



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA E AGRIMENSURA
COORDENAÇÃO DE ENGENHARIA CARTOGRÁFICA E AGRIMENSURA

GABRIEL LINS MELO

**MAPEAMENTO DA OCUPAÇÃO URBANA NO ENTORNO DO RESERVATÓRIO
ENGENHEIRO FRANCISCO SABÓIA – PE, POR MEIO DE CLASSIFICADORES
COM ABORDAGEM EM GEOBIA UTILIZANDO IMAGENS PE3D**

Type your text

Type your text

Recife
2020

GABRIEL LINS MELO

**MAPEAMENTO DA OCUPAÇÃO URBANA NO ENTORNO DO RESERVATÓRIO
ENGENHEIRO FRANCISCO SABÓIA – PE, POR MEIO DE CLASSIFICADORES
COM ABORDAGEM EM GEOBIA UTILIZANDO IMAGENS PE3D**

Monografia apresentada a Disciplina de Trabalho de Conclusão de Curso - TCC do Departamento de Engenharia Cartográfica e Agrimensura – Decart, Universidade Federal de Pernambuco - UFPE, como requisito parcial para a obtenção do título de Bacharel em Engenharia Cartográfica.

Orientador: Prof^o. Dr^a. Simone Sayuri Sato.

Coorientador: Ubiratan Joaquim da Silva

Recife

2020

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Melo, Gabriel Lins.

MAPEAMENTO DA OCUPAÇÃO URBANA NO ENTORNO DO
RESERVATÓRIO ENGENHEIRO FRANCISCO SABÓIA ? PE, POR MEIO DE
CLASSIFICADORES COM ABORDAGEM EM GEOBIA UTILIZANDO
IMAGENS PE3D / Gabriel Lins Melo. - Recife, 2020.

57

Orientador(a): Simone Sayuri Sato

Coorientador(a): Ubiratan Joaquim da Silva Junior

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Engenharia Cartográfica e
de Agrimensura - Bacharelado, 2020.

1. GEOBIA. 2. Ortofoto. 3. PE-3D. 4. Reservatório Engenheiro Francisco
Sabóia. 5. Uso do Solo. I. Sato, Simone Sayuri. (Orientação). II. Silva Junior,
Ubiratan Joaquim da. (Coorientação). III. Título.

GABRIEL LINS MELO

**MAPEAMENTO DA OCUPAÇÃO URBANA NO ENTORNO DO RESERVATÓRIO
ENGENHEIRO FRANCISCO SABÓIA – PE, POR MEIO DE CLASSIFICADORES
COM ABORDAGEM EM GEOBIA UTILIZANDO IMAGENS PE3D**

Monografia apresentada a Disciplina de Trabalho de Conclusão de Curso - TCC do Departamento de Engenharia Cartográfica e Agrimensura – Decart, Universidade Federal de Pernambuco - UFPE, como requisito parcial para a obtenção do título de Bacharel em Engenharia Cartográfica.

Aprovada em: 13 / 11 / 2020.

BANCA EXAMINADORA

Prof^o. Dr^a. Simone Sayuri Sato (Orientador)
Universidade Federal de Pernambuco - UFPE

Engenheiro Cartógrafo Ubiratan Joaquim da Silva (Coorientador)
Universidade Federal de Pernambuco - UFPE

Prof^a. Dr^o Cézarío de Oliveira Lima Júnior (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

Msc. Rayane Cavalcanti da Fonseca (Examinadora Externa)
Instituto Chico Mendes de Conservação da Biodiversidade (ICMbio)

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me dado saúde e força para superar todas as dificuldades e ter me permitido chegar até aqui. Sem Ele, nada disso seria possível.

A minha esposa, Ellayne Ferraz, e meus pais Grimaldo Melo e Patricia Melo, pelo amor, incentivo e apoio incondicional.

Aos meus irmãos, Grimaldo Neto e Milca Alves, e avós, que sempre acreditaram no meu sucesso.

A minha orientadora Professora Dr^a. Simone Sayuri Sato, pelo total suporte e atenção. Sempre mostrando ter uma paciência incrível comigo.

Aos professores do Departamento de Engenharia Cartográfica e Agrimensura – Decart, da Universidade Federal de Pernambuco – UFPE, por todo apoio, dedicação e suporte.

Aos meus colegas de curso, em especial Ubiratan Joaquim, que levarei pra sempre nossa amizade em minha vida.

Por fim, agradeço a todos que me ajudaram nessa jornada direta ou indiretamente.

RESUMO

O mapeamento do uso e ocupação do solo no entorno de reservatórios tem sido um desafio importante para as ciências geodésicas e cartográficas que utilizam de técnicas de sensoriamento remoto e fotogrametria para alcançar aferições de padrões de precisão e acurácia nesse tipo de mapeamento. Como objetivo, este trabalho de conclusão de curso, propôs investigar o comportamento dos classificadores: Máxima Verossimilhança (MXVER), Random Forest (RF) e k-nearest neighbor (KNN), com abordagens em GEOBIA na produção de mapas temáticos do uso do solo, destacando a ocupação urbana, no entorno do Reservatório Engenheiro Francisco Sabóia, conhecido como Poço da Cruz, estado de Pernambuco. Para o desenvolvimento do experimento foi utilizada uma ortofoto oriunda do Projeto Pernambuco Tridimensional (PE3D) do ano 2014, na escala 1:5000, resolução espacial de 50 centímetros. A metodologia utilizou uma pré-classificação das classes as serem mapeadas por meio de fotointerpretação, mapa de referência. Foram testados os três algoritmos de classificação MXVER, RF e KNN e analisados os coeficientes de concordância: Kappa, acurácia global, acurácia do produtor e do usuário com base nas matrizes de confusão e, dos indicadores estatísticos: correlação de Pearson, coeficiente de determinação (R^2) e a Raiz do Erro Quadrático Médio. Como resultados, os classificadores: MXVER, KNN e RF apresentaram acurácia global superior a 90% e o índice Kappa superior a 60%, indicando que a acurácia temática do mapeamento de uso e ocupação de solo de áreas urbanas com ortofotos de alta resolução por GEOBIA, em áreas de reservatórios, é apropriada.

Palavras-chave: GEOBIA, Ortofoto, PE-3D, Reservatório Engenheiro Francisco Sabóia. Uso do Solo.

ABSTRACT

The mapping of land use and occupation around reservoirs is an important challenge for geodesic and cartographic sciences, which use digital image processing techniques obtained by remote sensors and photogrammetry, As an objective, this undergraduate theses proposed to investigate the behavior of classifiers: Maximum Likelihood (MXVER), Randon Forest (RF) and k-nearest neighbor (KNN), with using Geographical object-based image analysis (GEOBIA) is a classification method for the production of thematic maps of land use, highlighting the urban occupation, around the Reservoir Engineer Francisco Sabóia. known as Poço da Cruz, located in state of Pernambuco. For the development of the experiment was used an orthophoto with GSD 50 cm from the Three-Dimensional Pernambuco Project (PE3D) of the year 2014, this is LIDAR mapping on the scale 1:5000. The methodology used a pre-classification of the classes by means of photointerpretation, reference map. The three classification algorithms MXVER, RF and KNN tested and the agreement coefficients were analyzed: Kappa, global accuracy, producer and user accuracy based on confusion matrices and, of statistical indicators: Pearson correlation, determination coefficient (R^2) and the Root Mean Square Error. As a result, the classifiers: MXVER, KNN and RF presented an overall accuracy greater than 90% and the Kappa index greater than 60%, indicating that the thematic accuracy of the mapping of land use and occupation of urban areas with high resolution orthophoto by GEOBIA , in reservoir areas, is appropriate.

Keywords: GEOBIA. Orthophoto. PE-3D. Engenheiro Francisco Sabóia Reservoir. Use of the soil.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Elementos de Fotointerpretação, Ordem e Métodos de Pesquisa.....	22
Figura 2 –	Fluxograma da Metodologia.....	34
Figura 3 –	Área de Estudo	35
Figura 4 –	Elementos da paisagem definidos para a classificação em A - Vegetação Densa B - Vegetação baixa C - Solo Exposto e D - Telhados.....	37
Figura 5 –	Ortoimagem classificada por GEOBIA através de separabilidade de texturas.....	39
Figura 6 –	Ortoimagem classificada por GEOBIA através de separabilidade de texturas pelos algoritmos (a) - MAXVER (b) - Randon Forest e (c) – KNN.....	40
Figura 7 –	Acurácia do produtor	44
Figura 8 –	acurácia do usuário.....	44

LISTA DE TABELAS

Tabela 1 –	Adjetivos Comuns dos Elementos de Interpretação de imagem.....	23
Tabela 2 –	Serviços realizados pelo Projeto PE – 3D.....	24
Tabela 3 –	Softwares e Recursos tecnológicos.....	36
Tabela 4 –	Medidas de acurácia de classificação.....	38
Tabela 5 –	Matriz de Confusão (Máxima Verossimilhança)	42
Tabela 6 –	Matriz de Confusão (KNN).....	42
Tabela 7 –	Matriz de Confusão (Randon Forest).....	42
Tabela 8 –	Parâmetros de acurácia.....	43
Tabela 9 –	Análises Estatísticas	45

LISTA DE ABREVIATURAS E SIGLAS

AP	Acurácia do produtor
APA	Área de Proteção Ambiental
AU	Acurácia do usuário
APA	Área de Proteção Ambiental
APP	Área de Preservação Permanente
CONAMA	Conselho Nacional do Meio Ambiente
DNOCS	Departamento Nacional de Obras Contra as Secas
GEOBIA	Análise geográfica baseada em objetos
ISPRS	International Society for Photogrammetry and Remote Sensing
KNN	K-nearest neighbor
LIDAR	Light Detection and Ranging
MDE	Modelos Digitais de Elevação
MDT	Modelos Digitais de Terreno
MXVER	Máxima Verossimilhança
PE-3D	Pernambuco Tridimensional
RF	Randon Forest
RMSE	Root Mean Square Error
SEINFRA	Secretaria de Infraestrutura e Recursos Hídricos do Estado de Pernambuco
SIG	Sistema de Informações Geográficas
SRTM	Shuttle Radar Topography Mission
VANT	Veículo aéreo não tripulado

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	17
1.2	ESTRUTURAÇÃO DA PESQUISA	18
2	REVISÃO DE LITERATURA	19
2.1	MAPEAMENTO DE USO E OCUPAÇÃO DO SOLO	19
2.1.2	Fotogrametria e Sensoriamento Remoto: Conceito e estado da Arte.....	20
2.1.3	A fotointerpretação como instrumento de avaliação temporal dos recursos naturais da Terra.....	21
2.1.4	Projeto Pernambuco Tridimensional (PE3D).....	24
2.2	CLASSIFICAÇÃO DIGITAL DE IMAGENS.....	25
2.2.1	Algoritmos de classificação de imagens.....	25
2.2.1.1	Algoritmos de classificação não supervisionada.....	26
2.2.1.2	Algoritmos de classificação supervisionada.....	27
2.2.1.3	Algoritmos de Aprendizagem de Máquina.....	28
3	METODOLOGIA DA PESQUISA	34
3.1	ÁREA DE ESTUDO	34
3.2	MATERIAL	36
3.3	MÉTODOS	36
4	RESULTADOS.....	39
4.1	CLASSIFICAÇÕES POR GEOBIA.....	39
4.2	ANÁLISE DA ACURÁCIA DO MAPEAMENTO	41
4.2.1	Matriz de confusão, acurácia global e índice kappa.....	38
4.2.2	Acurácia do Produtor e Acurácia do Usuário.....	43
4.2.3	Análises Estatísticas.....	45
5	CONCLUSÕES, RECOMENDAÇÕES E CONSIDERAÇÕES FINAIS.....	47
5.1	CONCLUSÕES.....	47
	REFERÊNCIAS	49

1. INTRODUÇÃO

Um dos maiores desafios para o planejamento territorial é a falta de informações adequadas sobre o uso e ocupação do solo e suas características físicas (CIRILO *et al.*, 2014), a exemplo, das matas ciliares no entorno de Reservatórios, consideradas áreas de preservação ambiental (APA).

O entorno dos corpos hídricos além de significar áreas de controle de cheias, contribuem para a regularização do escoamento natural das águas, controlando a erosão do solo e o assoreamento dos mananciais (LIRA, 2015). Informações sobre uso, ocupação e dinâmica da cobertura litosféricas dessa região são fundamentais (PANAGOS *et al.*, 2014), pois ações antrópicas não supervisionadas, podem gerar uma serie de impactos ambientais que percolam pela impermeabilização do solo, alterações na topografia, erosão das margens e assoreamento dos cursos d'água, perda das matas ciliares, diminuição da biodiversidade, aumento do escoamento superficial, dentre outros. Portanto, é necessário um contínuo monitoramento destes ambientes, de forma a proporcionar o acompanhamento de mudanças e alterações no cenário da paisagem. A exemplo do mapeamento de uso do solo, em que são qualificadas e quantificadas informações inerentes a cobertura da terra por meio de classes com similaridades de características, que possibilitam tal descrição.

Ao retratar as formas e a dinâmica de uso e ocupação, estes estudos também representam instrumento valioso para a construção de indicadores ambientais e para a avaliação da capacidade de suporte ambiental, contribuindo assim para a identificação de alternativas promotoras da sustentabilidade do desenvolvimento (IBGE, 2013).

