretificada, disponibilizada pelo curso de Pós-Graduação em Geografia (Mestrado e Doutorado) da Universidade Estadual de Ponta Grossa, obtida em agosto de 2012, e possui as características:
 - * resolução espacial de 5 metros;
 - * resolução radiométrica de 12 bits;
 - * resolução temporal de 1 dia;
 - * 5 bandas espectrais conforme a tabela 1.


Tabela 1: Bandas espectrais da imagem orbital Rapideye

Número	Faixa espectral (μm)	Banda
1	0,440 - 0,510	Azul
2	0,520 - 0,590	Verde
3	0,630 - 0,685	Vermelho
4	0,690 - 0,730	<i>Red-Edge</i>
5	0,760 - 0,850	Infravermelho próximo

Fonte: A autora

Na figura 10 é possível visualizar as bandas espectrais de acordo com seu comprimento de onda supracitado na tabela 1. A partir destas é possível realizar composições coloridas no sistema de cores RGB, das bandas para analisar as características da área.

Figura 10: Bandas espectrais monocromáticas da Rapideye



Fonte: A autora

A banda 1 (figura 10a) correspondente ao comprimento de onda do azul do espectro eletromagnético, possui baixa radiância refletida para as culturas em geral, como no caso das glebas de milho e aveia (glebas centrais e à direita da imagem, respectivamente) bem como mata de galeria. Entretanto para o trigo (glebas superiores à esquerda) a radiância refletida é alta, pois nesta data ele encontrava-se pronto para colheita (maduro). Nota-se ainda, nesta mesma banda espectral, que o uso da terra estradas e construções estão evidentes, refletindo mais.

A banda 2 (figura 10b) corresponde ao comprimento de onda do verde e, como esperado, a vegetação aparece em diferentes "nuances" ou tons, pois na verdadeira cor, a radiância da vegetação reflete mais em comparação ao comprimentos de onda do azul e

vermelho, destacando as diferentes culturas e seus estágios.

A banda 3 (figura 10c) corresponde ao comprimento de onda do vermelho. Verifica-se que as glebas dos cultivos de milho e trigo ficaram bastante semelhantes e evidentes. Isso ocorre devido a esta banda mostrar as atividades fotosintéticas e dos pigmentos presentes nos vegetais. O uso da terra de estradas e construções está com menor reflectância.


A banda 4 (figura 10d) corresponde ao comprimento de onda do *Red-Edge* do espectro eletromagnético. Possui grande reflectância nas glebas de aveia e pouca reflectância das glebas de milho que estão em estágio inicial de desenvolvimento. As estradas e construções ficam ainda menos evidentes, pois nesta banda ocorre uma mudança abrupta na reflectância da clorofila (WEICHELT *et al.*,).

A banda 5 (figura 10e) corresponde ao comprimento de onda do Infravermelho próximo, e como esperado, a mata de galeria possui alta reflectância. Nesta faixa, os corpos d'água ficam bem evidentes por terem baixa reflectância. As glebas de aveia ficam bem visíveis, bem como de trigo. Neste caso ocorre semelhança nas glebas de milho com o apresentado na banda 4 (*Red-Edge*).


Verifica-se, que no comprimento de onda do visível (vermelho, verde e azul), a radiância é marcada por um processo de absorção, ocasionando pela presença de pigmentos fotossintetizantes na vegetação sadia (clorofila). Já no infravermelho (banda 5), esta relação entre radiância refletida e biomassa verde é diretamente proporcional, podendo variar de acordo com a quantidade de folhas, distribuição e arranjo espacial do dossel (JENSEN, 2009).

Na figura 11 são exibidas algumas composições coloridas das bandas espectrais da Rapideye. A figura 11a corresponde a verdadeira cor, formada pelas bandas vermelho, verde e azul, em que o canal do sistema de cores se encontra em cada intensidade de cada canal espectral. Já em 11b, 11c e 11d estão apresentadas as composições em falsa cor, e é possível verificar as semelhanças entre cultivos bem como a reflectância de cobertura florestal e corpos d'água. Tais composições são necessárias para análise visual, na determinação das classes e comparações "in loco". Também são de suma importância para a separabilidade das classes mediante o classificador, devido as informações das regiões nas bandas e/ou a composição delas. Mais composições coloridas falsa cor estão apresentadas no Apêndice A.


Figura 11: Composições coloridas das bandas espectrais da Rapideye




(a) Bandas 3R 2G e 1B (Verdadeira cor)



(b) Bandas 2R 3G e 6B



(c) Bandas 1R 4G e 5B



(d) Bandas 5R 3G e 1B


Fonte: A autora

Ressalta-se que esse tipo de análise, apresentado na figura 11, é importante para compreender os diversos agrupamentos que a RNA SOM pode fazer devido à essas características espectrais, visto que é uma rede não-supervisionada, a qual busca as similaridades para formar os grupos (classes de cobertura e uso da terra). Este processo da SOM se assemelha ao processo de análise visual feito pelo analista, para discriminar as feições da área de estudo.

No diagrama de blocos da figura 12 é possível ver as etapas da pesquisa. Os dados obtidos são da imagem Rapideye, e calculando o NDVI, fica composta por 6 bandas, isto é, 5 bandas espectrais originais e uma banda artificial correspondente ao NDVI. Como mostra o diagrama, é realizada a fotointerpretação para delimitação das classes de interesse da área de estudo.

A próxima etapa é aplicar a GEOBIA, e gerar a nova imagem com nível de abstração de objeto ou região e tabela, contendo o banco de dados relacional com topologia e descritores. Na sequência é aplicada à tabela do banco de dados relacional com os descritores (espacial, espectral e de textura) a ACP, sem os descritores do NDVI, no método de seleção de variáveis. A próxima etapa é realizar o agrupamento dos padrões mediante RNA SOM, que gera as regiões, denominadas classes, para futura análise e validação dos resultados.

Figura 12: Diagrama de Blocos: etapas de desenvolvimento da pesquisa



Fonte: A autora

4.2 EXTRAÇÃO DE CARACTERÍSTICAS MEDIANTE GEOBIA

Os índices de vegetação para Aksoy, Akçay e Wassenaar (2010), são medidas simples mas poderosas para identificação fotossintética ativa. Segundo Moreira e Shimabukuro (2004), são encontrados na literatura mais de cinquenta índices de vegetação, sendo que quase todos obtidos de medidas de radiância refletida nas faixas espectrais do vermelho e infravermelho próximo do espectro eletromagnético. Os tipos mais comumente utilizados são os índices baseados em razão, o NDVI e RVI.

Neste trabalho optou-se pela utilização do NDVI por ser um parâmetro importante para o monitoramento da vegetação e é utilizado para construir perfis, sazonal e temporal, das atividades da vegetação e visa a redução de efeitos de iluminação topográfica bem como o realce de feições que podem não estar evidentes nas bandas espectrais. É comumente utilizado em dados remotos para dar indicação do vigor da vegetação, porém também é utilizado na estimativa do Índice de Área Foliar (IAF), análise da degradação ambiental, classificação da cobertura do solo, detecção de secas bem como identificação de áreas desmatadas (SINGH *et al.*, 2006). O NDVI é dado pela equação (31) :

$$NDVI = \frac{NIR - VIS}{NIR + VIS} \quad (31)$$

em que NIR é a faixa espectral do infravermelho próximo e a VIS é a do vermelho, com faixa de valores obtidos entre -1 e 1.

Portanto, o objetivo da utilização do NDVI no trabalho é o fato que, no processamento da RNA SOM, os descritores deste índice poderão auxiliar na separação das classes, principalmente os diferentes tipo de cultivos agrícolas bem como cobertura florestal, obtendo as diferenciações de corpos d'água². Após esta etapa, segue o processo de segmentação da imagem orbital. No software ENVI EX, da empresa ITT VIS (*Visual Information Solutions*) está implementado o algoritmo FLSA, como já descrita na seção anterior, e realiza a segmentação em duas etapas, reguladas por índices percentuais: *Scale Level* (SL) para escala, e *Merge Level* (ML) para fusão. Para o SL pode-se escolher o algoritmo de detecção de bordas *Edge* ou *Intensity*. Com eles é possível ajustar a escala de segmentação que será utilizada. O ML elimina segmentos espúrios (ruídos) dos segmentos maiores (GONZALEZ; WOODS, 2000). Porém, o tamanho dos segmentos varia de acordo com os valores definidos para SL. Se os valores de SL forem baixos, serão formados segmentos menores e em maior quantidade, o que pode gerar uma supersegmentação. Quando o ML é usado observa-se que os segmentos menores são inseridos em segmentos

²Qualquer acumulação significativa de água, por exemplo, rios, córregos e lagoas.

maiores, diminuindo a possibilidade de supersegmentação. Por isso, é necessário escolher estes valores criteriosamente de acordo com o estudo e a resolução espacial da imagem.

4.3 APLICAÇÃO DA ACP

A preparação dos dados para uma futura classificação temática em uma RNA é tarefa essencial e também complexa. É necessário identificar quais dados apresentam maior relevância e que estes não fiquem redundantes (JOLLIFFE, 1972).

Primeiramente deixa-se as variáveis³ na mesma escala, realizando a normalização, visto que os dados provenientes da GEOBIA possuem diferentes unidades de medida. Desta forma, segue-se a equação (32):

$$y_i = \frac{(x_i - \mu)}{\sigma} \quad (32)$$

em que y_i são os valores transformados, x_i são as amostras (objetos), μ e σ é a média e desvio padrão amostral, respectivamente.

Após aplicada a ACP, os dados são transformados em um novo sistema de coordenadas com eixos ortogonais. Assim, serão geradas n CPs a partir das n variáveis ortogonais. Cada CP pode ser analisada separadamente, e desta forma, ser escolhida quais CPs são mais importantes em cada eixo. Assim, a ACP é útil para reduzir a dimensionalidade de um conjunto de dados, bem como descarte de variáveis.

4.3.1 Seleção de variáveis mediante ACP

Com o novo conjunto de dados, é formada uma base, que contém grande parte da informação explicada pela distribuição de dados, ou seja, como os dados deste conjunto são apresentados de forma decrescente, as primeiras CPs apresentam a maior variância dos dados. Assim, quanto maior for a variância explicada pelas primeiras CPs melhor será a redução da dimensionalidade dos dados. A variância explicada pode ser obtida pela razão entre o autovalor (λ) correspondente e a soma de todas as variâncias, conforme a equação (33):

$$Variância_Explicada (\%) = 100 \times \frac{\lambda_i}{\sum_{i=1}^n \lambda_i} \quad (33)$$

em que λ_i corresponde à variância. Uma questão relevante à técnica de ACP é a escolha do número de CPs. Existem diversos métodos para esta seleção. Um dos primeiros trabalhos a comparar métodos multivariados na seleção de variáveis independentes foi o de Beale *et*

³A nomenclatura é: descritores para GEOBIA, atributos para SIGs e variáveis para análise estatística

al. (1967). Vários métodos de seleção de variáveis foram investigados por Jolliffe (1972), Jolliffe (1973) a partir da ACP.

O número de k CPs pode ser escolhido pelo número de CPs necessárias para explicar a porcentagem superior a 90% da variação total dos dados, ou também pelo número do autovalor (λ) associado, maior que 0,7. Esse procedimento é conhecido como método de Beale. Nesse método a determinação de k não é subjetiva. O λ_0 é um valor limite para a inclusão de variáveis, a seleção do número de CPs se dará para todas componentes tais que $\lambda_i < \lambda_0$, que segundo Jolliffe (1972) o valor de λ_0 deve ser 0,7.

Após definir o número de CPs, a serem utilizadas no estudo, é realizado o processo de seleção de variáveis. Nesta pesquisa, optou-se por utilizar o método B4 proposto por Jolliffe (1972), aprimorado em Jolliffe (1973), para seleção de variáveis, baseado na preservação da variação da maioria dos dados. Este método utiliza as n primeiras CPs selecionadas anteriormente, onde a variável de maior valor absoluto (autovetor) corresponde a primeira CP selecionada. Em seguida, a segunda CP selecionada será de maior valor absoluto correspondente da segunda CP, até o número n de CP serem selecionadas. Caso haja duplicação de variável em duas CP, a segunda a ser selecionada será aquela de segundo maior valor absoluto correspondente da CP. Aquelas variáveis que não forem selecionadas, serão descartadas.

Conforme Jolliffe (1973), o procedimento B4 pode ser descrito por:

- execute a ACP sobre o conjunto de dados definido sobre X ;
- defina o número p de variáveis⁴ para serem selecionadas;
- para cada uma das p primeiras CPs:
 - determine a variável com maior coeficiente;
 - selecione a variável.

