



ERIK MARCIANO FERNANDES

**CLASSIFICAÇÃO BASEADA EM OBJETOS PARA
IDENTIFICAÇÃO DA PERMEABILIDADE DA SUPERFÍCIE
USANDO IMAGENS DE ALTÍSSIMA RESOLUÇÃO OBTIDAS
DE VEÍCULOS AÉREOS NÃO-TRIPULADOS**

**LAVRAS – MG
2019**

ERIK MARCIANO FERNANDES

**CLASSIFICAÇÃO BASEADA EM OBJETOS PARA
IDENTIFICAÇÃO DA PERMEABILIDADE DA SUPERFÍCIE
USANDO IMAGENS DE ALTÍSSIMA RESOLUÇÃO OBTIDAS
DE VEÍCULOS AÉREOS NÃO-TRIPULADOS**

Monografia apresentada ao Colegiado do
Curso de Engenharia Florestal, para
obtenção do título de Bacharel em
Engenharia Florestal.

Prof. Dr. Luis Marcelo Tavares de Carvalho

Orientador

**LAVRAS – MG
2019**

ERIK MARCIANO FERNANDES

**CLASSIFICAÇÃO BASEADA EM OBJETOS PARA IDENTIFICAÇÃO DA
PERMEABILIDADE DA SUPERFÍCIE USANDO IMAGENS DE ALTÍSSIMA
RESOLUÇÃO OBTIDAS DE VEÍCULOS AÉREOS NÃO-TRIPULADOS**

**OBJECT-BASED CLASSIFICATION FOR IDENTIFYING SURFACE
PERMEABILITY USING HIGH RESOLUTION IMAGERY OBTAINED FROM
UNMANNED AIRCRAFT SYSTEMS**

Monografia apresentada ao Colegiado do
Curso de Engenharia Florestal, para
obtenção do título de Bacharel em
Engenharia Florestal.

APROVADO em 05/12/2019

Dr. Luis Marcelo Tavares de Carvalho

UFLA

Dr. Luis Marcelo Tavares de Carvalho

Orientador

**LAVRAS – MG
2019**

AGRADECIMENTOS

Sempre tentei fazer o meu melhor. Cada coisa que passei me ajudou a crescer e formar a pessoa que sou hoje. Agradecer é reconhecer que em algum momento você precisou de alguém, porque ninguém é capaz de desbravar o mundo sozinho.

Agradeço à minha família que sempre me apoiou nos meus projetos e nunca poupou esforços para me direcionar aos meus sonhos. Minha mãe Renata e meu pai Ademir construíram a pessoa que sou hoje e são meu porto seguro. Minha irmã Ariane por todo apoio que me ofereceu por todos esses anos. Aos meus amigos de Pouso Alegre que me viram crescer e com quem posso contar a anos. Às novas amizades que descobri em Lavras com quem eu posso confiar sempre que precisar. Aos professores pelo aprendizado, principalmente ao meu orientador, Passarinho. Aos colegas de laboratório pelo suporte a frente das dificuldades e a todas as pessoas que, de alguma, forma, contribuíram para este trabalho.

Cada um de vocês tem uma parte nessa conquista! Obrigado!

RESUMO

O desenvolvimento de metodologias para a avaliação de indicadores de sustentabilidade em universidades tem ganhado muito espaço, de forma que a permeabilidade das superfícies desempenha papel fundamental nessa avaliação. Ferramentas de sensoriamento remoto, somados às medidas de precisão, tem sido utilizadas para auxiliar na aquisição de informações do uso e ocupação do solo. O objetivo do presente trabalho foi comparar os algoritmos *Support Vector Machine* (SVM), Árvore de Decisão e Bayes para a classificação do uso e ocupação do solo da UFLA, por meio de imagens de altíssima resolução espacial obtidas por veículos aéreos não tripulados (VANT), para ser usado como indicador do *GreenMetric*. A área de estudo foi dividida em três classes: impermeável, permeável e árvore. A maior acurácia global e índice Kappa foram apresentados pelo classificador SVM, sendo mais indicado para a classificação de superfícies impermeáveis na área de estudo.

Palavras-chave: VANT. Superfícies Impermeáveis. Algoritmos de classificação.

LISTA DE ILUSTRAÇÕES

Figura 01 – Visão aérea da área de estudo	16
Figura 02 – Padrão geométrico de zigue-zague.....	17
Figura 03 – Sobreposições de deslocamento.....	18
Figura 04 – Intensidade de sobreposição	18
Figura 05 – Cena mostrando a (a) área de estudo e as bandas (b) azul, (c) verde, (d) vermelho, (e) infravermelho e (f) borda do vermelho	20
Figura 06 – Mosaico da sobreposição de imagens.....	21
Figura 07 – Ortomosaico da área de estudo	22
Figura 08 – Recorte da (a) área de estudo e das classificações usando os algoritmos de (b) árvore de decisão, (c) Bayes e (d) SVM.....	28

SUMÁRIO

1 INTRODUÇÃO.....	9
2 REFERENCIAL TEÓRICO	10
2.1 Indicador <i>GreenMetric</i>	10
2.2 Superfícies Impermeáveis.....	11
2.3 Sensoriamento Remoto	12
2.4 Classificação de imagens digitais	15
3 MATERIAIS E MÉTODOS	16
3.1 Descrição da área de estudo	16
3.2 Planejamento do voo.....	17
3.3 Sobrevoo.....	19
3.4 Processamento das imagens.....	20
3.5 Coleta de dados de referência.....	23
3.6 Segmentação e classificação da imagem	23
4 RESULTADOS E DISCUSSÃO	28
4.1 Mapas temáticos das classificações	28
4.2 Matrizes de confusão	29
4.3 Comparação dos três classificadores.....	30
5 CONCLUSÕES	33
REFERÊNCIAS BIBLIOGRÁFICAS	34

1 INTRODUÇÃO

As mudanças globais têm se tornado uma preocupação ao redor do mundo nos últimos anos, pelos impactos que vem causando e podem causar no futuro. Os conceitos de sustentabilidade passaram da ideia de manter apenas a qualidade do ambiente para uma abordagem em três dimensões: social, econômico e ambiental. Assim, indicadores ambientais surgem na perspectiva de avaliar os esforços em manter a sustentabilidade dos ambientes e do planeta. O *GreenMetric* se destaca como uma alternativa de avaliar as ações de sustentabilidade praticadas por *campus* universitários em escala global (LEMOS et al., 2018).