Em 1909 foi criada a Inspetoria de Obras contra as Secas (IOCS), atualmente Departamento Nacional Contra as Secas (DNOCS), sendo o primeiro órgão a estudar a problemática do semiárido, durante seus anos de atuação construiu centenas de açudes e administra atualmente 327, todos na região nordeste, e um deles é o Reservatório Engenheiro Francisco Saboya, conhecido como Poço da Cruz, objeto de estudo de diversas pesquisas, incluindo a presente pesquisa.

Dentre as técnicas de produção do mapeamento de uso do solo, tem-se a Fotogrametria, que proporciona técnicas de aquisição de imagens de alta resolução e o Sensoriamento Remoto, que utilizam métodos e processos de classificação de imagens, através de instrumentos fotointerpretativos.

A classificação supervisionada de imagens, procedimento de identificação de áreas espectralmente semelhantes (amostras de treinamento) em uma imagem, na qual o usuário reconhece preliminarmente regiões de interesse conhecidos na superfície terrestre (CATTANI *et al.*, 2013), e cabe ao algoritmo escolhido extrapolar essas características espectrais escolhidas para as outras regiões da imagem, realizando assim a classificação (CASTILLEJO-GONZÁLEZ *et al.*, 2009). Baseada em pixels tem sido aplicada para análises multitemporais para predição e mapeamento desses fenômenos (LU, 2013). Uma das principais limitações desse algoritmo de classificação é que os alvos podem conter padrões espectrais semelhantes, a exemplo de regiões com ocupações vegetais consolidadas (regiões agrícolas e florestas), resultando em interpretações ambíguas (MYINT, 2011; ANDRADE, 2012). Uma solução alternativa de classificadores de alta resolução é o método de análise geográfica baseada em objetos GEOBIA (Geographic Object-Based Image Analysis) (Hay e Castilla, 2008 apud Passo, 2013).

A GEOBIA apresenta uma abordagem eficiente quando comparada aos algoritmos baseados na classificação por pixel, pois considera a classificação de imagens com base nas informações topológicas (vizinhança, contexto, relações) e geométricas (forma, tamanho) dos objetos (RASTI *et al.*, 2019; PRUDENTE, 2017).

Em estudos desenvolvidos por Rolim (2003), foi demonstrado que com a utilização desta técnica de classificação, GEOBIA, foi possível classificar digitalmente imagens de alta resolução de forma acurada, com informações a respeito do uso do solo de uma microbacia hidrográfica no município de Nova esperança-PR.

As vantagens de utilização de processamento de imagens são inúmeras, porém, a validação dos dados gerados por esse meio é de fundamental importância, evitando interpretações ambíguas (RASTI *et al.*, 2019). A acurácia dos dados geográficos deve ser observada considerando três pontos fundamentais: a posição dos dados; a época de aquisição dos dados; e a temática investigada (QUEIROZ, 2017). A matriz de confusão tem sido uma das técnicas para análise da acurácia dos dados classificados (SOUZA, 2020).

O Projeto Pernambuco Tridimensional (PE3D) tem impulsionado uma variedade de estudos envolvendo as técnicas de Sensoriamento Remoto e Processamento Digital de Imagens e no estudo de Cirilo *et al.* (2014), e uma delas, é o uso do GEOBIA em imagens com alta resolução espacial e modelos digitais gerados

a partir de varredura a laser que proporcionam comprovadamente notável avanço na qualidade dos estudos e projetos que demandam conhecimento detalhado do terreno.

O Código Florestal Brasileiro instituído pela Lei 12.651 de 2012 considera as áreas no entorno dos reservatórios d'água artificiais, decorrentes de barramento ou represamento de cursos d'água naturais, como áreas de Preservação Permanente (BRASIL, 2012). Tornando a preservação desta área de grande importância, e para que isto ocorra é necessária uma ação integrada a partir de técnicas que possibilitem o monitoramento e acompanhamento da expansão urbana e ações antrópicas dela derivada.

Lira (2015) ressalta a partir da Resolução do Conselho Nacional do Meio Ambiente (CONAMA) nº302/02, que a vegetação situada em Área de Preservação Permanente (APP) no entorno de reservatórios deverá ser mantida, e caso ocorra a supressão de vegetação situada, o proprietário da área é obrigado a promover a recomposição da vegetação, ressalvados os usos autorizados previstos na lei, como ocorrem em alguns pontos do Reservatório Engenheiro Francisco Saboia (Poço da Cruz), em Ibimirim, município do estado de Pernambuco. Portanto, estudos contínuos que possibilite o monitoramento e planejamento, deste espaço, de modo a proporcionar uma preservação e utilização consciente dos recursos naturais, tornam-se necessários.

Dentre os estudos de monitoramento do uso e ocupação do solo no entorno do Reservatório Engenheiro Francisco Saboia (Poço da Cruz) - PE, se destaca o uso do Sensoriamento Remoto e técnicas de processamento digital de imagens, Lira (2015). Na pesquisa do autor, é caracterizado os aspectos socioambientais da área de estudo, foi mapeado a cobertura vegetal e o uso e ocupação atual do solo e, onde-se identificou os conflitos ambientais existentes, propondo diretrizes de planejamento e gestão integrada.

Seguindo a linha de preservação ambiental da área, em Oliveira e Galvício (2009) realizaram uma caracterização ambiental da Bacia Hidrográfica do Rio Moxotó, através do balanço de radiação.

Como contribuição e complemento aos estudos contextualizados na área do Reservatório Poço da Cruz, em Ibimirim, município do estado de Pernambuco, este trabalho trata do mapeamento temático de uso e ocupação do solo no entorno da área aplicando algoritmos de classificação supervisionada e o método da Análise de Imagens Baseada em Objetos Geográficos (GEOBIA). A metodologia empregada no

trabalho visa testar ainda a acurácia temática dos métodos de classificação empregados. Assim, o objetivo geral e os específicos a serem tratados envolvendo a são definidos na seção a seguir.

1.1 OBJETIVOS

Nesta seção serão apresentados o objetivo geral e os objetivos específicos deste Trabalho de Conclusão de Curso.

1.1.1 Objetivo Geral

Investigar a aplicação de algoritmos de classificação supervisionada numa abordagem em GEOBIA para identificar padrões de uso e ocupação do solo, no entorno do Reservatório Engenheiro Francisco Sabóia (Poço da Cruz) – PE, utilizando ortofotos do Projeto PE3D.

1.1.2 Objetivos Específicos

- a) Caracterizar padrões de uso e ocupação do solo, a partir da discriminação de classes temáticas, numa área urbana próxima ao Reservatório Poço do Cruz, por meio de técnicas de Fotointerpretação.
- b) Analisar a aplicação das ortofotos oriundas do Projeto PE3D para o mapeamento de uso e ocupação do solo por meio dos algoritmos de classificação supervisionada: Máxima Verossimilhança (MXVER) e de aprendizagem de máquina: *Randon Forest* (RF) e *k-nearest neighbor* (KNN), com abordagem em GEOBIA.
- c) Comparar o processo de classificação digital de imagens por GEOBIA, por meio dos algoritmos classificadores.
- d) Avaliar a acurácia de mapeamento dos algoritmos de classificação utilizando parâmetros como: acurácia do produtor e usuário, acurácia global e coeficiente *Kappa*.

1.2 ESTRUTURAÇÃO DA PESQUISA

Este Trabalho de Conclusão de Curso está organizado em 5 capítulos. No Capítulo 1 é apresentada a pesquisa, a problemática envolvida e a justificativa para escolha do tema e os objetivos a serem alcançados. No Capítulo 2 é feita uma revisão de literatura com os aspectos teóricos relacionados ao monitoramento da ocupação urbana nas áreas de reservatório por meio de técnica de processamento digital de imagens. Ainda neste capítulo, destaca-se uma abordagem ao modelo de Análise Geográfica Baseada em Objetos (GEOBIA) e ao Projeto Pernambuco Tridimensional (PE3D) acerca dos Produtos Gerados e suas aplicações. No Capítulo 3, são apresentados os materiais e métodos empregados no desenvolvimento da pesquisa. Os resultados obtidos com a metodologia empregada são discutidos no Capítulo 4. E por fim, tem-se o Capítulo 5, apresentando as conclusões e recomendações para pesquisas futuras.

2. REVISÃO DE LITERATURA

Neste capítulo de revisão de literatura, foi feita uma abordagem das metodologias de mapeamento de uso e ocupação do solo através de modelagens derivadas de imagens orbitais e fotogramétricas, destacando os classificadores digitais de imagem tradicionais e de aprendizagem de máquina e suas relações com a GEOBIA.

2.1 MAPEAMENTO DE USO E OCUPAÇÃO DO SOLO

Segundo Amaral e Rios (2012), O processo de ocupação do território, determinado por condicionantes naturais e sociais, e as suas consequências sobre os sistemas ecológicos, produzem efeitos na paisagem e no ambiente que precisam ser compreendidos. O levantamento do uso e ocupação do solo é imprescindível para analisar a forma pela qual determinado espaço está sendo ocupado, podendo este servir para planejadores e legisladores (PRUDENTE e ROSA, 2007). As primeiras classificações de uso da terra baseavam-se em trabalhos de campo. Posteriormente, a partir de década de 50 (STEINER, 1970 apud Borges *et al.*, 1993).

Com isso, a utilização das ferramentas geotecnologias como o sensoriamento Remoto e a Fotogrametria, proporciona o monitoramento da paisagem com alto potencial de temporalidade e precisão afirma Rosa (2009).

Para Enokida e Magalhães (2009) a espacialização dos dados de uso do solo, integrada a informações quantitativas em plataformas como Sistemas de Informações Geográficas (SIG) são medidas de ampla relevância para obtenção de uma análise ambiental de áreas como entornos de reservatórios. Dados esses que podem proporcionar um amplo planejamento e gerenciamento ambiental dessas áreas.

Lira (2015) afirma que o entorno dos corpos hídricos além de significar áreas de controle de cheias, contribuem para a regularização do escoamento natural das águas, controlando a erosão do solo e o assoreamento dos mananciais. Além disso, associados a essas áreas encontram-se as matas ciliares, responsáveis pelo equilíbrio ecossistêmico, sendo também indicadores da qualidade da água (VALERA *et al.*, 2019).

Dentre as técnicas de mapeamento de uso e ocupação do solo por meio de imagens orbitais e fotogramétricas, encontram-se as informações baseadas na forma,

textura, resposta espectral e o contexto espacial dos objetos (LOCK e KIRCHNER, 1997), através da classificação digital de imagens e avaliações da superfície de forma temporal.

2.1.2 Fotogrametria e Sensoriamento Remoto: Conceito e Estado da Arte

Em 1980 a ISPRS (*International Society for Photogrammetry and Remote Sensing*) conceitua a fotogrametria e o sensoriamento remoto como “Fotogrametria e Sensoriamento remoto é a arte, ciência e tecnologia de se obter informações confiáveis de imagens de sensores imageadores e outros, sobre a Terra e seu meio ambiente, e outros objetos físicos e processos através de gravação, mediação, análise e representação”.

Entretanto, Segundo Moreira (2003) *apud* Carmo e Schaefer (2009), a utilização de aerofotos para estudos voltados ao ambiente teve início bem antes do surgimento do sensoriamento remoto orbital. Mesmo após a consolidação dos dados orbitais, elas continuam sendo muito utilizadas para estudos que exigem maiores detalhes de reconhecimento dos alvos de ocupação do solo.

A evolução tecnológica ocorrida nas últimas décadas trouxe novos meios para levantar informações sobre o terreno de forma remota, entre elas se destacam as técnicas com o uso de sensores passivos (fotografias aéreas e imagens de satélite) e com o sensor Laser Scanner, também conhecido por LIDAR (*Light Detection and Ranging*) (FELISBINO *et al.*, 2019), utilizado pelo PE3D para geração dos seus produtos.

Portanto, o advento dos dados derivados de instrumentos como: LIDAR e VANT, associados a disponibilidade de imagens orbitais de alta resolução espacial, possibilitaram o desenvolvimento de técnicas e modelagens que derivam desde mapeamento de uso do solo a análises de parâmetros de qualidade de água em sistemas aquáticos continentais.

Com a redução de custos de aquisição de imagens aéreas e geração de ortofotos por meio de sistemas com aeronaves tripuladas remotamente, o VANT, estudos de classificação de imagens tornam-se importantes no mapeamento de uso e ocupação do solo.

Dentre os estudos de aplicações de produtos cartográficos obtidos através de dados VANT, destaca-se Buffon *et al.* (2017) que utilizou dados obtidos com VANTs,

ortofotos com alta resolução e modelo digital de elevação e do terreno para o mapeamento de vulnerabilidade ambiental causada por ações antrópicas derivadas da ocupação urbana de áreas da cidade de Campo Magro –Paraná, Brasil.

No estudo de Huang et al (2017), foi considerado que os modelos digitais do terreno e as ortofotos baseado em VANT, é um meio mais eficaz de monitorar a prevenção e mitigação de riscos geográficos. No estudo, foi comprovada a viabilidade do método utilizando como área de estudo, a encosta Qinglingou, que está localizada na cabeceira do reservatório Three Gorges, na China.

Outro estudo usando ortofotos com alta resolução e MDT é descrito em Yang et al. (2018), em que são fornecidas informações úteis para avaliar o impacto ribeirinho de projetos de água artificial entre bacias antes da implementação. São identificadas a cobertura vegetal nas zonas de amortecimento ribeirinhas existentes, e que deve ser restaurada.