4.4 TREINAMENTO DA SOM

Esta pesquisa foi realizada no ambiente computacional GeoSOM, desenvolvido pelos pesquisadores Fernando José Ferreira Lucas Bação e Victor José de Almeida e Sousa Lobo, com RNA SOM baseada na implementação com a caixa de ferramentas SOM para Matlab 5 (versão 2), disponível no site <http://www.cis.hut.fi/projects/somtoolbox/>. A

⁴Variável = descritores (espacial, espectral e de textura).


caixa de ferramentas SOM foi desenvolvida por Juha Vesanto, Johan Himberg, Esa Alho-niemi e Juha Parhankangas na Helsinki University of Technology - Finlândia e contém funções para criação, visualização e análise de SOM.

O GeoSOM trabalha com base nas coordenadas geográficas, e desta forma realiza o processo de treinamento da RNA SOM. As funções utilizadas foram: `som_data`, `som_train`, `som_topol`, `som_map`, `som_bmus`, `som_norm_variable` e `som_umat`. Com estas funções é possível realizar uma gama de combinações de topologias (hexagonal ou retangular), tamanhos do mapa, inicialização (randômico ou linear), treinamentos (sequencial ou por lote), normalização, funções de decrescimento de taxa de aprendizagem e do raio topológico. Maiores informações sobre a ferramenta em Henriques, Bação e Lobo (2012).

Fez-se necessário analisar como a ferramenta GeoSOM realiza o processo de agrupamento dos objetos geográficos. Uma forma de visualizar os agrupamentos é apresentada graficamente mediante *u_matrix*, obtida pela função "som_umat". A *u_matrix* apresenta através de unidades coloridas as distâncias entre os agrupamentos, conforme os neurônios. A *u_matrix* é quase duas vezes maior que o mapa original criado, pois existe hexágonos/retângulos adicionais no mapa em cada hexágono/retângulo (conforme topologia) para delimitação dos agrupamentos. Ou seja, se o mapa criado for 3x2, a *u_matrix* será de 5x4, conforme exibido na figura 13, pois adiciona-se 1 hexágono de distância entre cada hexágono original do mapa.

Para Vesanto *et al.* (2000) a variação de cores é representada conforme uma escala de distâncias, sendo do azul escuro com escala de valor 0 ao vermelho com escala de valor 1. A cor azul escuro representa os neurônios mais próximos, ou seja, os agrupamentos. As cores mais claras até o vermelho, representam que os hexágonos estão mais distantes conforme os agrupamentos. A figura 13 ilustra a separação visual dos agrupamentos conforme este autor. Desta forma, nota-se a formação de 4 grupos representados pelos hexágonos azul escuro e as divisões pelos hexágonos em cores mais claras tendendo ao vermelho.

Figura 13: Separação dos agrupamentos mediante *u_matrix*



Fonte: A autora

A caixa de ferramentas SOM, para Matlab, dispõe de métodos para normalização de dados. Assim, os objetos serão normalizados, pois provém de diferentes escalas e origens (espectral, espacial e de textura). Esta função é nomeada em `som_norm_variable` sendo os métodos descritos na tabela 2. Nela encontra-se os sete (7) métodos de normalização disponíveis no programa GeoSOM, os quais foram analisados para utilização nesta pesquisa. Ressalta-se que a ferramenta realiza a normalização e treinamento na mesma etapa, portanto, não se tem acesso, posteriormente, aos dados normalizados.

Tabela 2: Métodos de normalização da RNA SOM para Matlab

Método	Descrição
var	A variância dos dados é normalizada para 1(um)(operação linear);
range	Os valores são normalizados pela amplitude dos dados entre [0,1] (operação linear);
log	É aplicado o LogNatural aos valores: $x_{new} = \log(x - m + 1)$ onde $m = \min(x)$.
logistic	Transformação Logística ou softmax que leva todos valores entre [0,1];
histD	Equalização por Histograma discreto, os valores são escalados entre [0,1]. Pode utilizar um valor considerável de memória. Se a variável obter mais do que alguns valores (por exemplo 20) é recomendável o uso da função histC.
histC	Equalização por histograma contínuo, com operação parcialmente linear. Recomendada para variáveis contínuas. Valores escalados entre [0,1];
eval	Operação definida livremente. ⁵

Fonte: Vesanto (2000)

As funções de vizinhança presentes na GeoSOM são: *gaussian*, *cutgauss*, *ep* ou *bubble*, correspondentes à funções apresentadas na figura 6 na seção 2.7.2, respectivamente. Já as funções de aprendizado são: *inv*, *linear* ou *power*, já descritas na seção 2.7.2 e ilustradas na figura 7.


A caixa de ferramentas SOM mediante GeoSOM suporta grade hexagonal ou retângula, ilustrada na figura 14, e as formas plana, cilíndrica e toroidal, conforme figura 15.

• Medidas de qualidade do mapa

A GeoSOM apresenta duas métricas para avaliação da qualidade do mapa gerado após o processo de aprendizagem. As métricas são o Erro da Quantização Vetorial e o


⁵Este método não é utilizado no estudo, pois não foram encontradas referências sobre o seu funcionamento.

Figura 14: Exemplos de vizinhança: Hexagonal e Retangular



Fonte: Vesanto et al. (2000)

Figura 15: Topologia da RNA SOM (plana, cilíndrica e toroidal, respectivamente)



Fonte: Vesanto et al. (2000)

Erro Topográfico. O Erro de Quantização representa a média das distâncias entre cada vetor de dados e o correspondente vetor de pesos do neurônio vencedor. Estima-se que quanto menor o erro de quantização, mais bem ajustado o neurônio vencedor estará aos vetores de entrada.

O Erro Topográfico quantifica a capacidade do mapa em representar a topologia dos dados de entrada, para a qual o primeiro neurônio vencedor (Best Matching Unit (BMU)) e segundo neurônio (BMU2) não são unidades adjacentes. O resultado é igual a 1 se BMU e o BMU2 forem vizinhos, ou igual a 0 se BMU e BMU2 não forem vizinhos. Maiores detalhes sobre estas medidas em (VESANTO *et al.*, 2000).


4.5 TESTES DA SOM

São realizados inúmeros testes da arquitetura e configurações dos parâmetros de treinamento da SOM até que um seja adequado à análise. Desta forma, são realizadas variações de: testes com e sem atributos de NDVI, testes com seleção mediante ACP e com todas as variáveis. Assim, são identificadas as regiões e a contribuição das variáveis para cada região.

Como forma de analisar se o resultado da classificação foi satisfatória para o estudo, o fluxograma de testes das figura 16 explicita o procedimento. Primeiramente é

considerado um número mínimo de classes, no caso 3 (três) sendo estes: cultivo, cobertura florestal e corpos d'água. Se isso for possível, é verificado se houve diferenciação entre cultivos. Se afirmativo, é analisado se o contorno de corpos d'água (rio) é visível. Se há apenas um tipo de cultivo e o agrupamento dos corpos d'água não for satisfatório o teste é descartado. Por fim, são analisadas as confusões espectrais entre objetos e a influência das atributos nas regiões agrupadas.

Figura 16: Fluxograma para análise de testes











Fonte: A autora

4.6 VALIDAÇÃO A CAMPO

A classificação das áreas de estudo são validadas mediante Verdade Terrestre (VT). As classes foram obtidas por meio de interpretação visual e conhecimento a campo de algumas regiões, para gerar o mapa de referência com pontos de validação. Para compor a VT, foi utilizada verificação "in loco", bem como imagem aérea de Veículo Aéreo Não Tripulado (VANT), disponibilizada pela empresa Santiago e Cintra, em demonstração do equipamento. Desta forma, as classes de uso e cobertura da terra estão descritas na tabela 3.

Tabela 3: Elementos "chaves" de interpretação das classes de uso e cobertura da terra

Classe	R5G3B1 ⁶	R3G2B1 ⁷	Foto campo
Cultivo 1 (cultivo milho)			
Cultivo 2 (cultivo milho)			
Cultivo 3 (cultivo aveia)			
Cultivo 4 (cultivo trigo)			
Corpos d'água			
Cobertura Florestal			
Estradas			
Construções			

As fotos das classes cultivos 1, 2 3 e 4, bem como cobertura florestal e construções foram obtidas no local. Já as classes corpos d'água e estradas foram obtidas mediante imagem do VANT. A figura 17 ilustra os dois modos de análise a campo, sendo o VANT em 17a e do campo (horizontal) em 17b.


Com as imagens de campo, verificou-se que, a classe cultivo 2 também é milho, porém em ciclo fenológico diferente, que a classe cobertura florestal é determinante no fator textura, visto que há diferentes tipos de vegetação, inclusive a presença de vegetação

⁶R = Banda 5 (Infravermelho), G = Banda 3 (Vermelho), B = Banda 1 (Azul)

⁷R = Banda 3 (Vermelho), G = Banda 2 (Verde), B = Banda 1 (Azul)

rasteira ao redor da mata de galeria. Já com as imagens do VANT, foram identificadas na figura 17a, as classes estradas e corpos d'água, em 1 e 2, respectivamente.

Figura 17: Exemplos de imagens para validação a campo (VANT e horizontal)



(a)




(b)

Fonte: A autora

Para a validação, Congalton (1991) sugere o valor de tamanho mínimo de 50 amostras para cada classe deve ser adotado em áreas de abrangência territorial de até 4.050 Km. A área de interesse tem aproximadamente 6 Km², o que reduz o número de amostras coletadas. Assim, tendo o conhecimento a campo, para definição e posterior validação de todas as classes de uso e cobertura da terra, foram coletados 20 pontos amostrais de cada classe, conforme figura 18. Estes pontos foram superpostos à imagem classificada, gerando uma matriz de confusão, bem como análise mediante índice kappa, erros de

omissão e inclusão. O índice kappa, tradicionalmente usado para análise de resultados, é amplamente aceito e adotado pelo SIG e SR. A idéia é construir uma matriz de confusão que resume a categorização entre um conjunto de dados de referência, e o mapa temático a ser avaliado (MARINHO; FASBENDER; KOK, 2012).

Figura 18: Amostras coletadas para validação



Fonte: A autora

Também é realizado o teste F para duas variâncias, e foram escolhidas verdades de campo mediante a imagem do VANT. A figura 19, mostra 4 regiões da imagem do VANT, correspondente às classes: Cobertura florestal, corpos d'água, cultivo 3 e estradas. Nestas classes foram coletadas amostras para o cálculo da área. Esta validação aborda o novo paradigma baseado no objeto (GEOBIA), que foi explorado por Marinho, Fasbender e Kok (2012) e Becker, Ostermann e Pahl (2012).

Figura 19: Áreas selecionadas para teste F



Fonte: A autora

Nas subseções 4.6.1 e 4.6.2 são explicitadas as definições sobre matriz de confusão e índice kappa, bem como teste F, respectivamente.

4.6.1 Matriz de confusão e índice kappa

A maneira mais comum para representar uma classificação de dados de SR é sob a forma de uma matriz de confusão. A matriz de confusão pode ser usada como um ponto de partida para uma série de análises e técnicas descritivas e estatísticas. Mais informações estão disponíveis em Congalton (1991), Centeno (2004).

O índice Kappa pode ser definido como uma medida de associação usada para descrever e testar o grau de concordância (confiabilidade e precisão) na classificação (KOTZ; JOHNSON, 1983). Segundo Moreira (2011), o valor resultante pelo cálculo do índice kappa pode ser analisado mediante a qualidade da classificação explicitada na tabela 4.

Tabela 4: Valores de referência índice kappa

Valor de kappa	Qualidade da classificação
< 0,00	Péssima
0,00 - 0,20	Ruim
0,20 - 0,40	Razoável
0,40 - 0,60	Boa
0,60 - 0,80	Muito boa
0,80 - 1,00	Excelente

4.6.2 Teste F para duas variâncias

Como complemento na análise dos resultados, é realizada o teste F, em regiões da imagem classificada com base na imagem do VANT, sendo esta a verdade de campo. Procura-se verificar possíveis alterações na variabilidade. Nesses casos, o teste é feito com as hipóteses:

$$H_0: \alpha^2 = \alpha_0^2 \quad \text{e} \quad H_1: \alpha^2 \neq \alpha_0^2$$

Desta forma, é possível atribuir, *a priori*, um valor hipotético e, em seguida, com base nas informações amostrais, decidir sobre a aceitação ou rejeição do mesmo (GEMAEL, 1994).