A mensuração de superfícies impermeáveis compõe uma das categorias de indicadores de grande importância a serem avaliados para a aferição da sustentabilidade de uma universidade. Pensando nisto, faz-se necessário gerar a estimativa mais adequada das proporções de áreas permeáveis e impermeáveis (SUWARTHA,; SARI, 2013). A fim de obter índices mais confiáveis, diferentes técnicas podem ser utilizadas, como a mensuração em campo ou técnicas de interpretação de imagens.

Neste sentido, o sensoriamento remoto atua como ferramenta facilitadora na identificação dos elementos de uma paisagem. Com as técnicas de classificação de imagens digitais é possível obter informações acuradas do uso e ocupação do solo de uma região específica com alta precisão. O reconhecimento dos padrões espaciais, localização e geometria de superfícies que permitem ou não a infiltração de água é possível através de diferentes técnicas de sensoriamento remoto, sendo a mais utilizada para este fim a baseada em regiões ou objetos (WENG, 2012).

Diversos classificadores podem ser utilizados para tentar descrever o uso da terra em uma região. A melhor maneira de comparar a eficiência desses classificadores é através dos índices obtidos por matrizes de confusão (QIAN et al., 2015).

O objetivo deste trabalho foi encontrar comparar diferentes metodologias de classificação do uso do solo para a identificação de superfícies permeáveis e impermeáveis a partir do emprego de três algoritmos utilizados como base de classificadores, tendo como fonte imagens digitais de altíssima resolução obtidas com o sobrevoo de VANT.

2 REFERENCIAL TEÓRICO

2.1 Indicador *GreenMetric*

Ao longo das últimas décadas, as listas de *rankings* das universidades ao redor de todo o mundo contaram com uma grande popularização, abrangendo desde os maiores centros de ensino e pesquisa mundiais até pequenas universidades. O controle de criação destas listas passou dos setores governamentais para setores privados e de mídia (UNESCO-CEPES, 2004). Estas classificações lidam com diversos problemas que competem o ambiente das universidades, como pesquisa e prestígio acadêmico, parâmetros educacionais e de interação com a sociedade e, até mesmo, questões ambientais e de sustentabilidade (LUKMAN et al., 2010) Isto posto, os responsáveis pela criação desses *rankings* tendem a dar mais créditos ao desempenho em pesquisa e reputação acadêmica, empregando pouco poder aos índices ambientais (BABOULET; LENZEN, 2010).

Conforme Suwartha e Sari (2013), devido à extensa discussão global sobre mudanças climáticas, perspectivas de mitigação dos impactos e de sustentabilidade desempenham papel cada vez mais ativo na construção dos ordenamentos classificatórios. De acordo com os autores, muitas universidades começaram a tomar atitudes buscando combater as mudanças climáticas, manejando e aperfeiçoando sua sustentabilidade interna. Apesar disso, apenas algumas instituições medem e avaliam seus esforços.

O *GreenMetric* é uma classificação baseada na premissa de que é possível fazer uso de ferramentas de mensuração para verificar as ações praticadas tanto em países desenvolvidos quanto subdesenvolvidos. O *ranking* busca criar ordenamento do comportamento sustentável das instituições, usando um sistema online e de acesso livre onde as universidades podem mostrar seus esforços. Portanto, é uma avaliação tanto interna, com coleta de dados, metodologia e resultados; quanto externa (GRINDSTED, 2011).

Com o último resultado do *GreenMetric* em 2019, a Universidade Federal de Lavras se consagrou na 29ª posição no ranking global e segundo na América Latina, marcando presença na lista das universidades mais sustentáveis do mundo pelo oitavo ano consecutivo (UFLA, 2019).

A obtenção da avaliação final passa por diversos indicadores, agrupados em algumas categorias. Um desses indicadores, incluso na categoria denominada “Água” concerne à

retenção de água, baseado no cômputo em porcentagem de superfícies impermeáveis em relação à área total do *campus* (SUWARTHA E SARI, 2013).

2.2 Superfícies Impermeáveis

Superfície impermeável é toda aquela onde a água não pode se infiltrar no solo por algum tipo de intervenção antrópica que altere suas características. Territórios ocupados por estradas, telhados, pátios, estacionamentos (entre outros) possuem características que impedem a passagem de água para o solo. Com os passar dos anos e com o grande crescimento demográfico, os índices de superfícies impermeáveis surgiram como alternativa para ajudar a mensurar o grau de modificação antropomórfica decorrente da crescente urbanização, além de se tornar uma importante ferramenta que auxilia na avaliação da qualidade ambiental, tais como modelos hidrológicos e de capacidade de recarga do solo (ARNOLD; GIBBONS, 1996).

A observação da superfície da Terra com o uso de satélite permite mapear áreas de ocupação urbana e monitorar suas características estruturais de expansão, de forma que provê informações constantes do desenvolvimento antrópico. A confecção de mapas de uso e ocupação do solo derivados de imagens de satélite são capazes de apresentar os padrões singulares espaciais de cada ambiente, tanto aqueles com interferência humana ou não, tornando-se uma ferramenta fundamental para os estudos da composição e morfologia dos componentes urbanos (TURNER, 1989).

Segundo Voorde et al. (2011), historicamente as análises de superfícies impermeáveis tem suas informações geradas, na maior parte, por imagens de baixa ou média resolução, como as imagens *Landsat*, proporcionando uma gama de informações para o planejamento urbano estratégico. Entretanto, de acordo com Jensen e Cowen (1999), este tipo de imagem é considerada bem rudimentar para captar a heterogeneidade das cidades. Lu e Weng (2009) reafirmam a proposição levando em consideração a complexidade dos materiais das paisagens urbanas.

O uso de imagens de alta resolução espacial vem ganhado espaço nas estimativas de superfícies impermeáveis em virtude da crescente inovação tecnológica de sensores e ferramentas de processamento (LU; WENG, 2009). Veículos aéreos não tripulados permitem a captura de imagens de alta resolução para diversos usos.