2.1.3 A Fotointerpretação como instrumento de avaliação de recursos naturais

Para Amaral e Audi (1972), a fotografia aérea apresenta-se como material de trabalho indispensável no levantamento de solos, proporcionando ganho de tempo, precisão de limites e real visão global da paisagem com riqueza de detalhes. Souza (2005) afirma que a presença de padrões, de relevo, drenagem, erosão e vegetação, permite ao fotointérprete fazer inferências sobre a distribuição do solo e material de origem, porém, o trabalho de campo não pode ser substituído completamente.

A Fotointerpretação consiste na extração de informações qualitativas de alvos presentes na superfície terrestre, à parte de imagens aéreas, através de padrões de elementos como: Tonalidade e cor, Forma e tamanho, Padrão, Textura, Associação e Sombra. Esse princípio de interpretação de imagens foi desenvolvido por mais de 50 anos por meio de experiências empíricas.

Como descrito por JENSEN (1996) 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 elementos de interpretação de imagens incluem localização, tonalidade e cor, tamanho, forma, textura, padrão, sombra, altura e profundidade, volume, declividade, aspecto, sítio, situação e associação,

apresentado na Figura 1. Alguns adjetivos associados a cada um desses elementos estão resumidos na Tabela 1.

Na Figura 1, tem-se a descrição dos parâmetros utilizados pelos métodos fotointerpretativos para serem utilizados nas árvores de decisão como critérios para análises de um determinado objeto sobre a superfície terrestre.

Figura 1 – Elementos de Fotointerpretação, Ordem e Métodos de Pesquisa.



Fonte: Adaptado de Jensen (1996).

Na tabela 1, apresentada com detalhes os adjetivos comuns dos elementos de interpretação de imagem.

Tabela 1 – Adjetivos Comuns dos Elementos de Interpretação de imagem.

Elemento	Adjetivos Comuns (quantitativos e qualitativos)
Localização X e Y	<p>Coordenada x, y de imagem: Coordenada (x) coluna e (y) linha em uma imagem não retificada.</p> <p>Coordenada x, y de Carta-imagem: os cristais de haleto de prata ou pixels numa fotografia são retificados para Projeção de mapas.</p>
Tom, cor	<p>Tom de cinza: claro (brilhante), intermediário (cinza), escuro (negro).</p> <p>Cor: IHS = intensidade, matiz (H), saturação; RGB = vermelho, verde e azul; Munsell</p>
Tamanho	<p>Comprimento, largura, perímetro, área (m²); Pequeno, médio (intermediário), grande.</p>
Forma	<p>Características de um objeto: linear, curvilínea, circular, elíptico, radial, quadrado, retangular, triangular, dentre outros.</p>
Textura	<p>Arranjo e disposição característicos de repetições de tom e cor; Liso, intermediário (médio), rugoso (grosseiro), mosqueado.</p>
Padrão	<p>Arranjo espacial de objetos no terreno: sistemático, não-sistemático ou randômico, linear, curvilinear, retangular, etc.</p>
Sombra	<p>Uma silhueta causada por iluminação solar lateral.</p>
Altura/Profundidade Volume/Declividade/ Aspecto	<p>Elevação – z (altura), batimetria – z (profundidade), volume (m³), declividade (°), aspecto (°).</p>
Sítio/ Situação Associação	<p>Sítio: elevação, declividade, aspecto, exposição, adjacente a água, meios de transporte, serviços públicos.</p> <p>Situação: os objetos estão colocados numa ordem ou orientação um em relação ao outro.</p> <p>Associação: fenômenos relacionados estão, normalmente, presentes.</p>

Fonte: Jensen (1996) adaptada pelo autor

2.1.4 Projeto Pernambuco Tridimensional (PE3D)

O programa PE3D, iniciado pela SEINFRA em março de 2014 ainda não concluído, teve como objetivo de realizar varredura a laser e obter ortofotos e modelos digitais do terreno e de superfície de alta resolução de toda a superfície territorial pernambucana, cuja área é de 98.148km² (Cirilo *et al.*, 2014). Após a realização desse mapeamento estadual, por meio de um geoportal, seria disponibilizado gratuitamente todos produtos e insumos cartográficos. Os serviços de mapeamento incluíram recobrimento aerofotogramétrico e perfilamento a laser em dois níveis de precisão. O primeiro abrangendo todo o território de Pernambuco com um recobrimento aerofotogramétrico e geração de ortofotos na escala 1:5.000. O segundo nível corresponde ao mapeamento com perfilamento a laser com precisão altimétrica superior a 25 cm e geração de Modelos Digitais de Terreno (MDT), Modelos Digitais de Elevação (MDE) e imagens de Intensidade Hipsométrica.

A área total de maior precisão, abrangeu 870 km², distribuídos em 26 municípios, com recobrimento aerofotogramétrico e geração de ortofotos na escala 1:1.000, perfilamento a laser com precisão altimétrica superior a 10 cm e geração de Modelos Digitais de Terreno (MDT), Modelos Digitais de Elevação (MDE) e Imagens Hipsométricas. A Tabela 2 apresenta os serviços executados por área.

Tabela 2 - Serviços realizados pelo Projeto PE – 3D.

SERVIÇO	ÁREA
Recobrimento aerofotogrametrico digital com GSD 50cm e geração de ortoimagem na escala de 1:5.000 atendendo ao PEC classe A.	98.146 km ²
Recobrimento aerofotogrametrico digital com GSD 12cm e geração de ortoimagem na escala de 1:1.000 atendendo ao PEC classe A.	870 km ²
Perfilamento a Laser e geração do Modelo Digital do Terreno com erro máximo altimétrico melhor que 25 cm.	98.146 km ²
Perfilamento a Laser e geração do Modelo Digital do Terreno com erro máximo altimétrico melhor que 10 cm.	870 km ²

Fonte: PE- 3D (2020).

Dentre os estudos que utilizaram os produtos fornecidos pelo PE3D para o monitoramento de estruturas hídricas no semiárido pernambucano, destacam-se Nascimento (2017) que avaliou o potencial de uso de produtos da tecnologia LiDAR

para determinação da capacidade de armazenamento em reservatórios de abastecimento de água, na Bacia do Rio Pajeú. E Cirilo *et al.* (2014), avaliou o potencial do uso de bases de dados espaciais, particularmente o SRTM e a varredura a laser, como suporte a estudos e projetos destinados à implantação de infraestrutura e ações de previsão e controle de inundações.

2.2 CLASSIFICAÇÃO DIGITAL DE IMAGENS

A classificação é o processo de agrupamento dos *pixels* de uma imagem em categorias estabelecidas e pode ser feita de maneira manual, automática ou híbrida (ABBURU e BABUGOLLA, 2015).

A classificação Digital de Imagens é o processo de associar os *pixels* da imagem a um número finito de classes individuais que representam os objetos do mundo real, com base nos seus valores digitais. Ou seja, se um pixel satisfaz um determinado conjunto de critérios, normalmente avaliados por medidas estatísticas, o *pixel* é atribuído à classe que melhor satisfaz os critérios estabelecidos. Sendo o resultado final da classificação, uma imagem digital que constitui um mapa de *pixels* classificados, representando em polígonos os padrões homogêneos de classes de alvos (mapa digital temático) (MENEZES e ALMEIDA, 2012, p. 201).

Esse processo de classificação dar-se-á por meio de algoritmos classificadores, de forma supervisionada ou não supervisionada. A primeira necessita que amostras sejam selecionadas e atribuídas a classes; na segunda, o próprio algoritmo cria as classes sem a necessidade de seleção de amostras (MOURA 2016).

2.2.1 Algoritmos de Classificação de imagens

O método mais frequentemente utilizado para analisar dados e extrair informações do uso e ocupação do solo é a classificação digital dos alvos a partir de dados multiespectrais (JENSEN, 1996).

Nos grandes projetos de mapeamento, a técnica de interpretação visual é ainda muito utilizada, mesmo com diversos algoritmos de classificação de imagens já desenvolvidos (RIBEIRO *et al.*, 2005). Entretanto, Crosta (1992) ressalta que existe

uma tendência de utilização cada vez maior da classificação computacional, devido à rapidez e praticidade de processamento.

Esta classificação é realizada por meio de algoritmos. Compreendidos em algoritmos de classificação supervisionada, não supervisionada e de aprendizagem de máquina. A seguir são descritos os principais algoritmos de classificação digital de imagem e suas respectivas modelagens computacionais:

2.2.1.1 Algoritmos de Classificação Não Supervisionada

São classificadores que requerem pouca ou nenhuma participação do analista no processo de classificação da imagem (MENEZES e ALMEIDA, 2012). Entretanto, Richards (1986) afirma que é necessário que o analista forneça ao sistema alguns parâmetros (limiares) os quais servirão como critérios de decisão no momento de agrupar pixels em classes distintas.

Segundo Adami *et al.* (2006), o algoritmo define as classes, assim como a estratificação da cena sem a interferência do analista. Durante o processo de agrupamento dos pixels espectralmente semelhantes, são considerados os parâmetros fornecidos pelo analista. Entre os algoritmos que utilizam este método, têm-se os principais: K-Médias e o Isoseg.

a) K-Médias:

O K-médias é um algoritmo para partição de um conjunto de elementos num determinado número de clusters (K), e que utiliza o método dos mínimos quadrados e o ajustamento das médias no decorrer do processo de iteração (BARBOSA *et al.*, 2009).

Para Almeida e Menezes (2012), o objetivo do K-médias é minimizar a variabilidade interna do agrupamento que é dimensionada pela função soma das distâncias ao quadrado (erros) entre cada pixel e o centro ao qual é alocado. A soma da distância ao quadrado (SS) tem a forma:

$$SS_{distância} = \sum xy[x - C(x)]^2 \quad (1)$$

Em que, C(x) = média do agrupamento ao qual o pixel x é alocado.

b) Isoseg

O Isoseg é um algoritmo que procura agrupar regiões a partir de atributos estatísticos de média, matriz de covariância e área a partir de uma medida de similaridade entre elas, a partir da distância Mahalanobis entre a classe e as regiões candidatas a relação de pertinência com esta classe (OLIVEIRA e MATAVELI, 2013; KORTING, 2006).

Para Bins *et al.* (1993) o classificador Isoseg inicialmente particiona a imagem em regiões com diferentes atributos estatísticos (média, matriz de covariância e área). Em seguida, o algoritmo realiza a classificação das regiões embasado na teoria de agrupamento “*clustering*”.

2.2.1.2 Algoritmos de Classificação Supervisionada

Um algoritmo de classificação supervisionado pode ser subdividido em duas fases: (i) a fase de aprendizagem em que é identificado um padrão de classificação com base em assinaturas espectrais de bandas diferentes obtidas a partir de similaridades de "treinamento" com rótulos de classe conhecidos e (ii) a fase de previsão, na qual o padrão de classificação é aplicado a outros locais com membros de classe desconhecidos (SAMANIEGO e SCHULZ, 2009).

Portanto, os algoritmos de classificação supervisionada necessitam ser treinados para distinguir as classes, sendo este treinamento controlado pelo analista. Dentre os algoritmos de classificação supervisionada têm-se a Máxima Verossimilhança, utilizado no desenvolvimento desta pesquisa.

a) Máxima Verossimilhança (MAXVER)

MAXVER é um classificador paramétrico, que assume uma distribuição espacial de probabilidade, normalmente uma distribuição de Gauss, dos dados analisados, determinando os parâmetros como média e matriz de covariância com base nos dados de treinamento (BRASILEIRO *et al.*, 2016). Segundo Eastman (1999), no classificador por MAXVER, a distribuição dos valores de refletância em uma área de treinamento é descrita por uma função de densidade de probabilidade, desenvolvida com bases na estatística Bayesiana (YOKOO *et al.*, 2013)

Na classificação de máxima verossimilhança cada pixel é destinado à classe que tem a mais alta probabilidade, isto é, a máxima verossimilhança. Isso significa que para um pixel na posição x do espaço multiespectral, um conjunto de

probabilidades são computadas e que dão as possibilidades relativas do pixel pertencer a cada classe disponível, sendo: $(P(x|\omega_i))$ (MENEZES e ALMEIDA, 2002).

Segundo Richard e Jia, (2006) a classificação de um ponto x ocorre conforme descrito na Equação 2:

$$x \in \omega_i \text{ se } p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j) \quad (2)$$

Em que, $p(x|\omega_i)$ = a probabilidade da possibilidade de x pertencer à classe (ω_i) e $p(\omega_i)$ é a probabilidade de a classe ocorrer na imagem.

Os autores Menezes e Almeida (2002), ressaltam que tantas quanto forem às classes de treinamento selecionadas, tantas serão: $p(x|\omega_i)$. Assim, todos os *pixels* serão classificados, a menos que seja definido um limiar, quando ocorrem situações ruins de classificação. Conforme Equação 3:

$$p(x|\omega_i)p(\omega_i) > p(x|\omega_i)p(\omega_i) \text{ e } p(x|\omega_j)p(\omega_j) > \text{limiar} \quad (3)$$

2.2.1.3 Algoritmos de Aprendizagem de Máquina

Os algoritmos de aprendizagem de máquina têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (VAPNIK, 1995; NASCIMENTO *et al.*, 2009).

Essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes (OROZCO FILHO, 2017).

Os diversos sistemas de aprendizado de máquina possuem características particulares e comuns que possibilitam sua classificação quanto à linguagem de descrição, modo, paradigma e forma de aprendizado utilizado (MONARD e BARANAUSKAS, 2003). Dentre os algoritmos de aprendizagem de máquina têm-se o KNN e o Random Forest.

a) KNN (*k*-nearest neighbor)

O algoritmo K-NN é uma classificação realizada a partir das amostras de treinamento, com base nos vizinhos mais próximos (MENG *et al.*, 2007). Deve-se atribuir um valor k , que é o número de vizinhos a serem utilizados na determinação da

classe que será atribuída pelos valores de refletâncias de superfície da maioria dos pixels circunvizinhos (GAROFALO *et al.*, 2009).