Quando deseja-se confirmar ou refutar alguma hipótese, é comum estabelecer, ainda na fase do planejamento da pesquisa, a probabilidade tolerável de incorrer no erro de rejeitar H_0 , quando H_0 é verdadeira. Este valor é conhecido como nível de significância do teste, e comumente adota-se o valor de 5% (BARBETTA; REIS; BORNIA, 2010). Estabelecido o nível de significância α , tem-se a seguinte regra geral de decisão de um teste estatístico:

$$p > \alpha \quad \rightarrow \quad \text{aceita } H_0$$

$$p \leq \alpha \quad \rightarrow \quad \text{rejeita } H_0$$

A distribuição de referência para este teste é a chamada distribuição F, com grau de liberdade $gl = n_1 - 1$ no numerador e $gl = n_2 - 1$ no denominador, apresentada em tabela de referência, que pode ser consultada em Barbetta, Reis e Bornia (2010).

Com o resultado da classificação, será realizado o teste F para cada classe, considerando as seguintes hipóteses:

- Hipótese nula (H_0): As regiões da imagem classificada é igual à verdade de campo (imagem do VANT);
- Hipótese alternativa (H_1): as regiões da imagem classificada são diferentes da verdade de campo (imagem do VANT).

Portanto, nesta seção foram abordados os métodos de validação com abstração no pixel, sendo matriz de confusão, kappa, erros de omissão e inclusão, bem como abordagem baseada no objeto, com o teste F para duas variâncias. Na seção 5, estão explicitados os experimentos e resultados encontrados mediante os procedimentos metodológicos.

5 EXPERIMENTOS, RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados na forma de experimentos (testes). Somente o NDVI será exibido como resultado, pois aplicou-se apenas esta técnica de índice de vegetação na imagem orbital. Como a primeira etapa do trabalho é aplicar o NDVI, a figura 20 exibe o resultado do índice na área de estudo.

Figura 20: Área de estudo apresentada pela Banda Artificial NDVI (monocromática)



Fonte: A autora

Como mencionado na metodologia em 4.2, o NDVI é uma banda artificial usada para realce de feições. Analisando-se na figura 20, verifica-se a distinção entre diferentes tipos de cultivo, bem como a parte representada pela cobertura florestal, que ficou realçada. O corpo-d'água e o solo exposto/estrada também ficaram bem evidenciados, o que pode colaborar na separação das regiões.

5.1 PRIMEIRO EXPERIMENTO: Segmentação da imagem orbital mediante GEOBIA

Na literatura é salientada a importância da escala e fusão no processo de GEOBIA, uma vez que estes parâmetros influenciam no resultado da segmentação e agrupamento de objetos de interesse para a classificação de uso e cobertura da terra. Devido a este fato, foram realizadas algumas variações quanto aos níveis de escala e fusão na etapa de segmentação, com o objetivo de encontrar os valores que melhor representam a separação dos objetos na imagem.

As configurações do processo de segmentação mediante as técnicas de GEOBIA estão descritas na tabela 5 e todas utilizaram o algoritmo de escala *Edge* e algoritmo de fusão FLSA como citado na seção 2:


Tabela 5: Configurações da extração de características por GEOBIA

Valores	Segmentação 1	Segmentação 2	Segmentação 3	Segmentação 4
Escala	50	61,7	70	61,7
Fusão	20	40	50	70


Fonte: A autora

Conforme os valores de segmentação apresentados na tabela 5, a figura 21 ilustra a formação dos objetos na área de estudo.


Figura 21: Ilustração das variações de segmentação e seus respectivos vetores: (a) e (b) Segmentação 1, (c) e (d) Segmentação 2, (e) e (f) Segmentação 3, (g) e (h) Segmentação 4



(a) Primeira segmentação




(b) Vetores da segmentação 1



(c) Segunda segmentação




(d) Vetores da segmentação 2



(e) Terceira segmentação



(f) Vetores da segmentação 3



(g) Quarta segmentação



(h) Vetores da segmentação 4

Fonte: A autora

É possível verificar que, se a escala e fusão são valores pequenos, conforme pri-

meira segmentação, gera supersegmentação, ou seja, cria-se muitos objetos na imagem o que dificulta a separação dos mesmos. Já se os valores são muito altos, conforme a terceira segmentação, há perda dos limites dos objetos.

Para o primeiro teste com a segmentação com escala de 50 e fusão de 20, foram gerados os segmentos apresentados na figura 21a, e nota-se a quantidade de segmentos gerados. Em 21b exibe-se somente os vetores e, visualmente identifica-se quantidade de informações desnecessárias. É possível analisar que as regiões identificadas na imagem ficam supersegmentadas. Deste forma, este tipo de segmentação prejudica a identificação de bordas das classes de cobertura e uso da terra.

A configuração dos parâmetros na segunda segmentação foi de 61,7 e 40 (tabela 5). Aumentou-se a escala (em 11,7), entretanto a fusão foi o dobro. As figuras 21c e 21d mostram o resultado desta segmentação. É visível a diminuição dos segmentos pequenos se comparados com a segmentação número 1, porém, verifica-se que a classe estradas e construções ainda ficou com muitos segmentos espúrios.


Na figura 21e está a configuração dos parâmetros na segmentação número 3, com escala de 70 e fusão de 50. Aumentou-se em 9,3 a escala do que a anterior. A figura 21f ilustra o vetor da segmentação, a qual é possível notar perda de informação das regiões na área de estudo, ocasionando em segmentos maiores.

A figura 21g ilustra a segmentação 4. Foi escolhido o mesmo valor de escala da segmentação de número 2 (61,7) porém fusão maior (70), com o intuito de diminuir espúrios dentro de objetos maiores. Nela verifica-se que, com o valor de fusão maior que os demais testes, os objetos que estavam em excesso foram fundidos com os objetos maiores, sem perder as bordas, como no teste da segmentação 3. Desta forma o contorno dos corpos d'água não é perdido, bem como as fronteiras dos cultivos. Este teste representou a melhor delimitação das classes de uso e cobertura da terra, pois com ele, as classes de cultivo ficaram devidamente separadas, bem como as classes corpos d'água e estradas.

Portanto, esta segmentação foi a escolhida para a continuidade da pesquisa, a fim de gerar os descritores espaciais, espectrais e de textura com a técnica GEOBIA, resultando na formação do banco de dados relacional a ser utilizado na etapa de seleção de atributos por ACP, com posterior treinamento da SOM.

Para ilustrar o resultado da GEOBIA, na figura 22a está selecionado um objeto gerado a partir da segmentação 4 (figuras 21g e 21h). Com isso, a figura 22b destaca uma parte dos descritores gerados a partir de cada objeto da imagem no banco de dados relacional importado para um SIG.

Figura 22: Ilustração do banco de dados espacial e semântico gerados a partir da segmentação



(a) Vetor selecionado

FID	Shape	REGION ID	AREA	LENGTH	COMPACT	CONVEXITY	SOLIDITY	ROUNDNESS	FORMFACTOR	ELONGATION	RECT FIT	MAINDIR	MAJAXISLEN	MINAXISLEN
295	Polygon	186	300	80	0,244301	1,092129	0,888889	0,473218	0,589049	1,637002	0,608415	17,993398	28,410914	17,355456
296	Polygon	178	312,5	84,482484	0,23811	1,09657	0,862069	0,561586	0,550208	1,120609	0,494265	124,35705	26,617783	23,752971
297	Polygon	191	325	78,284271	0,25985	1,011509	0,962963	0,415116	0,866414	2,236017	0,729012	41,798705	31,572712	14,120067
298	Polygon	1622	575	108,284271	0,249875	1,111822	0,938776	0,485923	0,816236	1,555298	0,593569	123,506546	38,815489	24,959339
299	Polygon	194	2612,5	233,724993	0,246762	1,116763	0,908696	0,491558	0,800974	1,542619	0,595634	24,045677	62,26136	53,318885
300	Polygon	2203	200	64,72136	0,24656	1	1	0,63662	0,589991	1	0,5	0	20	20
301	Polygon	1595	137,5	57,393543	0,230538	1,00647	0,918667	0,441417	0,52455	1,267481	0,43942	24,851981	19,915091	15,712326
302	Polygon	182	100	56,18034	0,200849	1,006611	0,888889	0,20405	0,398145	2,63601	0,423448	140,820284	24,979688	9,476323
303	Polygon	1697	425	84,158548	0,276415	1	1	0,545093	0,75409	1,548648	0,652987	66,677811	31,507806	20,345368
304	Polygon	1938	312,5	117,434165	0,169658	1,136785	0,609756	0,180762	0,284755	2,742095	0,389297	142,0534	46,916538	17,109744
305	Polygon	207	2375	340,525052	0,161487	1,147971	0,655172	0,188137	0,25738	3,69655	0,488147	24,908578	134,108013	36,279239
306	Polygon	190	18062,5	990,283306	0,153139	1,388642	0,615417	0,27869	0,231456	2,06095	0,451106	15,098952	287,265316	139,384906
307	Polygon	184	987,5	158,209172	0,224126	1,016734	0,859686	0,249494	0,495774	3,092891	0,606058	53,324165	70,989432	22,952449
308	Polygon	185	50	30	0,265962	1	1	0,63662	0,698132	2	1	0	10	5
309	Polygon	188	500	116,922014	0,215796	1,156909	0,789231	0,440827	0,459608	1,35717	0,469886	143,117738	38,001941	28,000862
310	Polygon	1930	75	40	0,244301	0,079009	0,857143	0,477465	0,589049	1,333333	0,5	44,999999	14,142136	10,606602
311	Polygon	202	3000	291,375285	0,212111	1,198085	0,759494	0,431958	0,444044	1,748564	0,593216	98,168609	94,036151	53,779073
312	Polygon	193	150	60	0,230329	1,108194	0,857143	0,424413	0,523599	1,5	0,5	134,999998	21,213203	14,142136
313	Polygon	199	10650	1001,569862	0,116265	1,688225	0,553247	0,202601	0,133413	2,529258	0,402463	159,312443	258,707266	102,285816
314	Polygon	189	200	80	0,199471	1,120026	0,695652	0,321961	0,392699	2,280833	0,576749	164,321455	28,123424	12,330329
315	Polygon	196	1650	215,905782	0,212292	1,16989	0,763006	0,42449	0,444801	1,527019	0,509098	158,494943	70,34991	46,070098
316	Polygon	197	1462,5	178,467319	0,241793	1,072681	0,806997	0,473823	0,577017	1,558395	0,579941	79,188346	62,894944	40,226963
317	Polygon	198	175	60	0,248784	1,051321	0,933333	0,493894	0,610865	1,759426	0,682487	8,349622	21,240139	10,072201
318	Polygon	200	900	160,785821	0,210537	1,211656	0,75	0,550091	0,437479	1,133449	0,489696	75,539748	45,641393	40,267698
319	Polygon	195	75	40	0,244301	0,079009	0,857143	0,477465	0,589049	1,333333	0,5	134,999998	14,142136	10,606602
320	Polygon	1529	225	80	0,211571	1,141246	0,72	0,387529	0,441786	1,653671	0,477343	35,782525	27,919049	16,883076
321	Polygon	201	300	72,090552	0,271105	1,01251	0,96	0,480869	0,725395	1,606812	0,581611	49,95114	28,78901	17,916847
322	Polygon	203	1050	171,045151	0,213766	1,118284	0,848485	0,329045	0,451001	2,514663	0,649868	44,11286	63,741463	25,347914
323	Polygon	208	578437,5	6855,871411	0,169144	2,143337	0,795513	0,546301	0,154647	1,320184	0,566443	5,890371	1161,093281	879,493739
324	Polygon	2425	300	74,650533	0,261808	1,004255	0,923077	0,587728	0,676496	1,509906	0,696973	100,647698	25,493395	16,884094
325	Polygon	1809	450	110	0,217605	1,145171	0,75	0,375714	0,467344	1,606489	0,474051	39,621016	39,051046	24,308322
326	Polygon	2237	212,5	64,352408	0,255605	1	1	0,374381	0,644821	2,129018	0,626013	71,431355	26,882976	12,626939
327	Polygon	2065	175	62,118344	0,2403	1,014548	0,933333	0,356989	0,569913	1,666667	0,467297	2,105249	24,983126	14,989875
328	Polygon	205	375	90	0,242789	1,081063	0,909091	0,451599	0,581776	1,820228	0,645608	12,362211	32,515778	17,863572
329	Polygon	206	1425	163,204932	0,260993	1,040065	0,876923	0,681399	0,672292	1,237479	0,652262	171,996953	51,601419	41,698813
330	Polygon	1544	175	60	0,248784	1,067989	0,875	0,528396	0,610865	1,265589	0,525221	59,527301	20,53498	16,225625
331	Polygon	212	875	139,822009	0,238717	1,046343	0,823529	0,34289	0,562428	1,807222	0,486694	75,695869	57,000919	31,540626
332	Polygon	1824	150	60	0,230329	1,108194	0,857143	0,389767	0,523599	1,75	0,535714	108,434947	22,135944	12,64911
333	Polygon	213	2975	398,69169	0,154369	1,517215	0,644986	0,357462	0,235192	1,52852	0,429132	61,969035	102,939871	67,346103
334	Polygon	1933	450	89,385272	0,267791	1,014294	0,947368	0,446687	0,707767	1,606258	0,563518	49,682586	35,814582	22,296901
335	Polygon	1782	25	20	0,282095	1	1	1,27324	0,785398	1	1	89,999999	5	5

(b) Apresentação do vetor selecionado no banco de dados

Fonte: A autora

A próxima etapa é, a partir do banco de dados relacional gerado pela GEOBIA, realizar a ACP para seleção de variáveis, a qual é descrita na próxima seção.