Tokarczyk et al. (2015) verificaram o potencial de imagens obtidas com drone para a observação de alta qualidade das superfícies impermeáveis para a geração de modelos de escoamento de água, obtendo resultados comparáveis e superiores aos obtidos com imagens aéreas tradicionais.

2.3 Sensoriamento Remoto

Para a construção do conceito do que é sensoriamento remoto é necessário estabelecer alguns preceitos. O primeiro preceito consiste na exigência em não haver matéria no espaço entre o sensor e o objeto. O segundo preceito é baseado na consequência, no qual a informação do objeto pode ser transportada no espaço vazio. O último dos três preceitos baseia-se na existência de um elo de comunicação entre o objeto e o sensor, a energia eletromagnética, única forma de energia conhecida pelo homem capaz de se transportar pelo espaço (MENESES; ALMEIDA, 2012).

Entender o que é radiação eletromagnética é compreender a dualidade de seu comportamento. Isto quer dizer que a REM é, ao mesmo tempo onda e energia. Para o sensoriamento remoto, a ciência de tal dualidade é fator indispensável para o entendimento de tudo o que se é percebido na imagem com relação às características dos objetos da superfície. Com o propósito de estabelecer definições mais precisas para o dualismo na natureza da radiação eletromagnética foram formulados dois modelos, ondulatório e corpuscular, denominados para as suas características de onda e energia, respectivamente (FONSECA, 2000).

Segundo Menezes e Almeida (2012), de acordo com o modelo ondulatório, uma partícula carregada gera, ao seu redor, um campo elétrico e o movimento de tal partícula no espaço gera um campo magnético. Estes campos gerados pela movimentação da partícula carregada eletricamente possuem mesma amplitude e se modelam de acordo com as oscilações da partícula que, quando acelerada, dá origem a perturbações entre os campos elétrico e magnético que, por sua vez, são chamados de ondas eletromagnéticas. Para o sensoriamento remoto o comprimento de uma onda é a sua característica mais importante, uma vez que as medidas da interação da radiação eletromagnética com os elementos da superfície terrestre são explicadas levando em consideração o tamanho da onda e o tamanho dos objetos. Esta interação com os objetos é chamada de interação macroscópica.

Ainda, segundo Menezes e Almeida (2012), de acordo com o modelo corpuscular a radiação eletromagnética manifesta propriedades de transmissão de energia de um corpo para outro, em pequenos pulsos e em quantidade fixa, na forma de uma estrutura denominada fóton. Os fótons são corpúsculos puramente energéticos sem matéria, mas que se manifesta somente em contato com ela. A interação de troca de energia entre as ondas e a superfície dos materiais é chamada de interação microscópica, posto que a troca de energia acontece em nível molecular.

Devido a dualidade das ondas eletromagnéticas e de sua indissociabilidade, o autor ainda afirma que “as imagens dos objetos sempre são, em maior ou menor proporção, as respostas em função do tamanho da onda e da intensidade de sua energia.”. Portanto, de acordo com Menezes e Almeida (2012), o modelo ondulatório da REM está relacionado com as propriedades texturais dos objetos, em contrapartida ao modelo corpuscular que está relacionado à composição dos objetos.

As regiões da radiação eletromagnética conhecida pelo homem são denominadas regiões espectrais eletromagnéticas ou, de forma mais sucinta, espectro eletromagnético. Este espectro pode ser dividido em intervalos agrupados de acordo com suas características ou com as características dos métodos de definição, com nomenclaturas baseadas nas suas funções. O grupo mais conhecido da radiação eletromagnética é o espectro da luz visível da radiação solar, que abrange a faixa de radiação que o olho humano é capaz de captar (MENESES; ALMEIDA, 2012).

Partindo do princípio que que cada comprimento de onda interage de forma individual e com diferentes intensidades com determinado objeto da superfície terrestre, o comprimento de onda é o principal parâmetro do qual um sensor fará uso para captar informações. Uma imagem não pode ser definida por apenas um único comprimento de onda, mas sim por pequenos intervalos. Estes intervalos são chamados de bandas. As bandas mais utilizadas no sensoriamento remoto são as bandas vermelha, verde e azul (espectro visível) e as bandas infravermelho próximo e médio, do espectro da luz infravermelha (GONZALEZ; WOODS, 2010).

O sensor mede os valores de radiância, originários da energia de irradiação incidente de um objeto da superfície terrestre, para constituir as imagens. “Radiância é o fluxo de energia sendo transmitido em um ponto específico em uma direção particular” (MOGO, 2011). A radiância é caracterizada por ser uma grandeza radiométrica que descreve a distribuição da

radiação no espaço. Ela representa o brilho de um objeto da superfície e independe da distância entre o alvo e o sensor, desde que o alvo seja contínuo (MORAES, 2002).

Já Reflectância de uma superfície particular é complexa, sendo afetada pelo número e tipo de material presente no objeto, a proporção que esses materiais ocupam em sua composição, a granulometria de cada material e a sua conformação molecular. Isto é, a reflectância é uma propriedade típica do objeto, não podendo ser medida com equipamentos, mas por artifícios matemáticos que se baseiam em estabelecer uma relação entre radiância do objeto e a radiância de uma estrutura padrão (que apresenta valores máximos de reflectância) conhecida como placa Lambertiana. A reflectância de um mesmo objeto pode ser diferente para cada tipo de radiação que o atinge (CLARK; ROUSH, 1984).

“Quando o sensor detecta e mede a radiação que deixa a superfície dos objetos, o sensor está fazendo uma medição radiométrica” (MENESES; ALMEIDA, 2012). A imagem gerada é constituída das informações de radiância dos objetos da superfície captadas pelo sensor e pelos valores de reflectância daqueles objetos para certo tipo de radiação.