Depois de selecionar o valor de k , são realizadas as previsões com base nos exemplos KNN, essas previsões tratam-se da média sobre os resultados para KNNs (IMANDOUST e BOLANDRAFTAR, 2013) descritos conforme Equação 4:

$$y = \frac{1}{k} \sum_{i=1}^k y_i \quad (4)$$

Quando o método KNN é usado para regressão, o valor da resposta é calculado como uma soma ponderada das respostas de todos os k vizinhos, onde o peso é inversamente proporcional à distância do registro de entrada (AL-DOSARY *et al.*, 2019). A função distância euclidiana, utilizada pelo KNN é definida por Wilson e Martinez (2000), conforme a Equação 5:

$$E(x, p) = \sqrt{\sum_a^m (x_a - p_a)^2} \quad (5)$$

Em que,

x e p : são o ponto de consulta e um caso do conjunto de exemplos, respectivamente,

m : é o número de variáveis de entrada (atributos).

b) Random Forest (RF)

O classificador Random Forest consiste em uma combinação de classificadores de árvore, em que cada classificador é gerado usando um vetor aleatório amostrado independentemente do vetor de entrada, e cada árvore emite um voto unitário para a classe mais popular para classificar um vetor de entrada (SANTOS *et al.*, 2020).

Este classificador usa o Índice de Gini (BREIMAN *et al.*, 1984) como uma medida de seleção de atributo, que mede a impureza de um atributo em relação às classes (BREIMAN, 2001). Para um determinado conjunto de treinamento T ,

selecionando um caso (*pixel*) aleatoriamente e dizendo que pertence a alguma classe C_i , o índice Gini pode ser escrito como na Equação 6:

$$\sum \sum \left(\frac{f(C_i, T)}{|T|} \right) \cdot \left(\frac{f(C_j, T)}{|T|} \right) \quad (4)$$

Em que, $\frac{f(C_j, T)}{|T|}$ = probabilidade de o caso selecionado pertencer à classe C_i .

2.3 GEOBIA

A GEOBIA consiste na segmentação dos objetos da imagem, delimitando limites com regiões homogêneas, em vez de analisar os pixels independentemente de sua localização (SILVA e BACANI, 2007; DESCLÉE *et al.*, 2006).

O GEOBIA, pressupõe a incorporação de um modelo de conhecimento atrelado ao processo de interpretação da cena. Apoia em métodos já existentes (segmentação, detecção de bordas, extração de feições e classificação) para integrar informações espectrais e conceitos espaciais em diferentes escalas (Blaschke *et al.*, 2014).

Ao contrário da classificação baseada em *pixels*, a GEOBIA não classifica cada pixel separadamente. Em vez disso, a imagem é segmentada em objetos homogêneos que são usados como unidades a serem classificadas ou rotuladas. Esses métodos são especialmente aplicáveis aos dados de alta resolução espacial, onde os pixels são geralmente menores que os recursos mapeados (WALTER, 2004; MAXWELL, 2019).

A GEOBIA enquadra-se no tipo de classificação por região, considerando na segmentação e classificação várias características da imagem, como heterogeneidade espacial (forma), assim como espectral (cor) e diferença dos objetos de entorno, utilizando em síntese o método de crescimento de regiões para agregar pixels vizinhos (FOLHARINI e SOUZA, 2016).

Segundo Moreira (2007) a GEOBIA utiliza algoritmos cujo reconhecimento dos padrões espectrais na imagem é feito com base numa amostra de área de treinamento, que é fornecida ao sistema pelo analista, resultando num mapa com maior acurácia.

Diante disso, é crescente o desenvolvimento de sistemas tanto comerciais, como o Erdas e, Open-Source como o Quantum GIS (QGIS) voltados à GEOBIA, de

modo geral, o processo de mapeamento por meio da GEOBIA se baseia, na seguinte sequência de procedimentos: criação da rede semântica, segmentação, criação das regras para a separação das classes e avaliação da acurácia. WALTER, 2004; MAXWELL, 2019).

A potencialidade da classificação GEOBIA em estudos de planejamento ambiental de bacias hidrográficas é evidenciada em estudos de Folharini e Souza (2016), Garófalo *et al.* (2015) e Rolim (2003).

2.4 AVALIAÇÃO DA QUALIDADE DE CLASSIFICAÇÃO

De acordo com Montgomery & Schuch (1993), citado por Antunes (1997) apud Passo (2013), em qualquer mapa temático obtido por meio da classificação digital, pode ser efetuada a análise da acurácia referente às seguintes componentes:

- Posicional, que se refere à precisão espacial do mapa e que é variável de acordo com a sua escala; e
- Temático, que se refere à precisão da classificação das diferentes categorias que compõem o mapa.

As componentes citadas são interdependentes, entretanto, a avaliação é geralmente realizada de forma independente. Neste trabalho, será realizado somente a análise da acurácia temática.

2.4.1 Matriz de Confusão

A matriz de confusão, Congalton e Green (1999) *apud* Passo (2013), é uma maneira muito eficaz para representar a precisão do mapa. Uma matriz de confusão ou matriz de erros é uma matriz quadrada que expressa a relação do número de unidades de amostra atribuída a uma categoria particular de duas classificações. Nessa matriz, geralmente, as colunas representam os dados de referência (verdade de campo) e as linhas representam a classificação obtida com algum método de classificação automática.

A matriz de erros ou confusão apresenta de forma resumida os resultados da classificação digital ou fotointerpretação em relação à imagem referência, onde tem-se então uma distribuição binomial (LINGNAU e ANTUNES, 2003).

Cada frequência observada na matriz corresponde também a uma frequência esperada, a qual é calculada sob uma determinada hipótese de acordo com as regras da probabilidade (SPIEGEL, 1993).

É uma técnica estatística mais simples que representa um valor para a qualidade da classificação é a precisão estatística descritiva global ou exatidão ou acurácia global, que pode ser calculada dividindo-se o somatório da diagonal principal da matriz pelo número total de pixels da matriz de confusão (CONGALTON,1991).

2.4.2 Acurácia Global

A taxa de acerto ou Acurácia Global (ag), proposta por Hellden *et al.* (1980) (Equação 5), é calculada dividindo-se a soma dos valores da diagonal principal, que representa o número de amostras classificadas corretamente n_{ii} , pelo número total de amostras coletadas N , ou seja:

$$ag = \frac{\sum_{i=1}^M n_{ii}}{N} \quad (5)$$

Onde,

M = número de categorias informacionais presentes na matriz de erros;

n_{ii} = elementos da diagonal principal, ou seja, elementos classificados corretamente;

N = número total de amostras.

Segundo Brites *et al.* (1996), o índice G , ou seja, ag , apresenta os maiores valores quando comparado a outros índices pelo fato de considerar apenas a diagonal principal da matriz de erros, ignorando a ocorrência de concordância casual entre as classes.

2.4.3 Índice Kappa

Uma técnica estatística muito utilizada também na obtenção da acurácia da classificação é a estatística Kappa. A estatística Kappa é uma técnica multivariada discreta de utilização na avaliação da exatidão (COHEN, 1960). Pode ser utilizada para determinar se uma matriz de erro é significativamente diferente da outra. (CONGALTON,1991).

A estimativa de precisão calculada por estatística Kappa pode ser obtida a partir da equação 6 (CAVALCANTI, 2014):

$$K = \frac{n \sum_{i=1}^l x_{ii} - \sum_{i=1}^l x_i * x_{+i}}{n^2 - \sum_{i=1}^l x_i * x_{+i}} \quad (6)$$

Onde l é o número de linhas da matriz, i é o número de da observação em relação a linha i e a coluna i , e são os totais da linha i e coluna i respectivamente e n é o número total de observações (BISHOP et al., 1975 apud CAVALCANTI, 2014).

A estatística Kappa representa a acurácia a partir da relação entre os valores da diagonal principal e incorpora indiretamente os elementos que estão fora da diagonal ao resultado estatístico (CONGALTON, 1991), diferentemente, da acurácia global que incorpora apenas a diagonal principal e exclui os erros de omissão e de comissão do resultado. Isso faz do valor Kappa seja um dos mais utilizados em testes de acurácia estatística.

O resultado da estatística Kappa normalmente é comparado aos valores contidos na tabela 3, proposta por Landis & Koch (1977), a fim de indicar a qualidade do mapa temático. Embora essa tabela tenha sido desenvolvida para analisar resultados de diagnósticos clínicos, a mesma tem sido referência para classificar mapas resultantes da utilização de imagens de sensoriamento remoto (PRADO, 2009 apud PASSO, 2013).

Segundo Brites *et al.* (1996) Apud Passo (2013), o índice *Kappa* é recomendado como uma medida apropriada para avaliar a exatidão porque não representa apenas os valores que se situam na diagonal principal da matriz, mas ela por inteiro, sendo esta uma forma padronizada para reportar erros em locais específicos.

2.4.4 Acurácia do Produtor (Ap) e Acurácia do Usuário (Au)

Segundo Moreira (2007), a qualidade de um mapa temático é avaliada com base em dois quesitos: a precisão e exatidão de mapeamento.

Enquanto a precisão do mapeamento significa quanto à área de cada classe reflete a verdade no campo, a exatidão é um número (índice) que avalia o posicionamento da distribuição espacial de cada uma das classes que foram mapeadas (MENDES et al., 2015).

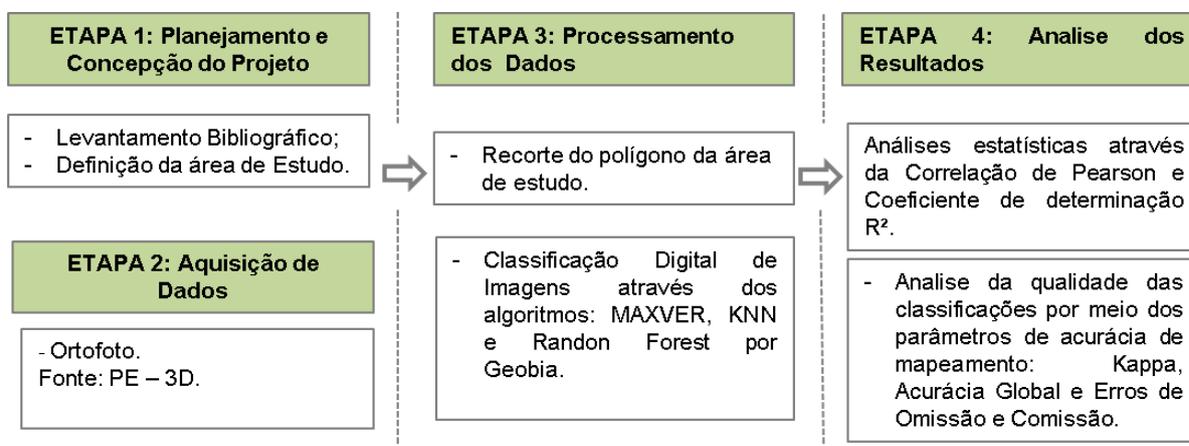
A acurácia do usuário ou do consumidor refere-se ao erro de comissão, enquanto a acurácia do produtor refere-se ao erro de omissão. Um erro de comissão consiste na inclusão de uma área dentro de uma classe à qual ela não pertence na realidade. Por outro lado, um erro de omissão consiste na exclusão de uma área da classe à qual ela pertence de fato (VIEIRA et al., 2009).

3 METODOLOGIA DA PESQUISA

Este capítulo compreende os procedimentos metodológicos desenvolvidos nesta pesquisa, como: área de estudo (Figura 3), materiais e métodos utilizados.

A metodologia empregada no desenvolvimento desta pesquisa foi compreendida em quatro etapas: a primeira corresponde ao planejamento e concepção do Projeto; a segunda, a aquisição dos dados; a terceira se refere ao processamento dos dados e; a quarta e última etapa, consiste nas análises e discussões dos resultados. A Figura 2 apresenta o fluxograma metodológico utilizado no desenvolvimento da pesquisa.

Figura 2 - Fluxograma da Metodologia.



Fonte: Autor (2020).