5.2 SEGUNDO EXPERIMENTO: Seleção de variáveis mediante ACP

Com a imagem segmentada (GEOBIA) e mediante os dados semânticos dos descritores⁸, aplicou-se o pré-processamento a eles, ou seja, a normalização, para que os mesmos fiquem na mesma escala, visto que, possuem diferentes unidades de medida. A partir dos descritores normalizados, processou-se a ACP. Ressalta-se que não foram realizados testes no que tange a seleção de descritores, visto que, elencou-se os métodos, a saber, Beale e B4, segundo Jolliffe (1972) e (JOLLIFFE, 1973).

A ACP foi aplicada para reduzir a dimensionalidade do conjunto de dados, obtidos pelo processo de GEOBIA, para vetores de entrada para RNA SOM pelo processo de seleção das CPs. Na tabela do Apêndice B, são apresentados os resultados dos autovalores, variâncias explicadas e acumuladas para as CPs obtidas.

De acordo com a seleção descrita por Jolliffe (1972), as CPs do conjunto de dados estudado, as quais possuem variância (autovalor) maior que 0,7, correspondem as 21 primeiras CPs, ou seja, 42 variáveis podem ser analisadas a partir dessas 21 CPs, garantindo a variabilidade com mais de 90%. As CPs não selecionadas, sendo CP_{22} à CP_{42} expressam menos que 6%, ao todo, da variância total. Com esta seleção do número de CPs a serem utilizadas, o conjunto de dados de 42 variáveis sintéticas (CPs) e 2489 amostras foi reduzido para 21 variáveis sintéticas (CPs) e 2489 amostras, formando o novo conjunto de dados. A figura 23 apresenta o gráfico de barras com a variância explicada para todas as CPs.

Figura 23: Variância explicada das CPs



Fonte: A autora

No gráfico é possível verificar que a maior quantidade de variância explicada é representada na primeira CP, a qual explica 29,96% do total de dados originais. As 21


⁸A nomenclatura é: descritores para GEOBIA, atributos para SIGs e variáveis para análise estatística

primeiras CPs selecionadas para representar os dados apresentam 93,42% da variância explicada. Esse valor é obtido pela curva do gráfico a qual representa a variância acumulada das CPs também descrita na tabela do Apêndice B.

A partir das CPs selecionadas, são extraídas as variáveis originais pelo valor absoluto dos *loadings*⁹, como descrito pelo método B4 de Jolliffe (1972). A tabela presente em Apêndice C, mostra as variáveis originais das CPs. De acordo com os resultados da referida tabela, as variáveis selecionadas, ou seja, variáveis que possuem maior valor absoluto de *loadings* correspondem: Comprimento, Fator Forma, Alongamento, Retangularidade, Direção Principal, Eixo Menor, Razão entre Bandas, Matiz, Variância da Textura, Entropia da Textura, Intervalo de Textura, Saturação, Desvio Padrão dos Valores Digitais Bandas 1, 2, 3, 4 e 5, Média dos Valores Digitais Bandas 3 e 5. Valor Máximo dos Valores Digitais das Bandas 4 e 5. Nota-se que a variável de Razão entre Bandas já havia sido escolhida para CP 3 e CP 7, então escolhe-se a terceira maior *loading* sendo Comprimento para CP 15. O mesmo ocorre com a CP 13, a qual a variável já escolhida da CP 7 é substituída pelo segundo maior *loading*.

Uma forma de analisar a disposição dos dados no novo conjunto de eixos é a partir de gráfico de *scores*, apresentado na figura 24. Este gráfico é formado pela projeção dos objetos nas CPs, sendo possível visualizar um grupo de variáveis correlacionadas com duas CPs.

Figura 24: Gráfico de scores das duas primeiras CPs



Fonte: A autora


⁹Correspondem aos elementos dos autovetores

O gráfico da figura 24a foi elaborado com as duas primeiras CPs, visto que estas apresentam a maior variância dos dados. Devido a base de dados conter muitas variáveis e amostras, a visualização fica comprometida, mas é possível verificar a correlação entre elas, destacadas pelo círculo vermelho, em que variáveis espectrais ficaram todas reunidas.

O uso do gráfico de *scores* é uma alternativa, utilizada para identificar possíveis *outliers*¹⁰ e assim esses dados serem excluídos. Visto que o banco de dados relacional é formado pela GEOBIA, não é possível realizar exclusão de regiões, pois a junção de todas elas formam o mapa da área de estudo. Desta forma, é possível verificar na figura 24b que nenhuma região pode ser selecionada como *outlier*, visto que todas elas são essenciais para o decorrer da pesquisa.

Para visualizar a influência dos descritores selecionados por ACP e do NDVI nas regiões extraídas por GEOBIA, verifica-se na figura 25, a espacialização de 4 descritores que foram considerados relevantes, e analisados perante intervalo de dados.

Figura 25: Ilustração da influência dos descritores espaciais (a), espectrais (b), de textura (c) e NDVI (d) nas regiões da área de estudo



Fonte: A autora

É representado em 25a um descritor espacial, o qual verifica-se que, conforme a legenda, em glebas de cultivo o valor é mais alto. Na figura 25b é um descritor de textura, e mostra que os cultivos de áreas mais homogêneas não possuem valores altos. Há maior relevância em uma região do cultivo de trigo, na estrada, bem como aos arredores da cobertura florestal, por esta região conter vegetação rasteira.

A figura 25c mostra um descritor espectral que se destacou para análise, visto que este é da banda 4 correspondente ao *Red-Edge*, evidenciando as áreas de cultivo, e

¹⁰Valor inconsistente que pode prejudicar a interpretação dos resultados

regiões de corpos d'água com valores baixos. E por fim, a figura 25d exibe a separabilidade dos cultivos milho e trigo com faixa de valores pequena. Para regiões do cultivo aveia, que está bem desenvolvido, e cobertura florestal há valores altos. Em Apêndice D é possível verificar as espacializações do restante dos descritores selecionados por ACP.

Esses resultados da ACP foram obtidos mediante implementação no *software* R, e as operações estão descritas no trecho de código em Apêndice E.

5.3 TERCEIRO EXPERIMENTO: Análise da *u_matrix*


A ferramenta GeoSOM é utilizada para o agrupamento automatizado de dados geográficos, e possui seus parâmetros a serem configurados. Nesta seção é apresentada a análise da *u_matrix* a partir de funções de normalização, a fim de estabelecer qual melhor se aplica no banco de dados relacional.

A figura 26 mostra a influência das funções de normalização nos agrupamentos mediante *u_matrix*, para uma mesma configuração dos parâmetros de treinamento. Estas funções foram detalhadas na seção 4.4. É possível verificar a função *log* na figura 26a que em apenas um neurônio (conforme a seta) todos os objetos correspondentes aos cultivos ficaram juntos. Nesta imagem também nota-se que não há separação entre os neurônios visto que praticamente todos estão em tons azul escuro, ou seja, distância próxima a 0.


Na função *range* em 26b ocorre a separação dos agrupamentos na *u_matrix* porém, alguns cultivos ficaram agrupados num mesmo neurônio, o que também não atinge o objetivo desta pesquisa. Para a função *var*, em 26c, a distância dos agrupamentos ficam próximos de 0, em muitos neurônios.

A função *HistD* em 26e também ilustra que houve confusões entre cultivos, agrupados em apenas um neurônio. Deste modo, a função *HistC* foi a que melhor normalizou os dados, separando todos os objetos de interesse da imagem. É possível verificar um neurônio com distância próxima a 0,5 e que separa um tipo de cultivo dos demais, visto que não há similaridade entre eles, destacado com a seta na figura 26d.


Figura 26: Figuras exemplificando a classe selecionada na imagem à esquerda e o neurônio na u_matrix à direita, mediante as funções de normalização: log (a), range (b), var (c), HistC (d) e HistD (e)




(a) Função log




(b) Função range



(c) Função var



(d) Função HistC



(e) Função HistD

Fonte: A autora

No Apêndice F, há três análises de normalização de variáveis selecionadas por ACP, que demonstram, em forma de histograma, o resultado das funções aplicadas nas variáveis. Em todas é possível verificar a influência da função *HistD* e *HistC*. Concomitante à análise das figuras 26d e 26e, verifica-se, novamente, que a função *HistC* (Equaliza-

ção por histograma contínuo) foi a que melhor normalizou os dados para o processo de classificação.

5.4 QUARTO EXPERIMENTO: Parâmetros de treinamento da SOM

Em se tratando de classificação por RNA, o treinamento desta é crucial, devido o aprendizado ser mediante exemplos. Assim, foram elaborados mapas com diferentes variações de topologia, tamanho, treinamento, funções de vizinhança e aprendizado, até a obtenção do mapa que fosse considerado adequado para análise de resultados, ou seja, que abordasse todas as classes de interesse identificadas pela fotointerpretação da área de estudo, e definidas a campo. No Apêndice G há uma tabela com algumas configurações utilizadas nestes. Os resultados foram analisados a fim de encontrar os melhores parâmetros para o agrupamento dos objetos. Desta forma, o resultado que apresenta a melhor configuração é detalhado a seguir:

- Tamanho da grade: 7 x 7
- Topologia: Hexagonal
- Inicialização dos pesos: Randômica
- Função de Normalização: *HistC*
- Função da taxa de aprendizagem: Linear
- Função do raio de vizinhança: Gaussiana

5.5 QUINTO EXPERIMENTO: Classificação do uso e cobertura da terra

A partir da classificação não-supervisionada RNA SOM, é possível analisar os agrupamentos das regiões de interesse na área de estudo. Para tanto, foi selecionado o resultado de configurações dos parâmetros da SOM que melhor realizou este processo. Devido ao banco de dados relacional possuir topologia, é possível adicionar, na posição adequada, as classes geradas na RNA SOM e suas respectivas regiões.

A tabela 6 mostra o resumo do treinamento SOM, com as configurações apresentadas na seção 5.3. Os valores dos parâmetros de aprendizagem e vizinhança escolhidos foram baseados nas diretrizes da seção 2.6.3.

Tabela 6: Parâmetros finais de treinamento na RNA SOM


Treinamento	N. de épocas	Aprendizagem	Vizinhança
Ordenação	85	0,6	3
Convergência	200	0,06	2

Fonte: A autora

As configurações de rede da tabela 6 geraram um erro topográfico de 0,89. O erro topográfico apresenta a proporção de todos os vetores de entrada para os quais o primeiro e o segundo neurônio vencedor não são unidades adjacentes. Também obteve-se o erro quantitativo de 0,04. Desta forma, verifica-se que o erro quantitativo é pequeno, portanto, o neurônio vencedor está bem ajustado aos vetores de entrada. Já o erro topográfico exibe que os neurônios vencedores (BMU e BMU2) estão próximos, isto é, são unidades adjacentes.

A fim de analisar a influência do NDVI no resultado da classificação, bem como o método de seleção de variáveis mediante ACP, foram feitos 4 testes com os parâmetros estabelecidos anteriormente. O primeiro teste é com o método de seleção de variáveis ACP porém sem as variáveis correspondentes ao NDVI (máximo, mínimo, média e desvio padrão dos valores digitais). É possível verificar na figura 27a que as classes selecionadas estão em vermelho, e estas classes correspondem na *u_matrix* da figura 27b a região do círculo, e que a separação dos objetos não fica evidente. Também verifica-se que a região selecionada com o círculo representa grande confusão nos objetos de cultivo, sendo estes cultivos 1, 2 e 4.

Figura 27: Ilustrações exemplificando a classe selecionada na imagem (a) e na *u_matrix* (b), com ACP e sem NDVI




Fonte: A autora

O segundo teste é sem ACP para seleção de variáveis mediante ACP mas com

todos os descritores do NDVI (máximo, mínimo, média e desvio padrão dos valores digitais). Verifica-se na figura 28b que somente um neurônio (destacado com a flecha) abrange as classes cultivos 1, 2 e 3, conforme exibido na figura 28a. Desta forma, não atinge os objetivos propostos pela pesquisa.