A resolução da imagem oferecida pelo sensor é diretamente influenciada pela forma de detecção da informação dos objetos da superfície (GONZALEZ; WOODS, 2004). Existem quatro tipos de resoluções que uma imagem é capaz de apresentar, sendo elas:

- 1) **resolução espacial:** capacidade de cada sensor em detectar a superfície da terra, resultando no tamanho do pixel. Esta resolução determina o tamanho do menor objeto que pode ser identificado em uma imagem.
- 2) **resolução espectral:** relativa às bandas espectrais que o sensor é capaz de captar simultaneamente. Um sensor com melhor resolução espectral possui maior número de bandas distribuídas em diferentes regiões do espectro.
- 3) **resolução radiométrica:** caracterizada pela medida de intensidade da radiância em cada pixel da imagem. Maior será a resolução radiométrica quanto maior for a capacidade do sensor em perceber as diferenças nos níveis de radiância. Faz o diagnóstico da assinatura espectral dos objetos.
- 4) **resolução temporal:** trata-se da periodicidade de visitar de um sensor à determinada área, sendo capaz de capturar imagens periódicas.

Estas quatro formas de resolução da imagem atuam em conjunto, de forma interativa, para explicar os objetos da superfície terrestre (MENESES; ALMEIDA, 2012).

2.4 Classificação de imagens digitais

Técnicas de classificação de imagens digitais em parceria com a interpretação dessas imagens podem ser utilizadas para uma série de objetivos nas mais diversas áreas do conhecimento, como: planejamento de infraestrutura de estradas, identificação de alterações nos níveis de água em reservatórios naturais e artificiais, monitoramento em mudanças do uso do solo, análise de ataque de doenças em plantas, estimativas de ocupação urbana, além de muitos outros. O processo usado para identificar os objetos em imagens digitais é chamado de interpretação de imagens. Para tal, faz-se uso de suas características espectrais, geométricas, como tamanho e forma, de textura, sombras, entre outros fatores (AVERY; BERLIN, 1992 *apud* ANDRADE, 2003).

Não existe metodologia definitiva para a classificação de imagens digitais, de acordo com Barbosa et al. (2019), posto que cada imagem possui suas características singulares. Suas propriedades variam pela escala, iluminação, ângulo de visão do sensor, entre outros. Os autores abordam duas grandes linhas para a abordagem na classificação de imagens digitais: a *pixel-a-pixel* e a orientada a objetos. A segunda sendo dividida em três processos fundamentais, sendo o primeiro deles a segmentação, o segundo a classificação e, por fim, as medidas de acurácia.

A abordagem baseada em pixel vem se tornando cada vez menos eficiente na classificação de imagens em função do avanço tecnológico em sensores que capturam imagens em alta resolução e registram cenas com heterogeneidade elevada. Nos últimos anos, a abordagem baseada em objetos vem ganhando cada vez mais espaço para a obtenção classificações do uso do solo (KAVZOGLU et al., 2016). Este tipo de classificação tem como vantagem a criação de objetos via segmentação na imagem, a partir de características dos *pixels* vizinhos e de suas similaridades espectrais, alcançando melhores resultados em imagens de alta resolução espacial (TZOTSOS et al., 2011; KIM et al., 2010).

Em estudo realizado por SCHNEIDER e STEINWENDNER (1999), foi realizada a segmentação e classificação de imagens de satélite. O objetivo do trabalho foi gerar mapas com classes de uso da terra, onde obtiveram bons resultados. Para os autores, classificações mais acuradas tem relação direta com os parâmetros usados na segmentação, como fatores de forma e textura.

3 MATERIAIS E MÉTODOS

3.1 Descrição da área de estudo

Localizado no município de Lavras, em Minas Gerais, o campus da Universidade Federal de Lavras – UFLA fica a 230 Km de Belo Horizonte e 420 Km de São Paulo, nas coordenadas $21^{\circ}13'37''S$ e $44^{\circ}58'38''O$, a 920 metros de altitude, com acesso por rodovias asfaltadas e de boa qualidade. A universidade encontra-se na bacia hidrográfica do Rio Grande.

“O campus universitário possui 600 hectares, sendo mais de 25 hectares de área construída. A estrutura física encontra-se em plena expansão com a construção de novos prédios para abrigar salas de aula, laboratórios, gabinetes de professores, além de Parque Tecnológico, Centro de Eventos e Casa de Cultura, Centro Esportivo de Alto Rendimento” (UFLA, 2019).

A área a ser trabalhada está destacada na Figura 01. Sua extensão compreende a região entre o canteiro da avenida central e a avenida norte do *campus*, tendo início no estacionamento adjacente ao centro de convivência, passando por departamentos e pavilhões de aulas e tendo fim próximo aos departamentos de Ciências Florestais e Agricultura e às obras do novo centro de convenções.

Figura 01 – Visão aérea da área de estudo.



Fonte: Google Earth (2019).


3.2 Planejamento do voo

O equipamento utilizado para a captura das imagens foi o drone DJI Matrice 100. O VANT (veículo aéreo não tripulado) possui plataforma de voo estável e flexível, com *design* customizável que o torna capaz de executar uma gama de aplicações em diversas áreas, desde uso recreativo como empresarial ou até de pesquisa. A sua estrutura expansiva torna possível a adição de componentes e dispositivos com o objetivo de obter melhora funcional e resultados. Possui compartimento para a instalação das baterias, permitindo maior autonomia de voo. O sensor utilizado para a captura das imagens foi o RedEdge MX, da MicaSense, que é capaz de registrar as bandas azul, verde e vermelho do espectro do visível e as bandas infravermelho e borda do vermelho, em altíssima resolução espacial.

O planejamento de voo foi feito através da plataforma *Pix4D Capture*, que é um aplicativo para dispositivos móveis que possui sincronia com os sistemas do VANT e da câmera utilizada. O cadastro de ambos no *software* é o passo inicial para a programação do voo.

Após cadastradas as informações necessárias, foi preciso configurar o tipo de missão de voo do dispositivo. A missão se refere ao tipo de deslocamento que o equipamento fará para a captura das imagens. Neste caso, a escolhida para ser executada pelo drone foi *Grid Mission*, ou seja, missão em grade. Neste tipo de trajetória, o veículo encontra o ponto inicial de coleta e se desloca em linha reta capturando as imagens até alcançar o limite da área de estudo. Quando atinge a borda do polígono que define a área, o veículo se desloca em uma distância fixa até a próxima linha, paralela à primeira. Posicionado, o drone segue seu deslocamento nesta linha realizando a captura das imagens até alcançar a borda da área, deslocando-se verticalmente para a próxima linha. O deslocamento do VANT neste tipo de missão segue o padrão geométrico de zigue-zague, como mostra a Figura 02.