3.1 ÁREA DE ESTUDO

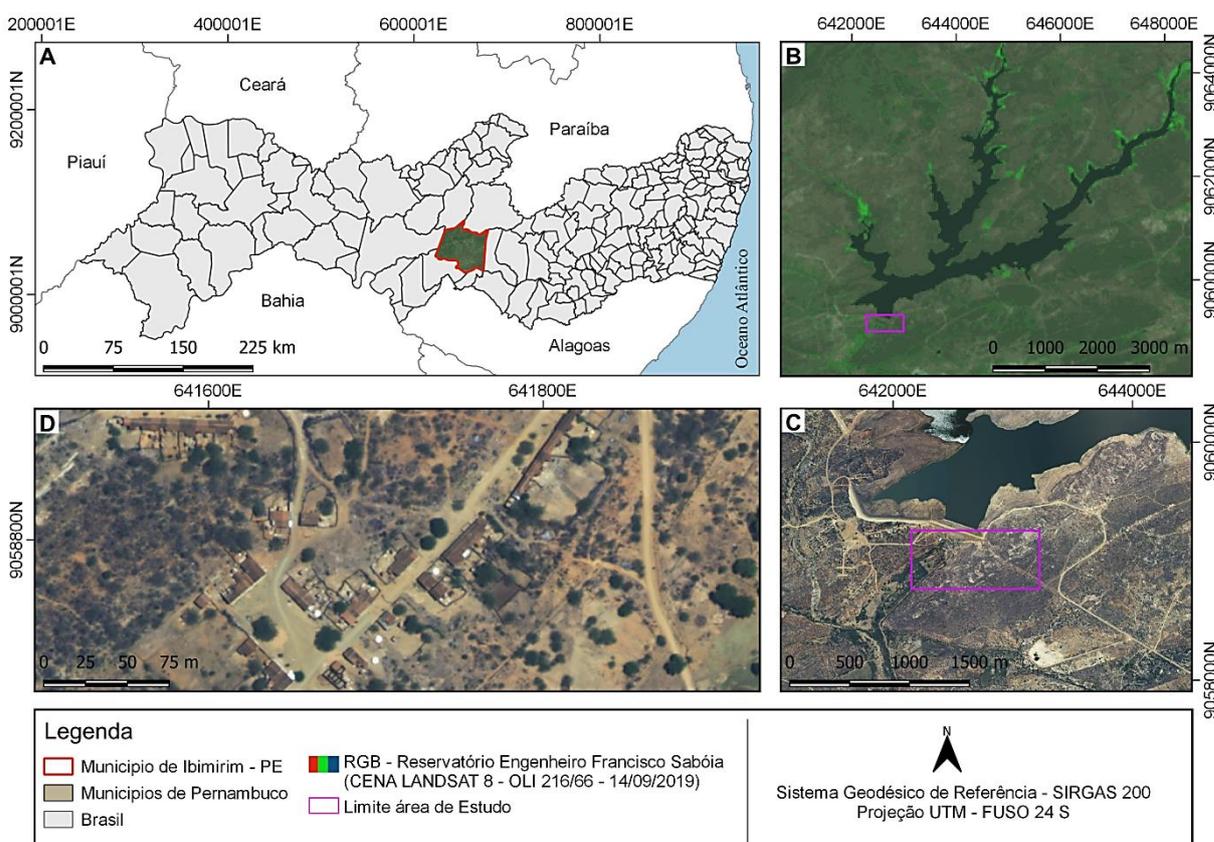
O reservatório Engenheiro Francisco Sabóia, também chamado Poço da Cruz, foi construído pelo DNOCS com objetivo de minimizar os efeitos decorrentes dos longos períodos de estiagem (OLIVEIRA e GALVÍNCIO, 2009), localizado no município de Ibimirim, na Bacia do Rio Moxotó, Estado de Pernambuco. Dista de 333

km a oeste da capital do estado, Recife, e se localiza na mesorregião de Sertão do Moxotó, no submédio da bacia do Rio São Francisco (LIRA, 2015).

Para os experimentos, fez-se um recorte da área de estudo, enquadrado nas coordenadas projetadas ao Sistema Geodésico de Referência SIRGAS 2000 - Fuso 24 S (641756, 7 E 9059110, 3 N; 642122, 45 E 9059284, 97 N), por se tratar de uma área viável para mapeamento de feições em pontos urbanos consolidados, no município pernambucano de Ibimirim próximo ao Reservatório.

A Figura 3 apresenta (A) – A Área de Estudo inserida no Estado de Pernambuco, Nordeste brasileiro. (B) – Recorte da cena 216/66 do satélite Landsat 8 – OLI de 14/09/2019, evidenciando o Reservatório Engenheiro Francisco Sabóia (Poço da Cruz). (C) Imagem do PE-3D, destacando o polígono utilizado para a área de estudo sob a escala da cena completa da ortoimagem onde se encontra dimensionado próximo ao Reservatório Poço da Cruz. (D) – Imagem do PE3D mostrando a ocupação urbana em partes do entorno do Reservatório.

Figura 3 - Área de Estudo.



Fonte: Autor (2020).

A região está inserida no clima semiárido, segundo a classificação de Kopper, é do tipo BShw, semiárido quente, com temperatura média anual de 25°C, com precipitações pluviométricas médias anuais concentradas no final e início de cada ano, vegetação é a Caatinga hiperxerófila, uma vegetação característica da região semiárida do Sertão (CASTRO et al., 2020).

Próximo ao açude de Poço da Cruz encontra-se uma comunidade que está localizada ao norte do município de Ibimirim. Dentre as atividades econômicas presente na região está à pesca no açude do Poço da Cruz, que tem tornado Ibimirim uma importante região da pesca artesanal das Sub-Bacias do São Francisco em Pernambuco (Lira, 2015).

3.2 MATERIAL

Como material foi utilizada a ortofoto SC-24-X-A-VI-2-NO-A-II, na escala de 1: 5000 com GSD de 50 cm, disponibilizada pelo PE3D, datada de 2014.

A Tabela 3 descreve os softwares e recursos tecnológicos utilizados no desenvolvimento da pesquisa:

Tabela 3 - Softwares e Recursos Tecnológicos.

Software/Equipamento	Aplicação Metodológica
QGIS 3.6.1 – <i>open source</i>	Processamento Digital das imagens.
Excel 2010	Cálculos Estatísticos.
Envi 5.6	Processamento Digital das imagens e aplicação em Geobia.
Word 2010	Redação do Trabalho de Conclusão de Curso.
Notebook (64 bits)	Processamento Digital das imagens, Tratamento dos dados e redação do texto.

Fonte: Autor (2020).

3.3 MÉTODOS

Para o processamento digital das imagens foi realizado a Reprojeção cartográfica ao Sistema Geodésico Brasileiro de Referência – SIRGAS 2000 e recorte

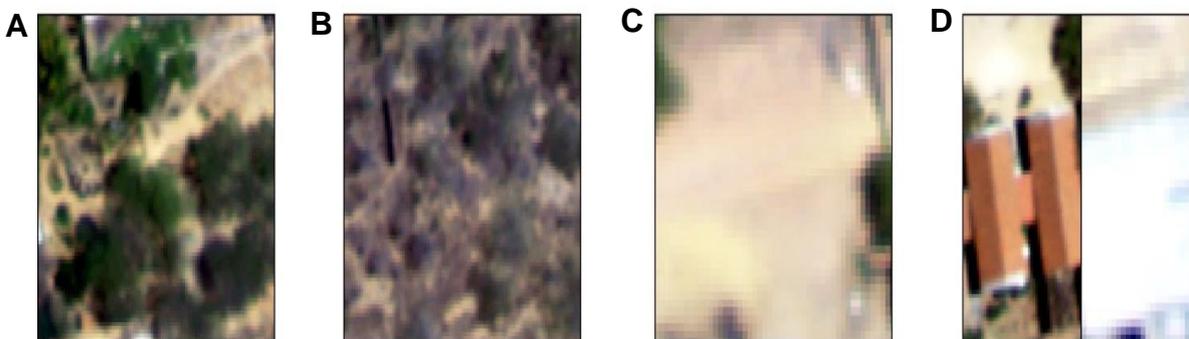
da cena a área de interesse (Figura 1). Todo o processamento executado nesta etapa foi desenvolvido nos softwares: QGIS 3.6.1 e ENVI 5.1.

As classes mapeadas foram escolhidas por meio de fotointerpretação e análise prévia de diminuição de erros, a partir do comportamento do agrupamento de pixels semelhantes (Figura 4).

Em seguida, foram testados neste trabalho três algoritmos de classificação: MXVER, *RF* e KNN, treinados para um conjunto de 100 amostras de forma aleatória, ao longo do recorte. As classes foram:

- A. Vegetação Densa que abrangeram os pixels referentes á arvores;
- B. Vegetação baixa, representada pela vegetação nativa seca ou com menos verdejamento;
- C. Solo Exposto, correspondentes as áreas totalmente homogêneas sem presença de outros elementos da paisagem; e
- D. Telhados, referentes a dois tipos de cores de telhados diferentes.

Figura 4 - Elementos da paisagem definidos para a classificação em A - Vegetação Densa B - Vegetação baixa C - Solo Exposto e D - Telhados.



Fonte: Autor (2020).

Baseando-se na metodologia de Liu *et al.* (2007), foram escolhidas as medidas de acurácia: índice Kappa, acurácia global, acurácia do usuário e produtor (avaliada através dos erros de omissão e comissão) e correlação de Pearson, utilizadas neste estudo, relativas à matriz de confusão. As medidas de acurácia estão separadas por categoria de classe e mapa, como pode ser visto na Tabela 4

Tabela 4 - Medidas de acurácia de classificação.

Grandeza	Fórmula	Definição	Referências
Acurácia do Produtor	$ap_i = p_{ii}/p_{i+}$	São as frações amostrais de <i>pixels</i> de cada classe corretamente atribuídos às suas classes pelos classificadores.	Story e Congalton (1986)
Acurácia do Usuário	$au_i = p_{ii}/p_{+i}$	São as estimativas das frações de <i>pixels</i> do mapeamento, para cada classe, corretamente classificados.	Story e Congalton (1986)
Acurácia Global	$ag = \sum_{i=1}^m p_{ii}$	É a estimativa da proporção de acerto global dos classificadores. É compreendida entre 0 e 1.	Story e Congalton (1986)
Coeficiente <i>Kappa</i>	$K = (ag - \sum_{i=1}^m p_{i+}p_{+i}) / (1 - \sum_{i=1}^m p_{i+}p_{+i})$	Mede a concordância entre classificação e valores de verdade. Um valor <i>kappa</i> igual a 1 representa concordância perfeita, enquanto um valor igual a 0 representa concordância imperfeita.	Cohen (1968)
Correlação de <i>Pearson</i>	$\frac{cov(X, Y)}{\sqrt{var(X) * var(Y)}}$	Mede o grau da correlação entre duas variáveis. Um valor de coeficiente igual a 1 representa concordância perfeita positiva, -1 representa concordância perfeita negativa, enquanto um valor igual a 0 representa não dependem linearmente uma da outra.	Pearson (1895)

Fonte: Autor (2020).

Cada medida de acurácia por categoria varia de acordo com uma determinada faixa de valores, assim: (Acurácia do Usuário) A_u e (Acurácia do Produtor) A_p variam de 0 até 1 e p_i representando a proporção da categoria i da cobertura da terra. A caracterização das classes de qualidade do índice Kappa é descrita em experimentos utilizados por Cohen *et al.* (1968) e contextualizado no subitem 2.4.3.

4 RESULTADOS

Neste item são apresentados os principais resultados encontrados com o desenvolvimento da metodologia aplicada na pesquisa. Em que, os subitens 4.1 e 4.2 detalham os resultados encontrados e os correlacionam com exemplos, dentre eles, os explorados na fundamentação teórica.

4.1 CLASSIFICAÇÕES POR GEOBIA

A Figura 5 mostra a ortoimagem mapeada por GEOBIA, através de separabilidade de texturas que foi utilizada como produto cartográfico de referência para testar os classificadores Maxver, Randon Forest e KNN.

Figura 5 - Ortoimagem classificada por GEOBIA através de separabilidade de texturas.



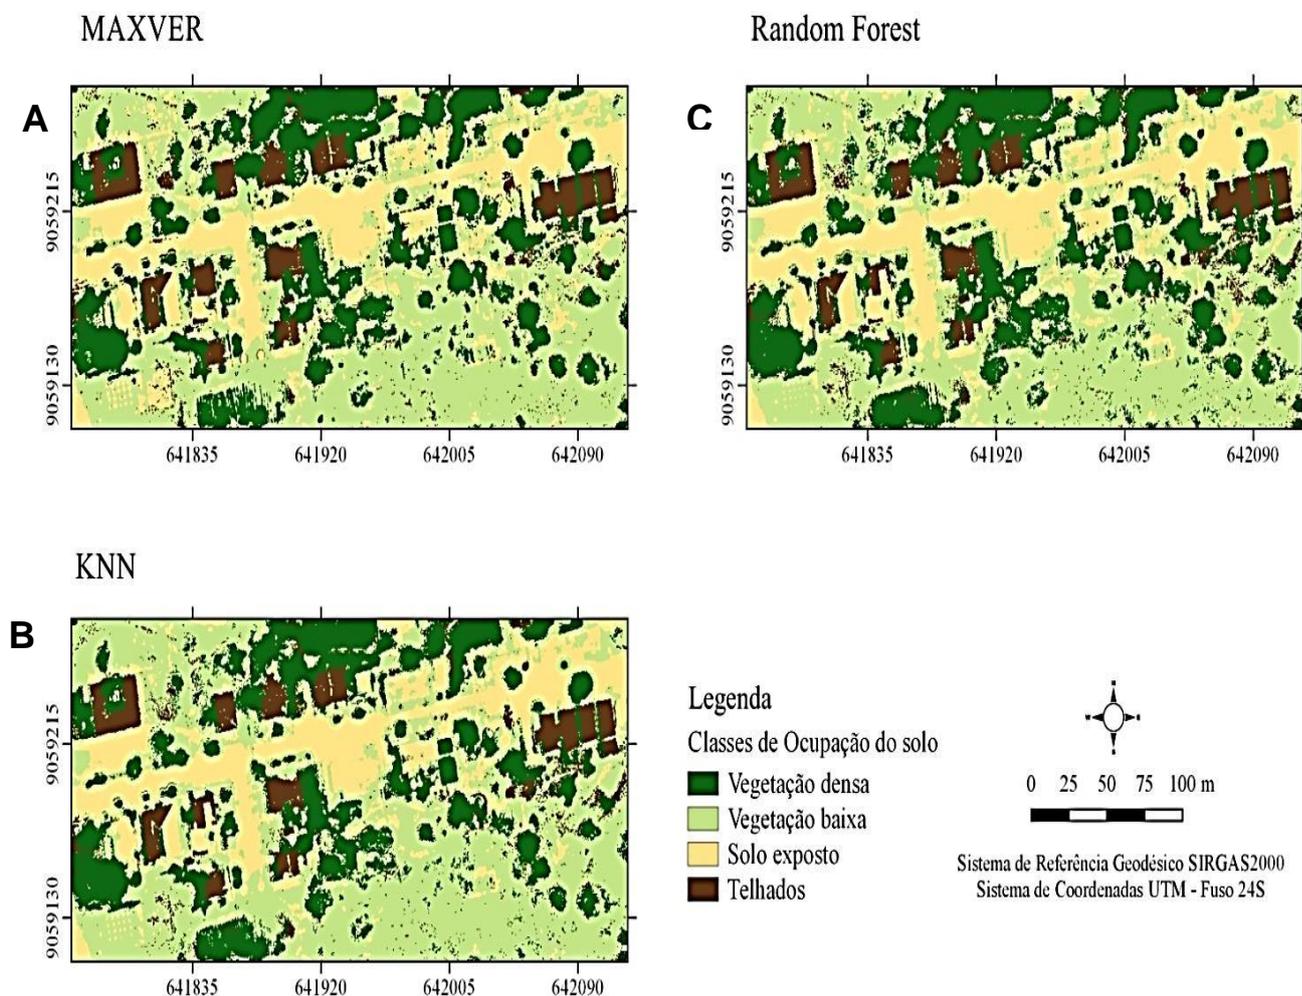
Fonte: Autor (2020).