Figura 28: Ilustrações exemplificando a classe selecionada na imagem (a) e na u_matrix (b), sem ACP e com NDVI



Fonte: A autora

O terceiro teste é sem seleção de variáveis mediante ACP e sem nenhum descritor de NDVI. Verifica-se que este teste ilustrado na figura 29a fica semelhante ao anterior, da figura 28, pois somente um neurônio (destacado com a flecha) na figura 29b, os cultivos 1, 2 e 3 ficam agrupadas numa só região.

Figura 29: Ilustrações exemplificando a classe selecionada na imagem (a) e na u_matrix (b), sem ACP e sem NDVI




Fonte: A autora

Já o quarto teste é com ACP e todas as variáveis de NDVI. Verifica-se que, no

teste ilustrado na figura 30, um hexágono (figura 30b) é selecionado e conseguiu distinguir a classe, cultivo 4 das outras, sendo esta o cultivo de trigo.

Figura 30: Ilustrações exemplificando a classe selecionada na imagem (a) e na u_matrix (b), com ACP e com NDVI




Fonte: A autora

Portanto, com os testes adicionais para visualização dos agrupamentos dos objetos, verifica-se a importância da seleção de atributos, visto que há um grande conjunto de dados e atributos, bem como as variáveis de NDVI que auxiliam na separação de cultivos e cobertura florestal, devido as diferenças espectrais das regiões da área de estudo.

Com esses resultados, realizou-se o treinamento da SOM utilizando as variáveis selecionadas por ACP e também as do NDVI (máximo, mínimo, média e desvio padrão dos valores digitais). Após o treinamento, buscou-se analisar as delimitações dos agrupamentos na u_matrix (figura 31) a fim de abranger todas as classes de uso e cobertura da terra que foram estabelecidas pelas fotointerpretação. Assim, encontrou-se 7 regiões com base nas distâncias entre neurônios.

Figura 31: U_matrix - Resultado final dos agrupamentos



Fonte: A autora

As regiões e suas correspondentes classes estão na tabela 7:

Tabela 7: Regiões da u_matrix em função das classes de uso e cobertura da terra


Região	I	II	III	IV	V	VI	VII
Classe	Cultivo 1	Cultivo 2	Cultivo 3	Cultivo 4	Cobertura Florestal	Corpos d'água	Estradas e construções

Fonte: A autora

• Contribuição dos descritores na classificação

Destaca-se que na u_matrix de agrupamento a maior distância entre as células é representada na cor vermelha. Porém, em apresentação individual dos agrupamentos para análise de variáveis, a escala é inversa, quanto mais próxima escala estiver do vermelho, mais próximo estão os agrupamentos. Esta análise é importante para verificar a contribuição dos atributos utilizados no treinamento para cada região classificada. A figura 32 apresenta as $u_matrizes$ de cada atributo utilizado na RNA SOM.

Figura 32: U_matrix do treinamento da SOM por descritores (21 selecionados por ACP e 4 do NDVI)



Fonte: A autora

Desta forma, conforme a figura 32 os descritores que mais se destacaram apresentam-se por flechas rosas. A tabela apresentada no Apêndice H exibe os descritores e suas respectivas regiões com base na figura 32.

Verificou-se que os descritores influenciaram principalmente nas regiões II e III, que correspondem aos cultivos 2 e 3 (glebas de milho e aveia). Também nota-se que as os descritores da banda artificial do NDVI (banda 6), colaboraram principalmente no agrupamento da região V, sendo esta a cobertura florestal, já "Stdband5" e "Maxband6" para classe VI (corpos d'água). Já a classe de estradas e construções, disposta na região VII, teve contribuições de descritores de forma, espectral e de textura. Os descritores "Txen-

tropy" e "Hue" se destacaram por colaborar em todas as regiões da u_matrix , já a variável "Recfit" não colaborou em nenhuma região.

A figura 33, ilustra o resultado da classificação do uso e cobertura da terra, obtido mediante o treinamento da RNA SOM. Os resultados serão validados mediante análise estatística, e apresentados na seção 5.6.

Figura 33: Imagem classificada do uso e cobertura da terra (com ACP e NDVI)



Fonte: A autora

A figura 34 ilustra as áreas demarcadas sobre a imagem classificada, as quais foram fotografadas em campo. Estas áreas assinaladas de 1 a 5 estão exibidas mediante fotografias "in loco", na figura 35.

Figura 34: Ilustração de áreas demarcadas a campo



Fonte: A autora

As áreas de número 1 e 3, da figura 34, estão representadas nas figuras 35b e 35c, respectivamente, ou seja, cultivo milho verificado em campo, mas em ciclos fenológicos diferentes. A área número 2, corresponde à figura 35d, que abrange a classe cultivo 3, sendo aveia, e a classe cobertura florestal ao redor dos corpos d'água (Rio Pitanguí). A área número 4 é ilustrada pela figura 35a, sendo o cultivo de trigo. Já as figuras 35f e 35e, sendo a classe construção e estradas, estão com as áreas demarcadas em 5.

Figura 35: Ilustrações das classes de uso e cobertura da terra verificadas a campo



(a) Cultivo trigo



(b) Cultivo milho (cultivo 1)



(c) Cultivo milho (cultivo 2)



(d) Cultivo aveia (cultivo 3), cobertura florestal e corpos d'água



(e) Estradas



(f) Construções

Fonte: A autora

5.6 Validação

O processo de validação é uma etapa necessária na pesquisa, visto que, há necessidade de analisar a acuracidade da imagem classificada, na forma estatística. A tabela 8 traz os resultados da matriz de confusão bem como os erros de inclusão e omissão, respectivamente.

Tabela 8: Matriz de confusão da classificação

Classe	Cultivo 1	Corpos d'água	Cultivo 2	Cultivo 3	Cobertura Florestal	Cultivo 4	Estradas e construções	Total
Cultivo 1	20	0	0	0	4	0	2	26
Corpos d'água	0	17	0	0	0	0	0	17
Cultivo 2	0	0	19	0	0	0	0	19
Cultivo 3	0	0	1	19	0	0	0	20
Cobertura Florestal	0	3	0	1	16	0	0	20
Cultivo 4	0	0	0	0	0	20	1	21
Estradas e construções	0	0	0	0	0	0	17	17
Total	20	20	20	20	20	20	20	140
Erros de inclusão (%)	23,07	0	0	5	20	4,76	0	
Erros de omissão (%)	0	15	5	5	20	0	15	

Fonte: A autora

Verificou-se na matriz de confusão da tabela 8 que uma amostra pertencente ao cultivo 2 foi classificado como cultivo 3. Houve confusão entre as amostras de corpos d'água com cobertura florestal, provavelmente devido a radiância refletida no canal do visível (bandas vermelho, verde e azul), ou mesmo a sombra que a cobertura florestal faz na água, alterando a sua intensidade.

Os cultivos 1 e 4 foram corretamente classificados nas amostras coletadas para validação, pois a RNA SOM conseguiu discriminar estas classes. Entre as classes estradas e construções e o cultivo 1 os erros de inclusão foram de duas amostras, já para cultivo 4 foi uma amostra. Para esta classe a separabilidade das estradas foi adequada somente na PR 151 (estrada principal), já para os caminhos entre as culturas, estrada de "chão batido" a confusão espectral é evidente na figura 33.

Na subseção 4.6.1 explicitou-se a análise de resultados mediante matriz de confusão e índice kappa. Neste trabalho, o índice kappa foi calculado com resultado em 0.9, conforme tabela 4, considerado excelente pelo valor de referência em Moreira (2011). Complementou-se a análise dos resultados com o teste F para duas variâncias, considerando a imagem do VANT, a VT. Assim, tem-se as hipóteses:

- Hipótese nula (H_0): As regiões da imagem classificada são iguais à verdade de campo (imagem do VANT)
- Hipótese alternativa (H_1): as regiões da imagem classificada são diferentes da verdade de campo (imagem do VANT)

Partindo deste princípio, realizou-se o teste F nas classes: Estradas e construções, Corpos d'água, Cobertura Florestal e Cultivo 3, visto que estas classes podem analisadas como verdade de campo na imagem VANT.

Tabela 9: Teste F - Classes: Estradas e construções, Corpos d'água, Cobertura florestal e Cultivo 3

Classe	Variância VANT	Variância Classificada	gl Num	gl Den	F	valor-P	F crítico
Estradas e construções	44092,96	86707,75	1	6	0,204511	0,666993	5,987378
Corpos d'água	50987,44	216286	1	6	0,029577	0,869107	5,987378
Cob. Florestal	316635,7	129622,4	1	6	0,243652	0,639127	5,987378
Cultivo 3	104944,6	100156,3	1	6	0,141578	0,719663	5,987378
Todas	212192,4	279732,1	1	6	0,101734	0,760571	5,987378

*Cob. = Cobertura, gl = grau de liberdade, Num = numerador, Den = denominador

Nota-se, conforme a tabela 9, que valor de F é menor que F crítico (valor tabelado

consultado em Barbetta, Reis e Bornia (2010)) em todas as análises. O valor p é menor que o nível de significância estipulado em 5%. Portanto, conclui-se que, a hipótese H_0 é aceita, determinando que todas as áreas (regiões) da análise são iguais à verdade de campo.

Ressalta-se aqui, a importância de realizar dois testes de acuracidade, sendo o primeiro com o nível de abstração no pixel, e o segundo com abordagem baseada no objeto (regiões). Assim, verificou-se que os resultados foram satisfatórios na abordagem de pixel, com exatidão de 91% verificadas na matriz de confusão. Já para abordagem baseada no objeto, o teste F pareada entre áreas do VANT e áreas de classificação, no nível de significância de 5%, com valor p próximo a 1, e valor de F menor que F crítico, resultando em áreas classificadas de forma igual.

6 CONSIDERAÇÕES FINAIS

A presente pesquisa realizou a classificação do uso e cobertura da terra mediante técnica de RNA não-supervisionada SOM. Para tanto, testou-se os parâmetros de configuração da GEOBIA, bem como a ACP na redução de dimensionalidade.

Para a realização da pesquisa foram levantados diversos artigos científicos, teses, dentre outros, em relação às metodologias sobre GEOBIA aplicada na classificação de imagens orbitais. Dentre eles, cita-se Gonzalez e Woods (2000), Richards e Jia (2006), Antunes (2003), Baatz e Schape (2000), Becker, Ostermann e Pahl (2012), Blaschke, Lang e Hay (2008), Blaschke e Kux (2007), Blaschke (2010), Marinho, Fasbender e Kok (2012), Papadias e Theodoridis (1997) e Vieira *et al.* (2012). Ressalta-se que estes materiais deram suporte ao conhecimento no estudo de segmentação, análise orientada a objeto para fins de classificação de imagem orbital, e ainda na verificação da acuracidade em classificação com nível de abstração em regiões. Destaca-se que, este material metodológico é recente, e os métodos de GEOBIA encontram-se em desenvolvimento, portanto, os testes realizados nesta pesquisa são relevantes no contexto aplicado.

O NDVI, aplicado na imagem orbital, auxiliou a separação das classes, principalmente em se tratando de cultivos agrícolas, bem como cobertura florestal e corpos d'água. Desta forma, foi possível realizar a fotointerpretação, a partir das composições coloridas mediante as bandas espectrais da Rapideye e NDVI, a fim de delimitar o número de classes de interesse na imagem.

Com a capacidade da GEOBIA em particionar regiões (objetos), foi possível realizar a segmentação da área de estudo, encontrando os valores de escala e fusão que melhor representassem a separação dos mesmos. Assim, obteve-se os descritores espectrais, espaciais e de textura dispostos em um banco de dados relacional. Destaca-se a importância do processo de segmentação, mediante escolha dos parâmetros de escala e fusão, de forma que não haja perda de informação dos objetos de interesse, auxiliando diretamente no processo de classificação.

Realizar a seleção de atributos pela técnica de ACP possibilitou a redução da dimensionalidade dos dados, separando aqueles descritores mais significativos no banco de dados relacional gerados pela GEOBIA. Assim, verificou-se que, com as 21 variáveis selecionadas, no processo de classificação obteve-se melhores resultados daqueles testes utilizando todas as 42 variáveis.

A abordagem de RNA não-supervisionada SOM pode reduzir significativamente a

complexidade da análise, tornando possível a utilização de técnicas que são normalmente consideradas complexas para o processamento de imagens de SR. Além disso, o método apresenta outras vantagens tais como a integração de dados de diferentes escalas e origens. A ferramenta GeoSOM possibilitou mediante a *u_matrix* a definição dos agrupamentos, determinando todas as classes de interesse definidas na etapa de fotointerpretação, contribuindo inclusive na separabilidade de um mesmo cultivo em ciclos fenológicos diferentes, sendo os cultivos 1 e 3.