Figura 02 – Padrão geométrico de zigue-zague



Fonte: Do autor (2019)

Escolhida a missão, o próximo passo foi a escolha da intensidade de sobreposição das imagens, ou *Overlap*, no momento da captura. Existem dois tipos de sobreposição, a frontal e a lateral, como mostra a Figura 03. A sobreposição frontal (*frontal overlap*) acontece entre uma imagem e a próxima ou as próximas em sua linha de captura, dependendo da intensidade. A sobreposição lateral (*side overlap*) acontece entre as linhas de deslocamento. A intensidade determina da sobreposição define a porção de uma imagem que ficará sobreposta à outra adjacente, conforme a Figura 04. Maiores valores de sobreposição implicam em mosaico de imagens com menos falhas, mas aumentam o tempo de voo necessário para a captura da área total.

Figura 03 – Sobreposições de deslocamento.

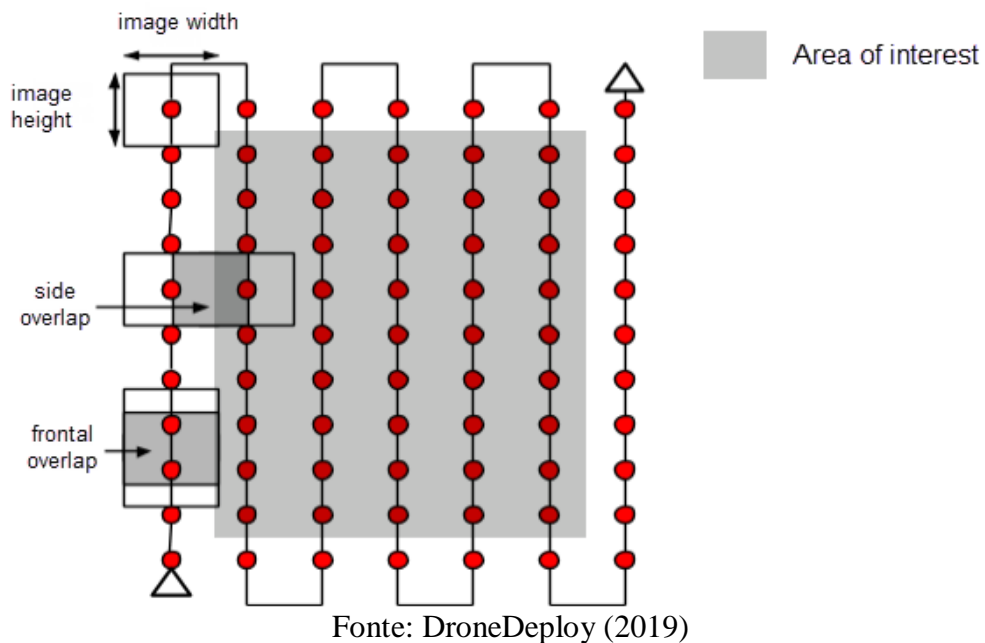
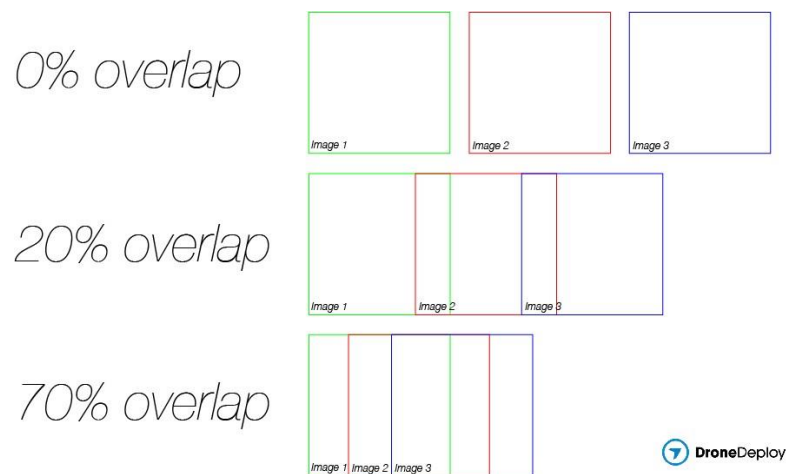


Figura 04 – Intensidade de sobreposição.



Fonte: DroneDeploy (2019)

Para este estudo, foi escolhida uma intensidade de sobreposição de 90%. Esta escolha se refere ao *overlap* frontal. O *overlap* lateral é modificado alterando a distância entre as linhas de deslocamento do drone, para que alcance 90%.

A altura de voo escolhida foi de 120 metros para que não houvesse problemas de colisão com objetos da paisagem. Além disso, maior altura de voo permite captura de imagem com maiores dimensões e maior tamanho de pixel. Também foi necessário estabelecer a velocidade de avanço do drone enquanto se desloca pela área. Foi decidido pela velocidade rápida de deslocamento. A máxima velocidade que o drone pode atingir para cada planejamento varia em função da altitude de voo e da sobreposição selecionada.

3.3 Sobrevoos

O sobrevoos sobre a área foi realizado no dia 23 de outubro de 2019. O horário escolhido para a realização do voo foi às 11 horas da manhã, buscando a menor quantidade de sombra possível causada pelo sol nos objetos da superfície.

O ponto de lançamento do drone, ou *homepoint*, foi decidido com base em diversos fatores. A área escolhida para o lançamento possui superfície plana, reduzindo os problemas causados no lançamento e pouso do veículo aéreo. Encontra-se distante de redes elétricas e de comunicação, para que não houvesse qualquer tipo de interferência eletromagnética que atrapalhasse a comunicação com o drone enquanto faz o sobrevoos. Além disso, foi selecionada uma área com cobertura de terra, para que o impacto do equipamento com o solo no momento do pouso fosse reduzido.