Observa-se que a ortofoto classificada pelo algoritmo de GEOBIA apresentou alto nível de detalhamento das feições imageadas, além de permitir ao usuário maior precisão e poder de interpretação dos elementos da paisagem previamente

escolhidas a serem classificadas. Nesta primeira análise foi gerada uma classificação através do índice de separabilidade empregando os elementos fotointerpretativos com abordagem em GEOBIA, através de uma segmentação.

A figura 6 mostra os mapas temáticos de ocupação do solo na área de estudo, com o uso da ortofoto e por meio dos algoritmos: (a) Maxver (b) Random Forest e (c) KNN para as classes atribuídas.

Figura 6 - Ortoimagem classificada por GEOBIA através de separabilidade de texturas pelos algoritmos (a) - MAXVER (b) - Randon Forest e (c) – KNN.



Fonte: Autor (2020).

A classe “Vegetação densa” apresentou duas ambiguidades em todos os classificadores:

i) - Mistura de pixels com a classe “Vegetação baixa”: Na parte inferior dos mapas tem-se uma vasta presença de pixels isolados da classe “Vegetação densa”, em que são originalmente da classe vegetação baixa.

ii) Erros na classificação causada por sombras das árvores e telhados. A vegetação densa e as áreas sombreadas possuem textura homogênea e coloração escura, causando ambiguidades na classificação dos pixels e sua seleção natural.

Na classe “Vegetação baixa”, assim como na classe “Vegetação densa” e “Solo exposto”, houve uma distribuição espacial semelhante em todos os classificadores. Embora esta classe requeira mais sensibilidade do operador, uma vez que possui pixels com elevada correspondência á classe “Solo exposto”. Apresentando feições visualmente similares com o mapeamento de referência.

A classe “Solo exposto” ficou representada em todos os mapas, como vazios entre as edificações, o que possivelmente caracteriza-se como áreas de passagem.

A classe “Telhado” visualmente foi a que apresentou maiores disparidades, com *pixels* isolados distribuídos em todo mapa, mostrando assim, exatidão baixa dos classificadores para este tipo de ponto urbano. Embora esta classe seja bastante complexa, quando se trata do plano da fotointerpretação. Uma vez que, existe uma diversidade arquitetônica de telhados, com textura, formas e cores singulares.

4.2 ANÁLISE DA ACURÁCIA DO MAPEAMENTO

A Acurácia do mapeamento foi analisada a partir das informações extraídas da matriz de confusão ou de erros, em que foram investigadas as grandezas: Acurácia Global, índice Kappa, Correlação de Pearson, acurácia do produtor e usuário (avaliadas através dos erros de omissão e comissão).

4.2.1 Matriz de Confusão, Acurácia Global e índice Kappa

As Tabelas 5, 6 e 7 apresentam a matriz de confusão, vista no item XX, gerada pela classificação do algoritmo por MXVER ,RF e KNN . A diagonal principal apresenta as amostras corretas das classes Agricultura, Água, Caatinga Aberta, Caatinga Densa e Pastagem.

Tabela 5 - Matriz de Confusão (Máxima Verossimilhança).

Classes	Vegetação Baixa	Vegetação Densa	Telhado	Solo Exposto
Vegetação Baixa	306.852	522.137	304.605	34.972
Vegetação Densa	76.458	1.187.470	278.386	17.494
Telhado	90.911	556.018	102.2980	3.917
Solo Exposto	391.282	649.208	135.129	70.961
Total	865.538	2.914.842	1.741.120	127.344

Fonte: Autor (2020).

Tabela 6 - Matriz de Confusão (KNN).

Classes	Vegetação Baixa	Vegetação Densa	Telhado	Solo Exposto
Vegetação Baixa	284.161	293.429	226.641	34.913
Vegetação Densa	104.935	1.461.732	345.506	21.346
Telhado	103.606	674.097	1.056.680	6.553
Solo Exposto	370.431	483.318	110.700	64.017
Total	865.538	2.914.842	1.741.120	127.344

Fonte: Autor (2020).

Tabela 7 - Matriz de Confusão (Randon Forest).

Classes	Vegetação Baixa	Vegetação Densa	Telhado	Solo Exposto
Vegetação Baixa	297.578	479.120	360.805	33.997
Vegetação Densa	135.512	1.251.791	249.873	34.324
Telhado	90.512	610.116	969.511	5.904
Solo Exposto	338.950	570.643	159.202	52.830
Total	865.538	2.914.842	1.741.120	127.344

Fonte: Autor (2020).

De acordo com Mendes *et al.* (2015) e Hay (1988), o uso da matriz de erro permite o cálculo de parâmetros de exatidão geral da classificação, e a identificação de erros específicos que afetam cada uma das categorias. Por meio das matrizes de confusão é permissível afirmar que houve uma redução de pixels classificados para vegetação densa, vegetação baixa e telhado quando utilizado o algoritmo KNN e quando comparado aos demais algoritmos. Em contrapartida, o algoritmo MXVER apresentou a maior quantidade de pixels classificados para todas as classes.

A partir dos dados das matrizes de confusão descritos através da Tabelas 5 e 6, foi possível, analisar os parâmetros de acurácia global e índice kappa como é apresentado na Tabela 8.

Tabela 8 - Parâmetros de acurácia extraídos das matrizes de confusão.

Classe	Máxima Verossimilhança	Randon Forest	KNN
Acurácia Global	0,90	0,93	0,96
Coefficiente Kappa	0,64	0,67	0,70

Fonte: Autores (2020).

Na Tabela 8 é visto que não houve redução de precisão nos mapas para os diferentes classificadores, apresentando resultados com conformidade e valores próximos. Estes resultados evidenciam a possibilidade para a redução de erros temáticos entre os classificadores quando se utiliza imagens de pequenas áreas e moderado número de classes.

Conforme visto no subitem 2.4.3 em Landis e Koch (1977), no geral, os classificadores apresentaram comportamentos próximos e os resultados de acurácia apresentados mostraram altos valores de acerto por classe temática, ou seja, o índice Kappa foi classificado como muito bom. Além disso, a variação de acurácia global se deu superior a 90% confirmando os valores obtidos com o índice Kappa.

Dados análogos foi encontrado em Amaral *et al.* (2009), comparando o desempenho dos classificadores por região e por pixel em imagens de alta resolução espacial para a classificação de estágios de sucessão florestal, obtiveram índice Kappa entre 0,44 a 0,64.

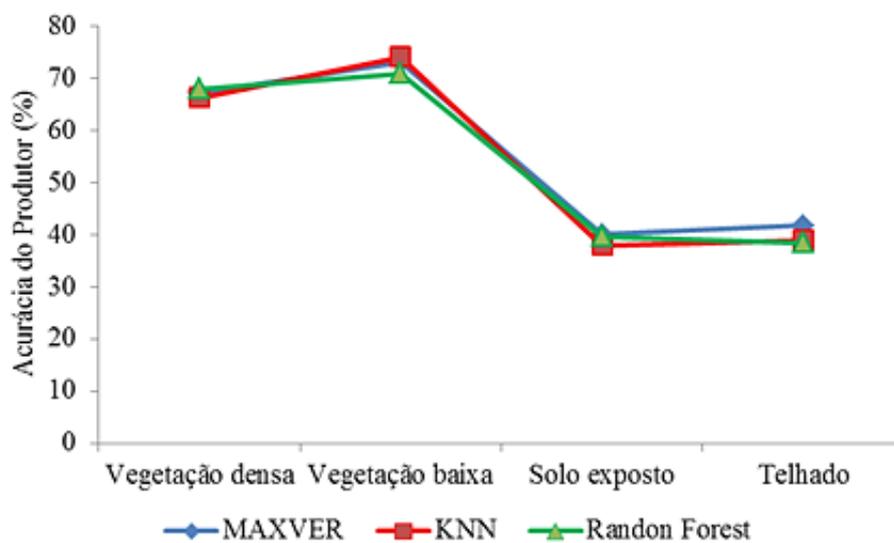
Em Prado (2016) utilizando a GEOBIA, mostrou que visualmente, os erros de classificação apresentam-se diluídos em áreas muito pequenas, porém, as classes temáticas se mostraram mais passíveis a erro temático, por apresentarem várias relações entre polígonos de outras classes. Esses resultados foram encontrados por Vieira *et al.* (2012) que ao avaliar o uso de GEOBIA através de algoritmos de classificação de imagem, apresentou altos níveis de exatidão global e coeficientes kappa, atingindo 93,99% e 0,87.

4.2.2 Análise da Acurácia do Produtor (A_p) e Acurácia do Usuário (A_u)

A partir da Matriz de confusão baseada em pixels dos dados de classificação pelo algoritmo de teste e classificação de referência, foi possível o cálculo dos parâmetros

acurácia do produtor e acurácia do usuário, como mostram graficamente as Figuras 7 e 8, em que foi possível a análises dos erros de omissão e comissão.

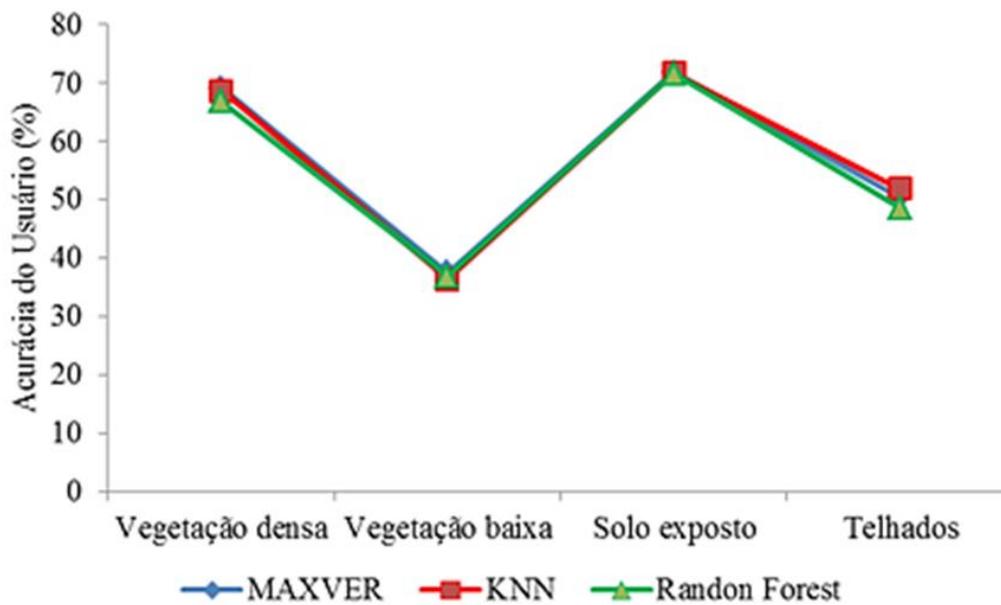
Figura 7 - Acurácia do produtor



Fonte: Autor (2020).

A Figura 8 mostra o nível de acurácia do usuário. A partir daí foi possível analisar os erros de omissão.

Figura 8 - Acurácia do usuário.



Fonte: Autor (2020).

Todas as classes analisadas obtiveram resultados satisfatórios. A classe de “Vegetação densa” apresentou maior quantidade de pixels, com boa classificação, em relação a todas as classes, tanto na acurácia do produtor, quanto na acurácia do usuário.

A classe de “Vegetação baixa” apresentou variações importantes nos valores de acurácia do produtor e do usuário, variando entre 71,05% ~ 73,25% (A_p) e 36,38% ~ 37,57% (A_u), respectivamente. O baixo valor de acurácia do usuário para esta classe “Vegetação baixa” pode estar relacionado a ambiguidades, como a atribuição de um pixel a uma classe diferente, referentes à classificação com a classe “Vegetação densa”.