A *u_matrix* também auxiliou na verificação das interferências dos descritores de GEOBIA e o NDVI no decorrer do aprendizado da rede, facilitando a interpretação e validação dos resultados.

Com base nos testes realizados com seleção de variáveis mediante ACP, bem como utilização dos descritores do NDVI, verificou-se que ambos os métodos auxiliaram diretamente no processo de classificação de cobertura e uso da terra, sendo esse o principal objetivo do trabalho.

O conhecimento a campo auxiliou na seleção das amostras para validação da classificação. Assim, foi possível analisar os resultados mediante matriz de confusão, com nível de abstração no pixel, sendo esta técnica consagrada em análises de classificação de uso e cobertura da terra. O índice kappa auxiliou para descrever e testar o grau de concordância, com valor de 0,90, resultado de qualidade excelente na classificação, destacando a eficiência dos métodos utilizados no objetivo de estudo.

A imagem do VANT, também obtida em visita a campo, colaborou na validação dos resultados em abordagem baseada no objeto (regiões). Desta forma, mediante o teste F, para duas variâncias, verificou-se que a hipótese foi aceita, com nível de significância de 5%. Isto demonstra que as áreas classificadas são iguais às áreas do VANT.

Conclui-se que os métodos utilizados no estudo atingiram os objetivos propostos na pesquisa, com resultados satisfatórios, visto que apresentaram eficiência e agilidade na classificação do uso e cobertura da terra em escala detalhada.

6.1 Trabalhos Futuros

Como trabalhos futuros, pretende-se:

- Utilizar a RNA SOM, a fim de fazer classificação em duas unidades de paisagem, de mesmo local, porém em épocas diferentes.

- Testar no mesmo banco de dados relacional, outros métodos de seleção de variáveis.
- Testar outras técnicas de segmentação na extração de características de imagens e comparar o resultado com a abordagem GEOBIA.
- Comparar o resultado da RNA SOM com outros classificadores para a mesma área de estudo.
- Fazer validação associada aos relacionamentos topológicos tais como contido, disjunto ou sobreposto, tomando como verdade de campo a imagem do VANT, conforme já pesquisado em Egenhofer e Herring (1990) e Papadias e Theodoridis (1997).

REFERÊNCIAS

- AKSOY, S.; AKÇAY, H. G.; WASSENAAR, T. Automatic mapping of linear woody vegetation features in agricultural landscapes using. *IEEE Transactions on Geoscience and Remote Sensing*, v. 48, n. 1, p. 511 – 522, 2010.
- ANTUNES, A. F. B. *Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial*. Dissertação (Mestrado) — Pós Graduação em Ciências Geodesicas, Curitiba, 2003.
- ASSAD, E. D.; SANO, E. E. *Sistema de informações geográficas. Aplicações na agricultura*. 2. ed. Brasília: Embrapa, 1998.
- BAATZ, M.; SCHAPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: _____. Heidelberg: Herbert Wichmann Verlag, 2000. cap. Beitrage zum AGIT Symposium Salzburg, p. 12–23.
- BARBETTA, P. A.; REIS, M. M.; BORNIA, A. C. *Estatística para cursos de engenharia e informática*. [S.l.]: Editora Atlas, 2010.
- BEALE, E. M. L. *et al.* The discarding of the variables in multivariate analasys. *Biometrika*, n. 54, p. 357–365, 1967.
- BECKER, C.; OSTERMANN, J.; PAHL, M. Automatic quality assessment of gis data base an object coherence. In: *Procedings of the 4th GEOBIA*. Rio de Janeiro: [s.n.], 2012.
- BLASCHKE, T. Object based image analysis for remote sensing. *Journal of Photogrammetry and Remote Sensing*, n. 65, p. 2–16, 2010.
- BLASCHKE, T.; KUX, H. *Sensoriamento e SIG avançados: novos sistemas sensores: métodos inovadores*. 2. ed. São Paulo: Oficinas de Textos, 2007.
- BLASCHKE, T.; LANG, S.; HAY, G. *Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline*. New York, 2008.
- BOGNOLA, I. A. *et al.* *Caracterização dos solos do município de Carambeí, PR. EMBRAPA/CNPS*. Rio de Janeiro, 2002.
- BURROUGH, P. P. *Principles of Geographical Information Systems for Land Resources Assesment* Claredon Press. England: Oxford, 1992.
- CENTENO, J. A. S. *Sensoriamento Remoto e Processamento de Imagens Digitais*. Curitiba: Universidade Federal do Paraná, 2004.
- CHON, T. S. *et al.* Patternizing communities by using an artificial neural network. *Ecological Modelling*, v. 90, p. 69–78, 1996.
- CONGALTON, R. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, v. 49, n. 12, p. 1671–1678, 1991.

- DEMATTE, J. A. M. *et al.* Fotopedologia, espectroscopia e sistema de informação geográfica na caracterização de solos desenvolvidos do grupo barreiras no amapá. *Bragantia*, v. 71, n. 3, p. 438–446, 2012.
- EGENHOFER, M. J.; HERRING, J. R. A mathematical framework for the definition of topological relationships. In: *4th International Symposium on Spatial data halding*. [S.l.: s.n.], 1990. p. 803–813.
- EMBRAPA. *Centro Nacional de Pesquisa de Florestas. Zoneamento Ecológico para Plan-tios Florestais no Estado do Paraná*. Brasília, 2006.
- FACON, J. *Processamento e Análise de Imagens*. [S.l.]: Pontifícia Universidade Católica do Paraná, 2002.
- FISCHLER, M. A.; FIRSCHEIN, O. *Intelligence: The Eye, The Brain and The Computer*. [S.l.]: Addison-Wesley, 1987.
- FLORENZANO, T. G. *Iniciação em sensoriamento remoto*. São Paulo: Oficinas de Textos, 2007.
- FREITAS, R. M. *et al.* Análise exploratória de dados multitemporais de sensoriamento remoto usando mapas auto-organizáveis: estudo em áreas de expansão da cana-de-açúcar. In: *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*. Natal: [s.n.], 2009. p. 7797–7804.
- GALO, M. L. T. B. *Interpretação de Imagem Aplicada à Geografia*. FCT/Unesp, 2009.
- GARCIA, G. L. *Sensorimento Remoto: Princípios e Interpretação de Imagens*. [S.l.]: Editora Nobel, 1982.
- GEALH, A. M.; MELO, M. S.; MORO, R. S. *Pitangui, Rio de Contrastes: seus lugares, seus peixes, sua gente*. Ponta Grossa: Ed. UEPG, 2010.
- GEMAEL, C. *Introdução ao ajustamento de observações*. [S.l.]: Editora UFPR, 1994.
- GONÇALVES, M. L. *et al.* Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. *Revista Brasileira de Cartografia (RBC)*, v. 60, p. 17–29, 2008.
- GONZALEZ, R.; WOODS, R. *Processamento de Imagens Digitais*. 3. ed. São Paulo: Edgard Blucher Ltda, 2000.
- HAIR, J. F. *et al.* *Análise Multivariada de dados*. 6. ed. Porto Alegre: Bookman, 2009.
- HAYKIN, S. *Redes Neurais: princípios e prática*. 2. ed. Porto Alegre: Bookman, 2001.
- HE, H.; HUANG, S. Fnea and d-s based remote sensing approach of land-use classification. *Communications in Information Science and Management Engineering*, v. 2, n. 5, p. 54–60, 2012.
- HENRIQUES, R.; BAÇÃO, F.; LOBO, V. Exploratory geospatial data analysis using the geosom suite. *Computers, Envirnmnt and Urban Systems*, v. 36, p. 218–232, 2012.

HU, X.; WENG, Q. Estimating impervious surfaces from medium spatial resolution imagery using the self-organizing map and multi-layer perceptron neural networks. *Remote Sensing of Environment*, n. 113, p. 2089 – 2102, 2009.

ITT VIS (VISUAL INFORMATION SOLUTIONS). *ENVI Feature Extration Module 4.6*. [S.l.], 2008.

JENSEN, J. R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. 2nd. ed. São José dos Campos: [s.n.], 2009.

JIANG, J. *et al.* Application of back propagation neural network in the classification of high resolution remote sensing image. In: *International Conference on Geoinformatics*. Beijing, China: [s.n.], 2010.

JOHNSON, R. A.; WICHERN, D. W. *Applied Multivariate Statistical Analysis*. 6. ed. [S.l.]: Pearson/Prentice Hall, 2007.

JOLLIFFE, I. T. Discarding variables in a principal component analysis. i: Artificial data. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, v. 21, n. 2, p. 160–173, 1972.

JOLLIFFE, I. T. Discarding variables in a principal component analysis. ii: Real data. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, v. 22, n. 1, p. 21–31, 1973.

JOLLIFFE, I. T. *Principal Component Analysis*. 2. ed. New York: Springer Series in Statistics, 1986.

JR, O. L.; COSTA, M. M. E. *Redes Neurais: Fundamentos e Aplicações com Programas em C*. Rio de Janeiro: Editora Ciência Moderna Ltda, 2007.

KOEPFLER, G.; LOPES, C.; MOREL, J. M. A. A multiscale algorithm for image segmentation by variational method. *SIAM Journal of Numerical Analysis*, v. 31, n. 1, p. 282–299, 1994.

KOTZ, S.; JOHNSON, N. *Encyclopedia of statistical sciences*. New York: John Wiley e Sons, 1983.

LEITE, T. A. *et al.* Delimitação das áreas de Preservação Permanente (APP) com o uso de geoprocessamento como subsídio à gestão dos recursos hídricos na bacia do Rio Jacaré. Sergipe: III Encontro de Recursos Hídricos, 2010. 34-38 p.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. *Remote Sensing and Image Interpretation*. [S.l.]: John Wilwy e Sons, 2007.

LIU, W. T. H. *Aplicações de Sensoriamento Remoto*. Campo Grande: Ed. Uniderp, 2006.

LOPES, L. H. M. Uso e cobertura do solo no município de tailândia- pa utilizando o tm/landsat e técnica de classificação não-supervisionada. *ENGEVISTA*, v. 10, n. 2, p. 126–132, 2008.

LU, D. *et al.* Land use/cover classification in the brazilian amazon using satellite images. *Pesquisa Agropecuária Brasileira*, v. 47, n. 9, 2011.

- MAACK, R. *Geografia física do Estado do Paraná*. Curitiba: Imprensa Oficial, 2002.
- MARINHO, E.; FASBENDER, D.; KOK, R. D. Spatial assessment of categorical maps a proposed framework. In: *Proceedings of the 4th GEOBIA*. Rio de Janeiro: [s.n.], 2012.
- MENESES, P.; ALMEIDA, T. *Introdução ao processamento de imagens de sensoriamento remoto*. 1st. ed. Brasília: CNPQ, 2012.
- MOREIRA, M. A. *Fundamentos do Sensoriamento e Metodologia de Aplicação*. 3. ed. [S.l.]: Editora UFV, 2011.
- MOREIRA, M. A.; SHIMABUKURO, Y. E. *Cálculo do índice de vegetação a partir do sensor AVHRR*. São Paulo, 2004. 79-101 p.
- MORO, R. S. *A vegetação dos Campos Gerais da escarpa devoniana*. Editora da uepg. Espaço e Cultura: Ponta Grossa e os Campos Gerais, 2001.
- NUCLEAM. *Bacia Hidrográfica do Manancial Alagados*. [S.l.], 2002.
- PAPADIAS, D.; THEODORIDIS, Y. Spatial relations, minimum bounding rectangles, and spatial data structures. *International Journal of Geographical Information Science*, v. 11, n. 2, p. 111–138, 1997.
- PEARSON, R. L.; MILLER, L. D. Remote mapping of standing crop biomass for estimation of the productivity of the short-grass prairie, pawnee national grasslands, colorado proc. In: *8th International Symposium on Remote Sensing of Environment, ERIM International*. Michigan, USA: [s.n.], 1972. p. 1357–1381.
- RICHARDS, J. A.; JIA, X. *Remote Sensing Digital Image Analysis - An Introduction*. 4. ed. Germany: Springer, 2006.
- ROBBINSON, D.; REDDING, N.; CRISP, D. *Implementation of a Fast Algorithm for Segmenting SAR Imagery*. [S.l.]: DSTO - Electronics and Surveillance Research Laboratory, 2002.
- ROCHA, H. C.; NETO, P. H. W. Padrões de uso das terras e implicações ambientais. In: GEALH, A.M.; MELO, M.S.; MORO, R.S (ORGS). *Pitangui, Rio de Contrastes: seus lugares, seus peixes, sua gente*. Ponta Grossa: Ed. UEPG, 2010. cap. 2, p. 23–41.
- ROUSE, J. W. *et al. Monitoring the vernal advancement of retrogradation (greenwave effect) of natural vegetation*. [S.l.]: NASA/GSFC, Type III, 1974.
- RUDORFF, B. F. T.; MOREIRA, M. A. *Sensoriamento Remoto Aplicado à Agricultura*. São José dos Campos, 2002.
- SINGH, D. *et al. Environmental degradation analysis using noaa/avhrr data*. *Advances in Space Research*, v. 37, p. 720–727, 2006.
- SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, analisys and Machine Vision*. USA: Brooks/Cole Publishing Company, 1998.
- STEFFEN, C. A.; MORAES, E. C. Tutorial de radiometria. In: REMOTO/INPE, C. S. L.-A. de S. (Ed.). *Simpósio Brasileiro de Sensoriamento Remoto*. Curitiba: [s.n.], 1993. p. 2–12.