Já em campo, o equipamento foi devidamente montado e antes de iniciar o voo, sendo realizado o calibramento do drone para que a sua posição geográfica fosse identificada. Similarmente, a câmera também teve que ser calibrada para sua identificação. Não somente isso, foram tiradas fotos do painel de reflectância compatível com a câmera antes do voo para posterior correção no processamento das imagens.


No momento do lançamento do drone, as condições de luz e vento foram favoráveis. O céu estava nublado com uma intensidade luminosa moderada que não gerava sombra pronunciada nos objetos da paisagem. Alguns minutos após o lançamento, com o drone já em operação, a intensidade luminosa aumentou causando o aparecimento de sombras mais

acentuadas, por isso, ao final do processo, foi necessário realizar mais fotos do painel de calibração, para que a correção pudesse ser feita.

O tempo previsto de voo era de, aproximadamente, vinte e três minutos com o uso de duas baterias. Contudo, ao final do processo o tempo total gasto com o sobrevoo foi de trinta e um minutos para cobrir toda a área com a utilização de três baterias. Desta maneira, foi preciso pausar a missão, trazer o drone de volta ao ponto de lançamento para a troca das baterias com carga abaixo do limite de segurança por uma completamente carregada e continuar a missão.

Com o sobrevoo, foi possível capturar 702 imagens, cada uma contendo as 5 bandas que a câmera é capaz de registrar. Este conjunto de imagens deram origem ao ortomosaico que representa a área. A Figura 05 mostra a o resultado da captura da imagem em cada uma das bandas em comparação a cena original.

Figura 05 – Cena mostrando a (a) área de estudo e as bandas (b) azul, (c) verde, (d) vermelho, (e) infravermelho e (f) borda do vermelho.



Fonte: Do Autor (2019)

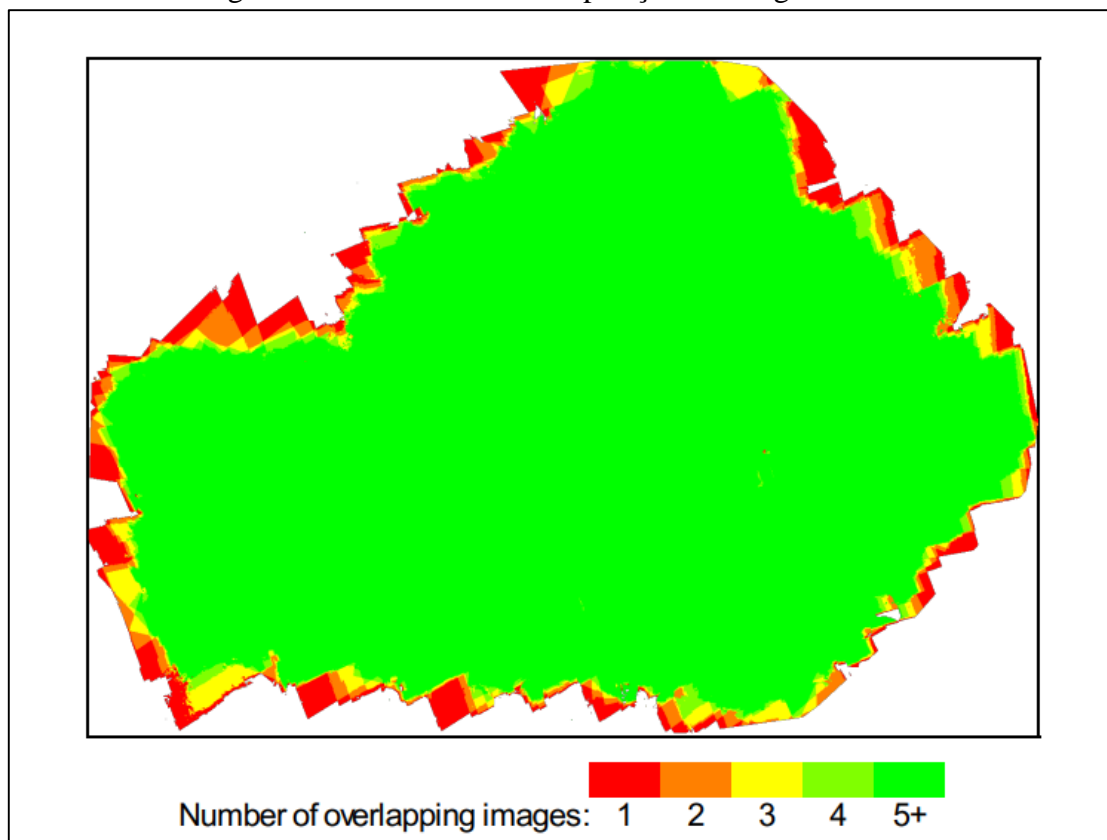
3.4 Processamento das imagens

Cada uma das imagens capturadas pela câmera passou por um processo de transição para uma ortofoto, que já é a representação ortográfica daquele clique fotográfico. Além disso, todas as ortofotos foram alocadas e sobrepostas de forma a representar cartograficamente a superfície da área, gerando o ortomosaico, que permite a visualização e diferenciação dos objetos com riqueza de detalhes e grande precisão.

A ferramenta utilizada para o processamento das imagens foi o Pix4D Mapper. As 702 imagens obtidas no voo foram adicionadas ao projeto para a geração de um ortomosaico com a reflectância de cada banda capturada pela câmera. Ao adicionar as imagens, o software é capaz de realizar uma auto calibração da câmera com o uso de um algoritmo que leva em consideração os pixels da imagem registrada para estimar a melhor calibração (VISOCKIENE et al., 2014). Apesar disso, foi necessário a inserção manual de parâmetros de cada banda descritos no painel de reflectância para a correção da intensidade luminosa (PIX4D, 2019).

Durante o processamento foi observado que 103 do total de imagens coletadas não estavam aptas para integrar a composição do ortomosaico. O motivo de tal impedimento se deu pelo fato de essas imagens não conterem informações da banda do limite do vermelho, impedindo assim a geração do ortomosaico. À vista disso, fez-se necessário a remoção manual dessas imagens embutidas de erro da base de dados para dar início ao procedimento. Ao final da operação, foi gerado um relatório da qualidade do processamento. A Figura 06 mostra a relação de sobreposição das imagens.