A classe “Solo exposto” apresentou um comportamento inverso a “Vegetação baixa”, com valor de 40,1% ~ 37,69% para acurácia do produtor e 71% ~ 72% para acurácia do usuário. Isto indica que no momento de adquirir as amostras pode ter ocorrido confusão entre pixels pertencentes as classes, tendo em vista a variabilidade de estado da vegetação da Caatinga.

A classe “Telhado” apresentou baixas estimativas de acurácia, tal fato pode estar relacionado à complexidade dos padrões espectrais e texturais desta classe que ocasiona interferências no desempenho dos classificadores no espaço de atributos.

Os resultados encontrados corroboram com os encontrados por Rezende (2012), em que valores de acurácia em trechos urbanos, foram justificados através da quantidade do número de amostras, que diminuiu os resultados de acurácia do usuário.

4.2.3 Análises Estatísticas

A Tabela 9 apresenta os valores estatísticos do coeficiente de Pearson, coeficiente de determinação R^2 e (*Root Mean Square Error*) RMSE obtidos a partir das análises dos pixels do conjunto de amostras utilizado.

Tabela 9 - Análises Estatísticas

Estatística	MXV	RF	KNN
Coeficiente de Pearson	0,63	0,73	0,83
R^2	0,40	0,54	0,70
RMSE	1,48	1,33	1,10

Fonte: Autor (2020).

Ao analisar a Tabela 5 percebe-se que o algoritmo KNN apresentou maior correlação e R^2 , indicando uma maior correspondência com o mapeamento de referência, oposto ao MXV que apresentou uma baixa correlação e R^2 , e alto valor de RMSE.

Estes resultados podem estar associados a três fatores: a classificação foi realizada por uma imagem de alta resolução espacial com classes bem definidas, com a finalidade de diminuir os prováveis erros, a utilização de igual padrão para as amostras geradas por classificadores supervisionados e a área de realização do experimento tratar-se de uma região com uma paisagem bastante fragmentada.

5 CONCLUSÕES, RECOMENDAÇÕES E CONSIDERAÇÕES FINAIS

Nesta seção são abordadas as principais conclusões encontradas com a análise dos resultados obtidos e são feitas recomendações para trabalhos futuros baseados nas abordagens tratadas nesta pesquisa.

5.1 CONCLUSÕES E RECOMENDAÇÕES

Neste estudo, o processo de urbanização no entorno do Reservatório Poço da Cruz, do estado de Pernambuco, foi investigado por meio do uso de técnicas de interpretação e classificação de imagens, resultando no mapeamento do uso do solo da área.

Neste processo de mapeamento do uso do solo, foram realizadas análises da eficiência dos algoritmos classificadores de imagem: MXVER, RF e KNN aplicados a GEOBIA utilizando a extração de dados derivados da Ortofoto SC-24-X-A-VI-2-NO-A-II obtida no projeto PE3D e, segundo os resultados das análises, pôde-se concluir que:

(1) A abordagem metodológica usada neste estudo que combinou as vantagens da interpretação visual de imagens de alta resolução para qualificar, mapear e identificar classes específicas de pontos urbanos, em áreas próximas a cursos hídricos, usando a acurácia posicional da ortofoto apresentaram potencial para esse tipo de demanda de mapeamento de uso e ocupação do solo no entorno de corpos hídricos e do seu monitoramento de ações antrópicas e de impactos ambientais.

(2) Os algoritmos: MXVER, KNN e Random Forest não apresentaram diferenças significativas na identificação das classes previamente definidas, entretanto a classe “Telhado” apresentou em todos os classificadores, baixos coeficientes de classificação temática de mapeamento, isto pode esta associado a baixa quantidade de amostras do objeto presente na cena ou a presença muito próxima de cobertura vegetal aos telhados das residências.

(3) Os mapeamentos gerados neste artigo apresentaram ambiguidade no agrupamento de áreas de sombras das árvores no solo, dossel sombreado e não sombreado.

(4) O experimento identificou que a combinação entre a GEOBIA e os parâmetros de qualidade classificadores foi eficaz para evitar a classificação incorreta

de objetos com recursos semelhantes. Entretanto, esta associação não foi capaz de qualificar qual o classificador mais eficiente para classificar imagens de alta resolução espacial. Pois os classificadores usuais possuem baixo poder de discriminação de feições em imagens de alta resolução, devido a quantidade de objetos identificados num pixel em decorrência da resolução espacial.

Contudo, as aplicações dos algoritmos de classificação de imagem: MXVER, KNN e RF com abordagem em Geobia por meio de critérios fotointerprativos facilitaram o alcance do principal objetivo deste trabalho, ou seja, a classificação da cobertura e uso do solo nas proximidades do Reservatório, possibilitando identificar alterações na paisagem devido a presença de ações antrópicas oriundas da ocupação urbana numa APA, visto que as feições foram em sua maioria classificadas de forma correta e com alto valor de Kappa e acurácia global para os mapeamentos realizados, classificando o mapeamento como bom.

Portanto, espera-se que os resultados alcançados com esta pesquisa subsidiem a melhoria da gestão do uso e ocupação do solo no entorno do reservatório Poço da Cruz, contribuindo para a manutenção da qualidade de suas águas. Através de medidas que possibilitem o uso consciente da área, assegurando a preservação apesar da presença de ações antrópicas, oriundas do processo de urbanização no semiárido. Como propostas para trabalhos futuros, recomenda-se uma análise com mais classes temáticas e outros algoritmos, a exemplo, do algoritmo Distância Mínima.

As classes com maior número de pixels classificados apresentaram melhores respostas visuais na identificação dos objetos pertencentes a cada classe analisada, embora tenha sido identificada a presença de mistura espectral de pixels, que acarretou no acréscimo de erros ao mapeamento, agregado com a presença dos erros de omissão, encontrando com maior frequência em uma das classes mapeadas.

Quanto a correlação entre os classificadores e o mapa de referência, o algoritmo KNN apresentou maior correlação, 0,83 e o MXV a menor correlação, 0,63. Conclui-se que a utilização dos classificadores testados para o mapeamento de áreas urbanas por GEOBIA, utilizando ortofotos com resolução espacial de 50cm, possibilitam um mapeamento do uso e ocupação do solo com acurácia global de 90% obtidos.

REFERÊNCIAS

ABBURU, S.; BABU GOLLA, S.. Satellite image classification methods and techniques: a review. **Int. J. Comput. Appl.** v.119, p.20–25, 2015.

ADAMI, M.; PINHEIRO, S.E.; MOREIRA, A. M. **Aplicação de diferentes algoritmos para a classificação de imagens ETM+/LANDSAT-7 no mapeamento agrícola.** São José dos Campos: INPE. 43p., 2002.

AL-DOSARY, Naji Mordi Naji; AL-HAMED, Saad Abdulrahman; ABOUKARIMA, Abdulwahed Mohamed. K-NEAREST NEIGHBORS METHOD FOR PREDICTION OF FUEL CONSUMPTION IN TRACTOR-CHISEL PLOW SYSTEMS. **Engenharia Agrícola**, v. 39, n. 6, p. 729-736, 2019.

AMARAL, A.Z., AUDI, R. **Fotopedologia.** In: MONIZ, A.C. Elementos de Pedologia. São Paulo: EDUSP/Polígono, 1972. p. 429-442.

AMARAL, B. A.; RIOS, S. A.; Geoprocessamento: mapeamento do uso e ocupação do solo no alto curso do Rio Piedade. **Revista Geografia**, v.2, n.1, p.1-8, 2012.

AMARAL, M.V.F.; SOUZA, A. L.; SOARES, V. P.; SOARES, C. P; LEITE, H. G.; MARTINS, S.V.; FERNANDES FILHO, S.V.; LANA, E.I.J.M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v. 33, n. 3, p. 575-582, 2009.

ANDRADE, R. G.; SILVA, G. B. S. da; OLIVEIRA, B. P. de; VICENTE, L. E.; LEIVAS, J. F. **Metodologia de classificação digital aplicada a imagem de alta resolução espacial.** Boletim de Pesquisa e Desenvolvimento da Embrapa (2012).

BINS, L. S., ERTHAL, G. J., FONSECA, L. M. G. Um método de classificação não-supervisionada por regiões. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 6., 1993, Recife. **Anais...** Recife: (SIBGRAPI 93). SBC/UFPE, 1995. v.2, p. 65-68.

BORGES, M.H.; PFEIFER R.M.; DEMATTÊ J.A.M.; Evolução e mapeamento do uso da terra, através de imagens aerofotogramétricas e orbitais em Santa Bárbara D'Oeste (SP) **Scientia agrícola**, v. 50, n.3, p.365-371, 1993.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

BREIMAN, L. **Using adaptive bagging to debias regressions**. Technical Report 547, Statistics Dept. UCB. 1999.

BRASIL. Lei nº 12.727, de 17 de outubro de 2012. Institui o Novo Código Florestal Brasileiro. Diário Oficial da União, Brasília, DF, n. 227, 18 Oct 2012. Seção 1, p. 1.

BRASILEIRO, F, G.; OLIVEIRA, C, M, M.; RODRIGUES, R, A.; DELGADO, R, C. Classificação de imagem orbital pelo método máxima verossimilhança em Quixeramobim, Ceará, Brasil. **Rev. Geogr. Acadêmica** v.10, n.1, 2016.

BREIMAN, L.; FREADMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees**. Wadsworth International, CA. 1 ed. 1984. BUFFON, E. A. M.; PAZ, O. L. de S. da; SAMPAIO, T. V. M. Uso de Veículo Aéreo Não Tripulado (VANT) Para Mapeamento das Vulnerabilidades à Inundação Urbana: Referenciais e Bases de Aplicação. **Revista do Departamento de Geografia**, n. spe, p. 180-189, 2017.

BUFFON, E.; PAZ, O. da; SAMPAIO, T. Veículo aéreo não tripulado (VANT) - aplicação na análise de inundações em áreas urbanas. **Got - Journal Of Geography And Spatial Planning**, v. 13, p. 85-108, 2018.

CARMO, Z. F. L.; SCHAEFER, R. G. E. C.; Mapeamento, por fotointerpretação, do uso e cobertura do solo urbano em Rio Branco (AC): Subsídios ao planejamento urbano. **Revista de C. Humanas**, v. 9, n. 1, p. 85-95, 2009.

CASTILLEJO-GONZÁLEZ I. L.; LÓPEZ-GRANADOS F.; GARCÍA-FERRER A.; PEÑA-BARRAGÁN J. M.; JURADO-EXPÓSITO M.; ORDEN M. S.; GONZÁLEZ-AUDICANA M. Object - and pixel-based analysis for mapping crops and their

agroenvironmental associated measures using QuickBird imagery. *Computers and Electronics in Agriculture*. v.68, p. 207-215, 2009.

CASTRO, I. N.; SANTOS, S. R.; KONDO, M. K.; MAIA, V. M.; SANTOS, C. C. R. AGRONOMIC PERFORMANCE AND WATER USE EFFICIENCY OF IRRIGATED CACTUS PEAR CULTIVARS. **Revista Caatinga**, v. 33, n. 2, p. 529-540, abr. 2020.

CATTANI, C.E.V.; MERCANTE, E.; DE SOUZA, C. H. W.; WRUBLACK, S. C. Desempenho de algoritmos de classificação supervisionada para imagens dos satélites RapidEye. (2013). *In: Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE. Anais*. 10, São José dos Campos: INPE, 2013, p. 2060 – 2065.

CAVALCANTI, R. C. Simulação e análise espacial de riscos de inundações usando Dados LIDAR: estudo de caso da Bacia do Rio Una-PE. Dissertação (Programa de Pós-graduação em Ciências Geodésicas e Tecnologias da Geoinformação). Departamento de Engenharia Cartográfica - Universidade Federal de Pernambuco. CTG, 2014.

COHEN, J. Weighted kappa: Nominal scale agreement with provision for scaled disagreement or partial credit. **Psychological Bulletin**, v.70, p.213-220, 1968.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, v. 49 n. 12, p. 1671-1678, 1991.

CRÓSTA, A. P. **Processamento digital de imagens de Sensoriamento Remoto**. Campinas: IG/UNICAMP, 1992. 170 p.

CIRILO, J. A.; ALVES, F. H. B.; SILVA, L. A. C.; CAMPOS, J. H. A. L. Suporte de Informações Georreferenciadas de Alta Resolução para Implantação de Infraestrutura e Planejamento Territorial. **Revista Brasileira de Geografia Física**, v. 07, n.04, 2014.

DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P., Forest change detection by statisticalobject based method. **Remote Sens. Environ.** v.102, p.1–11. 2006.

EASTMAN, J. R. **Idrisi for Windows. Versão 2.0.** Worcester, MA: Clark University, 1999.

FELISBINO, S. B.; Guerrero, Y.; Barra, B.; Nierwinski, H.; Heidemann, M. **Sensoriamento remoto: Fundamentos e uso.** 1 ed. Poisson. Belo Horizonte. 2019.

FERNANDES, R. R.; NUNES, G. M.; SILVA, T. S. F.; Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. **Pesq. agropec. bras.** [online]. Vol.47, n.9, pp. 1251-1260, 2012.

FOLHARINI, S. O.; SOUZA, S. O. GEOBIA classification applied to the watershed management: case of watershed of monte alegre stream. **Rede: Revista Eletrônica do PRODEMA**, v. 10, n. 02, p. 37-48, 7 dez. 2016.

GAROFALO, D.F.T., MESSIAS, C.G., LIESENBERG, V., BOLFE, E.L., FERREIRA, M.C. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático. **Pesquisa Agropecuária Brasileira**, v. 50, n. 7, p. 593-604, 2015.