TAFNER, M. A.; XEREZ, M. de; FILHO, I. W. R. *Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação*. Blumenau: Editora da FURB, 1995.

TSO, B.; MATHER, P. *Classification methods for remotely sensed data*. 2. ed. [S.l.]: CRC Press, 2009.

VASCONCELOS, C. H.; NOVO, E. M. L. M. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens - fração solo, sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do sensor tm/landsat5, na região do reservatório do tucuruí - pa. *Acta Amazônica*, v. 34, n. 3, p. 487–493, 2004.

VELOSO, H. P.; FILHO, A. L. R. R.; LIMA, J. C. A. *Classificação da vegetação brasileira, adaptada a um sistema universal*. Rio de Janeiro: IBGE: Departamento de Recursos Naturais e Estudos Ambientais, 1991.

VESANTO, J. *et al.* *SOM Toolbox for Matlab 5*. April 2000. Disponível em: <<http://www.cis.hut.fi/projects/somtoolbox>>.

VICENTE, L. E. *et al.* Mapeamento de características de solos tropicais utilizando self-organizing map aplicado à dados hiperespectrais. In: *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*. Foz do Iguaçu: [s.n.], 2013.

VIEIRA, M. A. *et al.* Object based image analysis and data mining applied to a remotely sensed landsat time-series to map sugarcane over large areas. *Remote Sensing of Environment*, v. 123, p. 553–562, 2012.


WEICHELT, H. *et al.* *The RapidEye Red Edge Band*. [S.l.]: BlackBridge - Delivering the World.

WEISS, C. V. C. *et al.* Mapeamento do uso e ocupação do solo utilizando imagens de satélite do sensor tm/landsat 5 no litoral sul do rio grande do sul, brasil. In: *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*. Foz do Iguaçu: [s.n.], 2013.


YUAN, H.; WIELE, C. F. V. D.; KHORRAM, S. An automated artificial neural network system for land use/land cover classification from landsat tm imagery. *Remote Sensing*, v. 1, p. 243–265, 2009.

ZILLER, S. R.; GALVÃO, F. A degradação da estepe gramíneo-lenhosa no paraná por contaminação biológica de pinus elliotti e p. taeda. *Revista Floresta*, Curitiba, v. 32, n. 1, p. 41–47, 2002.


APÊNDICE A – Composições coloridas da Rapideye




(a) Bandas 1 2 e 6




(b) Bandas 1 3 e 5




(c) Bandas 1 3 e 6




(d) Bandas 1 4 e 5




(e) Bandas 1 4 e 6




(f) Bandas 1 5 e 6




(g) Bandas 2 3 e 4




(h) Bandas 2 3 e 5




(i) Bandas 2 3 e 6




(j) Bandas 2 4 e 5




(k) Bandas 2 4 e 6




(l) Bandas 3 4 e 5



(m) Bandas 3 4 e 6



(n) Bandas 3 5 e 6



(o) Bandas 4 5 e 6

Banda 1 = Azul, Banda 2 = Verde, Banda 3 = Vermelho, Banda 4 = *Red-Edge*

Banda 5 = Infravermelho próximo, Banda 6 = NDVI

APÊNDICE B – Autovalores, variância explicada e acumulada

CPs	Autovalor	Variância explicada	Variância acumulada
1	3,547	29.96	29,96
2	2,315	12.76	42,72
3	1,775	7,339	50,064
4	1,604	6,131	56,195
5	1,320	4,151	60,345
6	1,210	3,490	63,83
7	1,174	3,283	67,118
8	1,091	2,837	69,956
9	1,073	2,741	72,697
10	1,006	2,410	75,11
11	0,985	2,312	77,418
12	0,935	2,083	79,501
13	0,927	2,047	81,548
14	0,905	1,951	83,499
15	0,868	1,798	85,297
16	0,821	1,605	86,902
17	0,784	1,465	88,366
18	0,759	1,374	89,740
19	0,727	1,261	91,002
20	0,721	1,238	92,239
21	0,703	1,180	93,42
22	0,681	1,105	94,524
23	0,636	0,964	95,488
24	0,610	0,888	96,376
25	0,527	0,663	97,039
26	0,468	0,522	97,561
27	0,429	0,439	98
28	0,416	0,413	98,413
29	0,355	0,301	98,714
30	0,337	0,270	98,99
31	0,309	0,228	99,212
32	0,295	0,208	99,420
33	0,249	0,149	99,569
34	0,228	0,124	99,693
35	0,195	0,091	99,784
36	0,180	0,077	99,861
37	0,173	0,072	99,933
38	0,128	0,039	99,973
39	0,100	0,024	99,997
40	0,036	0,003	100,0
41	0,006	0000	100,0
42	$1,35e^{-12}$	0000	100,0


APÊNDICE C – Matriz de autovetores

Variável	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC11
Area	-0,2026	0,006	-0,2282	0,0324	-0,082	0,1764	-0,069	0,2023	-0,0416	0,0676	-0,0634
Length	-0,1068	0,1018	0,0213	0,0765	0,3819	-0,0736	-0,1364	-0,0054	0,2688	0,2149	0,1015
Compact	-0,117	0,3165	0,2449	-0,0732	-0,1225	0,0444	-0,0158	0,0321	-0,0549	0,003	-0,0314
Convexity	-0,0812	-0,2417	-0,2542	0,0129	-0,0365	-0,1373	-0,2899	-0,0967	0,1515	0,0973	0,0146
Solidity	-0,1646	0,2765	0,1347	-0,0024	-0,0195	0,1271	0,1331	0,112	-0,057	0,0521	-0,0285
Roundness	-0,1243	0,2477	0,1597	-0,1051	-0,2412	-0,0535	-0,3631	-0,031	0,0577	0,0723	0,0235
Formfactor	-0,1163	0,3169	0,2452	-0,0727	-0,121	0,0453	-0,013	0,0323	-0,0552	-0,0009	-0,0327
Elongation	-0,0449	-0,1398	-0,1541	0,1464	0,2191	0,1874	0,5988	0,1035	-0,0799	-0,0363	-0,0778
RectFit	-0,0961	0,2194	0,165	-0,0224	-0,1518	0,1552	0,2707	0,0297	-0,0394	0,0215	-0,0111
Maindir	-0,063	0,0233	-0,0097	0,018	-0,1452	-0,0441	0,2138	-0,2909	0,3785	0,106	0,128
Majaxislen	-0,0614	-0,2035	-0,1435	-0,0249	-0,3967	0,0267	0,2062	0,0016	-0,1027	-0,091	-0,1329
Minaxisleg	-0,0863	-0,1226	-0,142	-0,047	-0,4952	0,0256	0,0316	0,0854	-0,0721	-0,013	0,0318
Numholes	-0,2134	0,0432	-0,2693	0,0531	0,0345	0,1485	-0,1224	0,2012	0,0221	0,1442	-0,0035
Holesolrat	-0,2151	0,0424	-0,267	0,0541	0,0345	0,1468	-0,1197	0,1986	0,0246	0,1431	-0,005
Bandratio	-0,0301	0,0821	-0,2951	-0,2359	-0,0488	0,0663	-0,0643	-0,1903	0,1008	-0,0864	-0,2243
Hue	-0,0238	-0,0629	0,1135	0,2575	0,017	-0,2262	0,0579	-0,1412	-0,15	0,5955	-0,303
Saturation	-0,0899	-0,2803	0,1634	-0,1531	0,0135	-0,0019	-0,0358	-0,0422	0,0526	0,1939	-0,0202
Intensity	-0,0731	0,3042	-0,2209	0,0117	0,1768	-0,0763	0,0611	-0,0246	0,0759	-0,1568	0,009
TxRange	-0,0414	-0,1167	0,2201	0,1283	0,0678	0,1502	0,1533	0,0368	0,2937	0,1271	0,2176
TxMean	0,2347	0,0064	0,084	0,227	-0,0197	0,0662	-0,0417	0,0056	0,0166	-0,0457	0,0281
TxVarianc	-0,0662	-0,0067	-0,1208	0,0186	-0,0294	-0,0835	0,0497	-0,1979	-0,3592	0,0945	0,7513
TxEntropy	-0,1758	0,0592	-0,1636	0,0713	0,0716	0,14	-0,0195	0,1128	0,1489	0,0799	-0,0534
Minband1	0,1646	0,1855	-0,156	0,2866	0,0357	0,1419	-0,1106	0,134	0,0177	-0,036	0,0668
Maxband1	0,1646	-0,1509	0,0802	0,2821	-0,135	0,2106	-0,1773	0,1307	-0,0422	0,1514	0,0293
Avgband1	0,2514	0,0077	0,0726	0,2072	-0,0504	0,0671	-0,0665	0,0226	-0,0077	-0,0382	0,046
Stdband1	-0,073	0,0589	-0,1417	0,0303	0,2166	-0,1651	-0,1102	-0,1826	-0,4742	-0,1295	-0,0024
Minband2	0,2322	0,1757	-0,1518	-0,0066	0,0109	-0,0528	0,0353	0,0244	0,0147	0,0841	-0,04
Maxband2	0,2326	-0,0547	-0,0796	-0,2313	-0,042	0,1084	-0,0637	0,0551	0,0216	0,0543	-0,0111
Avgband2	0,267	0,0586	-0,0482	-0,1025	-0,0034	-0,0179	0,0251	0,0009	0,0064	0,0534	-0,0187
Stdband2	-0,0114	-0,1466	0,1715	-0,2451	0,2671	0,2849	-0,0935	0,0198	-0,0557	-0,0319	-0,0202
Minband3	0,2278	0,1653	-0,1293	0,1437	-0,0009	0,0588	-0,0356	0,0541	0,0339	-0,0867	0,0078
Maxband3	0,2414	-0,1028	0,0319	0,0164	-0,0746	0,1377	-0,1261	0,0789	-0,0039	0,0109	-0,0059
Avgband3	0,2695	0,0226	0,0267	0,0678	-0,0241	0,0567	-0,0289	0,0136	0,0296	-0,0776	0,0179
Stdband3	-0,0319	-0,1208	0,1586	-0,0579	0,1697	0,0734	-0,1188	0,1825	-0,3979	0,0082	-0,2212
Minband4	0,2132	0,1689	-0,1159	-0,1304	0,052	-0,1643	0,1008	0,0501	0,0131	0,1076	-0,0782
Maxband4	0,1657	-0,0338	-0,0419	-0,3262	0,038	-0,0634	0,0636	0,1557	0,0952	0,049	0,0551
Avgband4	0,2338	0,0749	-0,0638	-0,2275	0,0276	-0,1225	0,0826	0,0566	0,0104	0,1	-0,0367
Stdband4	-0,0671	-0,168	0,0768	-0,2744	0,1497	0,2767	-0,0752	-0,072	0,099	-0,1707	0,1184
Minband5	-0,0935	-0,0599	0,1302	0,0598	0,0676	-0,365	0,0273	0,4487	0,0677	-0,2466	0,0753
Maxband5	-0,055	0,0078	0,0384	0,2586	0,0449	0,1967	-0,081	-0,4955	0,0421	-0,3144	-0,2326
Avgband5	-0,1082	-0,1151	0,0796	0,2033	-0,0655	-0,2088	-0,093	0,2028	0,1293	-0,3381	0,0378
Stdband5	-0,0673	-0,1122	0,02	0,026	0,0208	-0,3731	0,0445	-0,0163	0,1004	-0,1189	-0,1942