Figura 06 – Mosaico da sobreposição de imagens.




Fonte: Do Autor (2019)

A Figura 06 demonstra o número de imagens sobrepostas computadas para cada pixel da imagem. A região em verde indica que pelo menos 4 imagens foram sobrepostas para os valores de pixel de determinada região, enquanto as áreas em vermelho, laranja e amarela que se encontram na periferia apontam baixa sobreposição.

O ortomosaico gerado está representado na Figura 07, apresentando resolução espacial de 7,8 centímetros (altíssima resolução espacial). A região destacada em amarelo é a área obtida com sobrevoo do drone. Nota-se que de acordo com o mosaico da qualidade de processamento, a área de interesse está totalmente contida em na seção com boa sobreposição de imagens. Não obstante, a região destacada em vermelho e ampliada demonstra a existência de problemas nas bordas do ortomosaico, onde houve pouca sobreposição das imagens. Sendo assim, toda a região da borda da imagem final foi descartada.

Figura 07 – Ortomosaico da área de estudo.



Fonte: Do Autor (2019)

3.5 Coleta de dados de referência

Na análise dos dados, Congalton (1991) descreve o uso de critérios utilizados para avaliar a qualidade da classificação do uso da terra e comparar os resultados entre diferentes métodos. De acordo com o autor, o uso de matrizes de erro para calcular os erros de inclusão e omissão apresentados pela classificação é o passo inicial para diversas análises estatísticas, como o cálculo da acurácia global. Portanto, para a validação da classificação é necessário a coleta de dados de referência.

Neste projeto, foram registrados 85 pontos de uso e ocupação do solo. O método empregado para a coleta dos dados de referências baseou-se na visita de regiões distribuídas de forma aleatória em toda a extensão da área de estudo, identificando o uso do solo existente para aquele local. Foram registradas amostras dos usos: asfalto, concreto e telhado como impermeáveis; grama, solo exposto e blocos como permeáveis e árvore. As coordenadas geográficas dos pontos de coleta foram catalogadas com o uso de GPS e, posteriormente, tabulados identificando os usos permeáveis e impermeáveis.

3.6 Segmentação e classificação da imagem

3.6.1 Segmentação

A segmentação e a classificação das imagens foram realizadas utilizando-se do *software* eCognition® que realiza análises de imagens baseadas em objetos. O ortomosaico das cinco bandas foi adicionado ao novo projeto. Para a melhor visualização da área e diferenciação dos objetos foi utilizada a cor verdadeira da imagem, contudo falsas cores foram utilizadas em alguns momentos para ajudar na identificação de objetos segmentados.

O primeiro passo na construção da árvore de processos foi decidir a forma como a segmentação seria feita. No processamento da imagem da área, foi decidido por uma segmentação em dois níveis, sendo o primeiro deles uma *multiresolution segmentation*, ou segmentação multiresolução. Nesta etapa do processamento, existem alguns fatores que afetam a forma como os pixels serão agrupados nos segmentos: o parâmetro de escala e os critérios de homogeneidade *shape/colour* e *compactness/smoothness*.

O parâmetro de escala é a medida da máxima heterogeneidade que dos objetos da imagem podem possuir quando são unidos, sendo que quanto maior o seu valor maior serão os objetos criados na segmentação. O critério *colour* define uma porcentagem em que os valores espectrais das camadas da imagem contribuem para a homogeneidade, sendo inversamente proporcional ao *shape*, que prioriza a homogeneidade da forma dos objetos. Da mesma forma dos critérios anteriores, *smoothness* e *compactness* são relações percentuais e inversamente proporcionais, sendo que o primeiro prioriza a suavidade das bordas dos objetos que serão criados, enquanto o segundo dá mais peso a compacidade desses objetos (TRIMBLE, 2011; TROYA-GALVIS et al, 2016).

O segundo nível da segmentação consistiu na segmentação por diferença espectral, que funde objetos vizinhos que possuam valores de média espectral (*spectral difference*) abaixo do limite estabelecido, ou seja com uma dada máxima diferença espectral. Este tipo de segmentação necessita de ser executado em segundo nível, ou seja, precisa que alguma segmentação utilizando outro algoritmo já tenha sido utilizada (TRIMBLE, 2011).

O método utilizado para a escolha dos parâmetros e critérios de ambos os níveis de segmentação foi de tentativa e erro. O objetivo destes testes foi alcançar uma segmentação de maior qualidade, a partir de uma seção da imagem, com objetos possuindo bordas definidas e de tamanho que permitisse a diferenciação dos componentes da cena.

No total, oitenta e cinco testes foram realizados. Destes, seis apresentaram resultados mais semelhantes ao esperado. Todos os seis processamentos foram refeitos e comparados para a escolha da melhor combinação de critérios a ser utilizada na segmentação da imagem total. Por fim, os parâmetros decididos foram: *scale* – 200, *shape* – 0,1, *compactness* – 0,1 *spectral difference* – 1000.

A segmentação pôde, então, ser executada abrangendo toda a extensão da imagem. Após o primeiro nível de análise foram gerados 27.540 polígonos, todavia o total de objetos reduziu para 22.598 após junções realizadas pela segmentação em segundo nível.

3.6.2 Classificação

3.6.2.1 Determinação das classes e seleção de amostras

Foi decidido pelo uso de três classes para a identificação de superfícies impermeáveis neste projeto. A primeira delas determinada “Impermeável” abrange vários tipos de usos de solo antrópicos, como asfalto, telhado, concreto, outras estruturas de composição urbana, como caixas d’água e carros. A segunda classe, “Permeável”, contempla os usos de grama, solo exposto e agricultura, além das superfícies semipermeáveis (blocos). Por fim, a terceira classe decidida foi “Árvore”. A decisão para a separação deste tipo de objetos em uma classe separada vem da incerteza do uso do solo presente abaixo da copa desses indivíduos, podendo ter usos permeáveis ou impermeáveis.