HAY, A. M. The derivation of global estimates from a confusion matrix. **International Journal of Remote Sensing**, v.9, n.8, p.1395-1398, 1988.

HUANG, H. et al. Unmanned aerial vehicle based remote sensing method for monitoring a steep mountainous slope in the Three Gorges Reservoir, China. **Earth Science Informatics**, 2017.

IBGE. Manual Técnico de Uso da Terra. 3ª Edição. ISSN 0103-9598. <https://biblioteca.ibge.gov.br/visualizacao/livros/liv81615.pdf>.

IMANDOUST, S. B.; BOLANDRAFTAR, M. Application of k-nearest neighbor (knn) approach for predicting economic events: Theoretical background. **International Journal of Engineering Research and Applications**, v. 3, n. 5, p. 605-610, 2013.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2.ed. New Jersey: Prentice Hall, 1996. 316 p.

KÖRTING T. S: **Classificação de Imagens por Regiões. Divisão de Processamento de Imagens**, INPE, São José dos Campos, 2006. Disponível em: <<http://www.dpi.inpe.br/~tkorting/projects/isoseg/material.pdf>>. Acesso em 15 set 2020.

KUHLMAN, C., Yan Y., Cao L., Rundensteiner E. (2017) Pivot-Based Distributed K-Nearest Neighbor Mining. *In: Ceci M., Hollmén J., Todorovski L., Vens C., Džeroski S. (eds) Machine Learning and Knowledge Discovery in Databases. Anais... ECML PKDD 2017. Lecture Notes in Computer Science, vol 10535. Springer, Cham.*

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977..

LINGNAU, C.; ANTUNES, A. F. B. Object oriented analysis and semantic network for high resolution image classification. **Boletim de Ciências Geodésicas**, v. 9, n. 2, p. 233-243, 2003.

LIRA, P.M.M. **Análise do uso e ocupação do solo no entorno do reservatório Poço da Cruz, Pernambuco – Brasil**. 92 f. Dissertação (Programa de Pós Graduação em Engenharia Civil) – Universidade federal de Pernambuco. Recife. 2015.

LIU, C ; Frazier, P., Kumar, L. Comparative assessment of the measures of thematic classification accuracy. **Remote Sensing of Environment** v. 107 p.606–616. 2007.

LOCK, R. E. M.; KIRCHNER, F. F. Classificação de imagens multiespectrais de landsat TM e feições de textura: mapeamento da cobertura da terra. **Floresta**, v.27, n.12, p.41-58, 1997.

LU, D.; Li, G.; Moran, E.; Hetrick, S. Spatiotemporal analysis of land-use and land-cover change in the brazilian amazon. **Int. J. Remote Sens.** 2013, 34, 5953–5978.

MAXWELL, A.E.; Strager, M.P.; Warner, T.A.; Ramezan, C.A.; Morgan, A.N.; Pauley, C.E. Large-Area, High Spatial Resolution Land Cover Mapping Using Random Forests, GEOBIA, and NAIP Orthophotography: Findings and Recommendations. **Remote Sens.** V.11, p.1409-1520, 2019.

MEHTA, S.; Shen, X.; Gou, J.; Niu, D. A New Nearest Centroid Neighbor Classifier Based on K Local Means Using Harmonic Mean Distance. **Information.** V.9, p.234-243, 2018.

MENDES, D. F.; SILVA, Samuel F.; FERRARI, J. L.; SANTOS, A. R.; GARCIA, R. F. Thematic accuracy of the maximum likelihood classifier in high spatial resolution imaging satellite geoeye-1. **Nucleus**, v. 12, n. 1, p. 107-118, 2015.

MENESES, P. R.; ALMEIDA, T. Introdução ao Processamento de Imagens de Sensoriamento Remoto. Brasília: UNB, 2012.

MENG, Q.; CIESZEWSKI, C. J.; MADDEN, M.; BORDERS, B. E.. K Nearest Neighbor Method for Forest Inventory Using Remote Sensing Data. **Giscience & Remote Sensing**, v. 44, n. 2, p. 149-165, 2007.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação.** 3. ed. Viçosa: Ed. UFV, 2007.

MOURA, A. V. N.; **Comparação entre classificadores supervisionados para fins de análise multitemporal do uso e cobertura da terra no entorno do Reservatório da Usina Hidrelétrica de Corumbá IV/GO.** 2016. 53f. Dissertação (Programa de Pós-Graduação em Geografia) - Instituto de Ciências Humanas, Universidade de Brasília. Brasília. 2016.

MONARD, M. C.; BARANAUSKAS, J. A. **Conceitos Sobre Aprendizado de Máquina. Sistemas Inteligentes Fundamentos e Aplicações.** 1 ed. Barueri-SP: Manole Ltda, 2003. p. 89--114.

MYINT SW, Gober P, Brazel A, Grossman-Clarke S, Weng Q Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. **Remote Sensing of Environment**, v.115, n.5, p.1145–1161, 2011.

NASCIMENTO, F. V. **Produtos de sensoriamento remoto de alta resolução aplicados á caracterização volumétrica de reservatórios de água**. 104 f. Dissertação (Programa de Pós-graduação em Engenharia Civil) – Universidade Federal de Pernambuco. Recife. 2017.

NASCIMENTO, R. F. F.; ALCÂNTARA, H. E.; KAMPEL, M.; STECH, L. J.; NOVO, E. M. L. M.; FONSECA, L. M. G. O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2. In: XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR, Natal, RN, Brasil. **Anais**. 14, São José dos Campos: INPE, 2009, p. 2079 – 2086.

-

OLIVEIRA, H.T.; GALVÍNCIO, D. J. Caracterização ambiental da Bacia Hidrográfica do Rio Moxotó- PE usando sensoriamento remoto termal. **Revista Brasileira de Geografia Física**. V.1 n.02, 2008.

OLIVEIRA, S. B.; MATAVELI, V. A. G.; Avaliação do desempenho dos classificadores Ioseg e Bhattacharya para o mapeamento de áreas de cana-de-açúcar no município de Barretos-SP. In: Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil. **Anais**. Foz do Iguaçu: INPE, 2013, p.1-8.

OROZCO FILHO, C. J. **Avaliação do Uso da Abordagem Orientada-Objeto com Imagens de Alta Resolução RapidEye na Classificação das Fitofisionomias do Cerrado**. 52f. Dissertação (Programa de Pós-Graduação em Geografia) - Universidade de Brasília Instituto de Ciências Humanas. Brasília. 2017.

PANAGOS P.; MEUSBURGER K.; LIEDEKERKE, M.; ALEWELL, C.; HIEDERER R.; MONTANARELLA, L.; PANAGOS, P.; MEUSBURGER, K.; LIEDEKERKE, M. Assessing soil erosion in Europe based on data collected through a European network. **Soil Science and Plant Nutrition**. v. 60, p.15-29, 2014.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, V.26. P.217-222, 2005.

PASSO, D. P. **Análise da qualidade de classificadores para identificação de alvos urbanos em imagens de alta resolução espacial - uma aplicação com as imagens do satélite Worldview**. Dissertação (Programa de Pós-Graduação do Instituto de Geociências Aplicadas - Geoprocessamento e Análise Ambiental) – Universidade de Brasília. Brasília. 2013.

PEARSON, K. "Notes on regression and inheritance in the case of two parents," **Proceedings of the Royal Society of London**, v.58, p.240–242, 1895.

PRADO, D. F. C. do. **Medidas de acurácia baseada em objeto: análise metodológica em relação à validação baseada em pixel**. 2016. 112 p. Dissertação (Mestrado em Engenharia Florestal)-Universidade Federal de Lavras, Lavras, 2016.

PRUDENTE, Victor H. R. et al . Compaive assessment beteen per pixel and oject-oriented for mapping land cover and use. **Eng. Agríc.**, Jaboticabal , v. 37, n. 5, p. 1015-1027, 2017.

QUEROZ, T.; BALDIN, T.; MARCHESAN, J.; PEDRALI, L.; SOARES PEREIRA, R.; DE JESUS BATISTA, F.; SOUSA, R. Avaliação do desepemoenho da classificação do uso e cobertura da terra a partir de imagens Landsat 8 e Rapideye na região central do Rio Grande do Sul. **Geociencias**. V.36. p.569-578, 2017.

RASTI, P.; AHMAD, A.; SAMIEI, S.; BELIN, E.; ROUSSEAU, D. Supervised Image Classification by Scattering Transform with Application toweed Detection in Culture Crops of High Density. **Remote Sensing**, v. 11, p.249 -264, 2019.

RESENDE, Marcos Ribeiro; BERNUCCI, Liedi Légi Barianni; QUINTANILHA, José Alberto. Classificação híbrida: pixel a pixel e baseada em objetos para o monitoramento da condição da superfície dos pavimentos rodoviários. **Bol. Ciênc. Geod**, v. 18, n. 3, p. 397-420, 2012 .

RIBEIRO, P. M. R.; SOARES, P. V.; VIEIRA, O. A. C.; Avaliação de métodos de classificação de imagens IKONOS para o mapeamento da cobertura terrestre. In. Anais do XII Simpósio Brasileiro de Sensoriamento Remoto, 12, Goiânia, Brasil, 2005. **Anais...**Goiânia: INPE, 2005, p.4277 – 4283.

RICHARDS, J. A. Thematic mapping from multitemporal image data using the principal components transformation. **Remote Sensing and Environment**, v. 16, n. 1, p. 35-46, 1988.

RICHARDS, J. A.; JIA X. **Remote Sensing Digital Image Analysis**. An Introduction. 4

ROLIM, F.A. **Classificação orientada a objetos em imagens de alta resolução para auxílio ao monitoramento ambiental em uma microbacia hidrográfica** (2003). Dissertação em Engenharia Florestal. Departamento de Ciências Florestais e da Madeira, Setor de Ciências Agrárias. UFPR (Curitiba).

ROSA, R. **Introdução ao sensoriamento remoto**. 7. ed. Uberlândia: EDUFU, 2009.

SAMANIEGO, L.; SCHULZ, K. Supervised Classification of Agricultural Land Cover Using a Modified k-NN Technique (MNN) and Landsat Remote Sensing Imagery. **Remote Sensing**, v. 1, n. 4, p. 875-895, 2009.

SANTOS, M. A. S.; ASSAD, E. D.; GURGEL, A. C.; OMAR, N. Similarity Metrics Enforcement in Seasonal Agriculture Areas Classification. **Remote Sensing**, v. 12, n. 11, p. 1791-1808, 2020.

SILVA, D. C. da.; Evolução da Fotogrametria no Brasil. Revista Brasileira de **Geomática**, v. 3, n. 2, p. 81-96, 2015.

SILVA, L. C. N.; BACANI, V. M. Classificação orientada a objeto (GEOBIA) aplicada à análise das alterações do uso e cobertura da terra da Bacia Hidrográfica do Rio da Prata em Jardim e Bonito - MS. **Geografia**, v. 26. n. 1. p. 05 – 18, 2017.

SOUZA, A. S.; **Processamento digital de fotografias aéreas para análise do uso do solo**. 2005 77f. Dissertação (Mestrado em Agronomia) – Faculdade de Ciências Agrônômicas da UNESP – Campus de Botucatu, Botucatu, São Paulo, 2005.

SOUZA, J. A. C. Acurácia das métricas de validação da classificação de imagens. Dissertação (Programa pós-graduação em Engenharia de Produção) - Universidade Federal de Minas Gerais, Belo Horizonte, Minas Gerais, 2020.

SPIEGEL, M. R. **Estatística**. McGrawhill, 3ªedição, 1993, 70p.

STEINER, D. Time dimension for crop surveys from space. *Photogrammetric Engineering*. **Falls Church**, v.36, n.2, p.187-194. 1970.

STORY, M. and CONGALTON, R.G. Accuracy Assessment: A User's Perspective. **Photogrammetric Engineering and Remote Sensing**, v.52, p.397-399, 1986.

VALAVANIS, KIMON P. *Recent Developments in Unmanned Aircraft Systems*. 1 ed. Springer. 2012. 638 p.

VALERA, C.A.; PISSARRA, T.C.T.; FILHO, M.V.M.; VALLE JÚNIOR, R.F.; OLIVEIRA, C.F.; MOURA, J.P.; SANCHES FERNANDES, L.F.; PACHECO, F.A.L. The Buffer Capacity of Riparian Vegetation to Control Water Quality in Anthropogenic Catchments from a Legally Protected Area: A Critical View over the Brazilian New Forest Code. **Water**, v. 11, n. 3, p.549-565, 2019.

VAPNIK, V. **The Nature of Statistical Learning Theory**. New York: Springer-Verlag, 1995.

WALTER, V. Object-based classification of remote sensing data for change detection. *ISPRS J. Photogramm. Remote Sens.* v.58, p.225–238, 2004.

WILSON, D. R. E MARTINEZ, T. R. Reduction techniques for instancebased learning algorithms. **Machine learning**, v.38, n.3, p.257–286, 2000.

YANG, S. et al. The assessment of the changes of biomass and riparian buffer width in the terminal reservoir under the impact of the South-to-North Water Diversion Project in China. **Ecological Indicators**, 2018.

YOKOO, J. M.; ROSA, M. J. G.; FERNANDO FLORES CARDOSO, F. F.; ULHÔA MAGNABOSCO, U. C.; ALBUQUERQUE, G. L. O uso da estatística Bayesiana no melhoramento genético animal: uma breve Explicação. **Mal. Cdo. Rondon**, v.12, n.4, out./dez., p.247-257, 2013.