Variável	PC12	PC13	PC14	PC15	PC16	PC17	PC18	PC19	PC20	PC21
Area	0,0105	0,025	0,019	-0,1003	-0,0183	0,0483	0,095	0,0199	0,1969	-0,1951
Length	-0,1059	-0,0423	-0,2062	0,3167	0,0778	-0,3316	0,0521	-0,1448	-0,2613	0,1817
Compact	-0,0214	-0,0323	-0,0015	-0,0609	-0,1217	-0,0138	0,154	-0,0389	-0,0385	0,0108
Convexity	-0,0124	-0,0366	0,0016	0,0227	0,2337	-0,0461	-0,2186	0,1486	0,0161	-0,0678
Solidity	-0,0078	-0,0086	-0,1081	0,0304	-0,0944	-0,0358	0,1699	-0,0424	0,0287	-0,0259
Roundness	-0,0274	0,01	-0,0062	-0,0322	0,1529	-0,0133	-0,164	0,0693	0,0333	-0,0284
Formfactor	-0,023	-0,0324	-0,0005	-0,0615	-0,1219	-0,0134	0,1543	-0,0432	-0,038	0,0125
Elongation	-0,0561	-0,0478	-0,1777	0,1356	0,0669	-0,0208	-0,0588	0,0101	-0,0035	-0,0272
RectFit	-0,0517	0,0345	-0,318	0,2022	0,2832	-0,0604	-0,3477	0,1562	0,1432	-0,0367
Maindir	0,7384	0,255	-0,0233	0,0298	-0,0798	0,088	-0,0008	-0,0126	0,0395	-0,0135
Majaxislen	0,0233	-0,116	0,1401	-0,1476	-0,0991	-0,0986	0,2421	-0,0447	-0,1764	0,1499
Minaxisleg	-0,0924	-0,062	0,0156	0,0033	0,2858	-0,1267	-0,2598	-0,1361	-0,1912	0,1004
Numholes	0,046	0,0627	-0,0162	-0,0201	-0,0085	0,0019	0,0996	-0,0374	0,1358	-0,1298
Holesolat	0,0445	0,0589	-0,0142	-0,0219	-0,0073	7,14e	0,1006	-0,036	0,1314	-0,128
Bandratio	-0,2125	0,0579	0,0111	0,3839	-0,4607	0,1354	-0,1187	0,2089	0,1624	0,2681
Hue	-0,0685	-0,2524	0,0486	-0,0038	-0,039	0,3779	-0,0025	0,1081	-0,0366	-0,0886
Saturation	0,0129	-0,1606	-0,0936	0,027	0,0017	-0,1777	0,2464	-0,0219	0,0665	-0,0168
Intensity	-0,0046	-0,0681	0,1646	-0,1375	0,1439	0,069	-0,1186	0,0089	-0,1376	-0,1212
TxRange	-0,2531	0,0252	0,453	-0,2697	-0,291	-0,2984	-0,3005	0,0405	0,2266	-0,0625
TxMean	0,0224	0,0068	-0,0473	-0,0843	0,0191	-0,0099	-0,0065	0,0477	-0,162	0,1723
TxVarianc	-0,1938	0,1776	0,064	0,1497	0,0034	0,1796	0,2068	-0,0406	0,0133	0,0334
TxEntropy	0,0203	0,024	0,0926	-0,1799	0,0138	4,19e	0,1128	-0,0691	-0,354	0,502
Minband1	0,0596	0,0366	-0,0475	-0,1163	0,0181	0,0922	0,0133	0,0738	-0,032	-0,1141
Maxband1	0,0754	0,0489	-0,2119	0,017	-0,0688	-0,062	0,0788	0,0327	0,0857	0,0529
Avgband1	0,0193	0,0093	-0,084	-0,0415	0,0101	0,0105	-0,0291	0,055	-0,0824	0,0406
Stdband1	0,294	-0,2562	-0,2049	-0,2879	-0,2153	-0,3728	-0,1982	0,019	0,1585	0,1055
Minband2	-0,0213	-0,0105	0,0663	-0,0312	0,0032	0,0479	-0,0038	-0,0593	-0,0062	-0,0308
Maxband2	0,0089	0,0237	-0,098	0,0919	-0,0625	-0,0871	0,1	-0,0732	0,1455	0,0486
Avgband2	-0,0149	-0,0024	0,0162	0,0006	0,004	0,0048	0,0154	-0,045	0,002	0,0268
Stdband2	0,074	-0,0063	0,0176	-0,1843	0,25	0,4051	-0,1302	-0,3778	0,29	0,3086
Minband3	-0,0308	0,0107	0,0163	-0,0152	-0,0305	0,0734	-0,0164	0,0353	0,0295	-0,0391
Maxband3	0,0146	0,0313	-0,1104	0,0977	-0,0801	-0,0711	0,0828	0,0321	0,0978	0,0186
Avgband3	-0,033	0,0142	-0,0173	0,0159	-0,0277	0,0084	-0,0162	0,0408	-0,0016	0,0359
Stdband3	0,2086	0,4874	0,351	0,275	-0,0234	-0,1162	-0,1359	0,038	-0,2858	-0,1465
Minband4	-0,0108	-0,0035	0,1643	-0,0362	0,0888	0,0027	0,0128	-0,1315	0,0153	-0,0338
Maxband4	0,0473	-0,1349	-0,0276	0,0061	0,0999	-0,2186	0,1983	-0,0403	0,0133	-0,2992
Avgband4	0,0141	-0,0394	0,1146	-0,0325	0,0851	-0,0239	0,0506	-0,0634	-0,0212	-0,0559
Stdband4	-0,026	-0,1536	-0,1807	-0,1892	-0,1013	0,2496	0,0152	0,385	-0,4161	-0,2776
Minband5	0,1272	-0,1022	0,1483	0,1084	0,1675	0,0891	0,1939	0,4694	0,2478	0,2747
Maxband5	-0,0948	-0,0368	0,2277	0,1307	0,3304	-0,135	0,3556	-0,0288	0,1689	-0,1295
Avgband5	0,0331	-0,2449	-0,047	0,2686	-0,2735	0,2016	-0,1272	-0,5149	-0,0669	-0,2333
Stdband5	-0,3038	0,5885	-0,3701	-0,3585	-0,0251	0,0157	0,1	-0,0785	0,0466	-0,0552

APÊNDICE D – Ilustração dos atributos selecionados por ACP


1 - Descritores espaciais selecionados por ACP




(a) Perímetro




(b) Fator de forma



(c) Retangularidade




(d) Direção principal




(e) Eixo menor

2 -Descritores de textura selecionados por ACP




(a) Variância da textura




(b) Entropia da textura


3 - Descritores espectrais selecionados por ACP




(a) Razão entre bandas




(b) Matiz




(c) Max níveis digitais banda 1




(d) Desvio pad. níveis digitais banda 1




(e) Desvio pad. níveis digitais banda 3




(f) Média dos níveis digitais banda 4




(g) Desvio pad. níveis digitais banda 5




(h) Média níveis digitais banda 3



(i) Média dos níveis digitais banda 5




(j) Máximo níveis digitais banda 5




(k) Saturação

4 - Atributos NDVI



(a) Desvio pad. níveis digitais banda 6 (b) Máximo níveis digitais banda 6



(c) Mínimo níveis digitais banda 6

APÊNDICE E – *Script* da ACP no software R


```

1 #ANALISE DE COMPONENTES PRINCIPAIS NO R
2 #Criado por: Kelly Lais Wiggers
3 #Mestranda em Computacao Aplicada
4 #UEPG – Universidade Estadual de Ponta Grossa (Brasil)
5 #Agradecimentos: CAPES pela concessao da minha bolsa de estudos.
6 #e-mail: kellylaiswiggers@hotmail.com
7
8 #_____CARREGA A TABELA DE DADOS_____#
9 dados <- read.table(dadosGeobia)
10 #Adiciona o nome das variaveis
11 variaveis <-c("AREA", "LENGTH", "COMPACT", "CONVEXITY", "SOLIDITY", "ROUNDNESS",
    "FORMFACTOR", "ELONGATION", "RECT_FIT", "MAINDIR", "MAJAXISLEN", "MINAXISLEG",
    "NUMHOLES", "HOLESOLRAT", "BANDRATIO", "HUE", "SATURATION", "INTENSITY", "
    TX_RANGE", "TX_MEAN", "TX_VARIANC", "TX_ENTROPY", "MINBAND_1", "MAXBAND_1", "
    AVGBAND_1", "STDBAND_1", "MINBAND_2", "MAXBAND_2", "AVGBAND_2", "STDBAND_2",
    "MINBAND_3", "MAXBAND_3", "AVGBAND_3", "STDBAND_3", "MINBAND_4", "MAXBAND_4",
    "AVGBAND_4", "STDBAND_4", "MINBAND_5", "MAXBAND_5", "AVGBAND_5", "STDBAND_5")
12 names(dados) <- variaveis
13 #Transforma os dados de data.frame para matriz
14 dadosMatriz <-data.matrix(dados, rownames.force = NA)
15
16 #_____PRE-PROCESSAMENTO DOS DADOS_____#
17 media <- apply(dadosMatriz,1,mean)
18 desvio<- apply(dadosMatriz,1,sd)
19 preproc <- (dadosMatriz - media)/desvio
20 #Cria a matriz de correlacao com os dados pre-processados
21 matcor<- cor(preproc)
22
23 #_____INICIO DA ACP_____#
24 #Realiza o processo de ACP
25 acpcor <- prcomp(preproc, scale = TRUE)
26 #Mostra variancia explicada
27 varianciaExplicada <- summary(acpcor)
28 str(varianciaExplicada)
29 varianciaExplicada <- varianciaExplicada$importance[2,] * 100
30 #Biplot da ACP
31 biplot(acpcor,col = c("gray", "black"))
32 #Loadings
33 loadings <- acpcor$rotation
34 #Scores
35 scores <- acpcor$x


```

APÊNDICE F – Histogramas das funções de normalização


(a) Normalização dos dados do descritor Comprimento



(b) Normalização dos dados do descritor Saturação



(c) Normalização dos dados do descritor Intervalo de Textura



APÊNDICE G – Resultados de alguns testes na SOM

Mapa	Norm.	Viz.	Aprend.	Ordenação (Épocas, Viz., Aprend.)	Convergência (Épocas, Vizi., Aprend)	Resultados
7x7	Random	histD	Inv	30, 3, 0.6	200, 2, 0.06	Apenas 1 cultivo bem separado.
6x6	Random	histD	Inv	60, 3, 0.8	300, 2, 0.08	Todos os cultivos ficaram juntos.
10x15	Linear	Range	Inv	100, 6, 0.9	500, 3, 0.05	Não diferenciou C1 e C4.
12x12	Linear	Range	Power	100, 6, 0.8	200, 3, 0.4	Todos os cultivos ficaram juntos.
8x8	Random	Range	Inv	60, 30, 0.99	500, 16, 0.09	Confundiu C1 e C2 e corpos d'água difíceis de identificar.
6x5	Linear	Log	Linear	100, 3, 0.5	300, 2, 0.05	Umatriz toda agrupada, cultivos todos juntos.
6x6	Random	HistC	Linear	50, 3, 0.8	100, 2, 0.08	Confundiu C1 e C2.
9x9	Random	HistD	Inv	80, 3, 0.6	200, 2, 0.06	Confundiu C1 e C2.
10x12	Linear	Range	Linear	100, 6, 0.7	400, 3, 0.05	Todos os cultivos ficaram juntos. Corpos d'água em 2 regiões da umatriz.
9x12	Linear	Range	Inv	80, 6, 0.6	400, 3, 0.09	C1, C2 e C4 juntos. C3 ficou em duas regiões da umatriz
5x5	Random	histD	Inv	50, 5, 0.5	100, 3, 0.03	C1 e C2 juntos. Estradas junto com cultivos.
10x10	Random	Range	Inv	50, 8, 0.9	200, 4, 0.99	C1, C2 e C4 juntos. Confusão de cultivos com estradas. Alguns objetos do C2 confundiu com Cob. Florestal.

APÊNDICE H – Tabela da contribuição dos descritores na u_matrix

Descritores/regiões	I	II	III	IV	V	VI	VII
Lenght		X			X		
Formfactor					X		
Elongation							X
Rectfit							
Maindir					X		
Minaxisleng		X	X		X		
Bandratio		X	X				
Hue	X	X	X	X	X	X	X
Saturation				X	X		
Txrange				X			X
Txvarianc				X			X
Txentropy	X	X	X	X	X	X	X
Stdband1				X			X
Stdband2			X	X			
Avgband3		X	X			X	
Stdband3		X	X				
Maxband4		X	X				
Stdband4		X		X			
Maxband5		X	X				
Avgband5		X	X				
Stdband5						X	
Minband6					X	X	
Maxband6					X		
Avgband6					X		
Stdband6	X			X			X

Fonte: A autora