O número de amostras que devem ser coletadas em uma análise baseada em objetos é, de modo geral, baseado na experiência do pesquisador, embora existam estimadores capazes de oferecer esta resposta (FOODY, 2006). Neste estudo, foram coletadas 300 amostras aleatórias, sendo 100 para cada uma das classes. As amostras foram escolhidas no primeiro nível de segmentação para garantir que os objetos amostrados tivessem apenas um dos usos do solo, evitando posteriores erros de classificação (QIAN et al., 2015). As amostras foram coletadas aleatoriamente por toda a área, obtendo quantidades similares de *pixels* em cada uma das classes.

As características dos objetos escolhidas para treinar os classificadores foram as descritas na Tabela 01.

Tabela 01 – Descrição das características escolhidas para a classificação das imagens.

Fator	Descrição
Média	Valor da média de determinada banda para o objeto da imagem
Desvio padrão	Valor do desvio padrão de determinada banda para o objeto da imagem
Brilho	Valor médio de todas as bandas
Textura (Haralick)	Valores espectrais, de forma e contraste de sub objetos de cada objeto

Fonte: Do Autor

3.6.2.2 Classificadores

Os classificadores escolhidos para a análise foram: *Support Vector Machine* (SVM), Árvore de Decisão e Bayes. Uma das etapas mais importantes para a utilização desses métodos está na definição de seus parâmetros, que são diferentes para diferentes classificadores. Para

cada um deles foi testado uma série de combinações desses parâmetros, buscando alcançar a melhor classificação possível. Para a comparação entre os classificadores foi usada a classificação baseada na escolha de parâmetro otimizada para os classificadores.

SVM é um algoritmo proposto pela primeira vez por Vapnik e Chervonenkis (1971). Com o uso desse algoritmo “um hiperplano é construído primeiro com base na lacuna máxima dos conjuntos de amostras de treinamento fornecidos e, em seguida, classifica os objetos segmentados em uma das classes de cobertura do solo identificadas” (QIAN et al., 2015). Foi usada a função RBF (*radial basis function*) que se provou superior de acordo com vários estudos (DURO et al, 2012).

O algoritmo da Árvore de Decisão cria uma árvore a partir do particionamento recursivo binário que divide os conjunto de dados das amostras em subconjuntos a partir dos seus valores das características dos objetos. Então, o processo é repetido para cada conjunto criado até gerar a classificação final (QIAN et al., 2015). O principal parâmetro deste classificador é a máxima profundidade da árvore, que determina a complexidade do modelo. O valor padrão para este campo é 3, contudo neste trabalho o valor escolhido foi 10.

O método que se originou do algoritmo de Bayes, chamado de *normal* Bayes (NB), é um classificador probabilístico vindo da estatística Bayesiana. Este classificador assume que as características vetoriais de cada classe são distribuídas de forma normal, porém não de forma independente. O algoritmo usa as amostras de treinamento para estimar matrizes de covariância para cada classe com base das características dos objetos (QIAN et al., 2015). Em comparação aos demais, o classificador não permite ajuste dos parâmetros.

3.6.2.3 Medidas de Acurácia

Com o objetivo de avaliar os esforços dos classificadores dos dados, as medidas de acurácia são comumente usadas em análises de classificação do uso do solo (ERENER, 2013). Neste trabalho foi conduzida a comparação das acurácias resultantes dos três classificadores utilizados. Os resultados foram obtidos através da confecção das matrizes confusão de cada mapa gerado pela classificação, usando como dados de referência os pontos coletados em campo com GPS.

A conferência entre os dados de referência e as informações de cada uma das classificações foi realizada com sistema de informações geográficas ArcGis. As matrizes foram calculadas em forma de tabela e, a partir delas, os valores de acurácia global e índice Kappa para cada um dos classificadores puderam ser gerados e usados para a comparação entre os métodos.

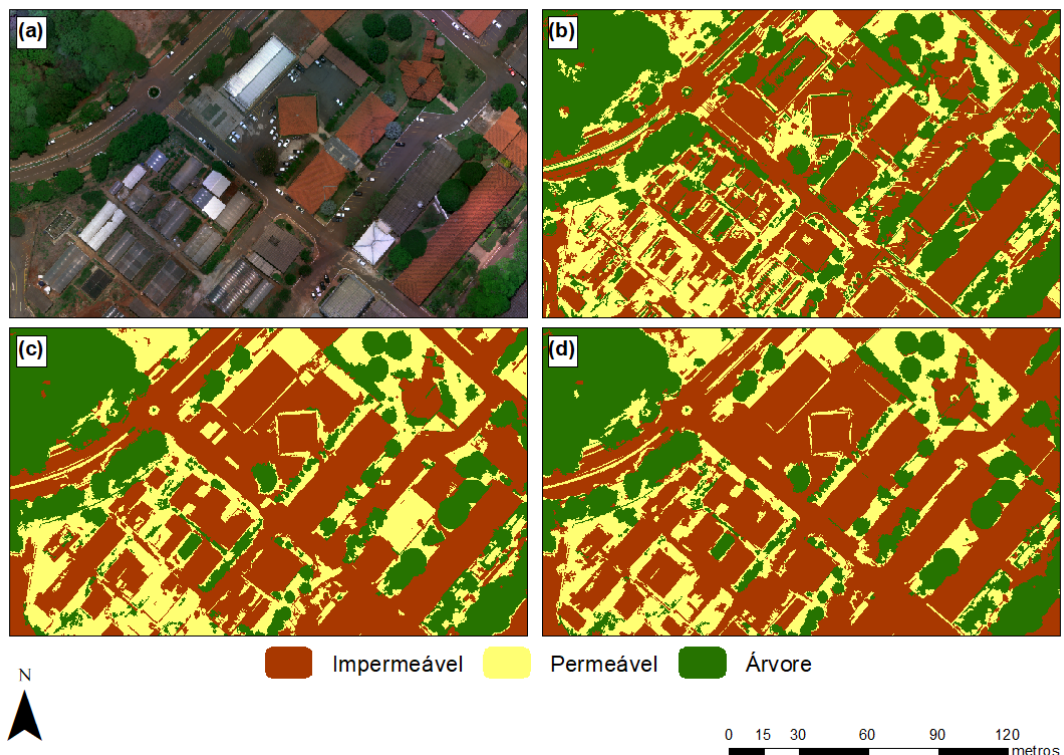
4 RESULTADOS E DISCUSSÃO

4.1 Mapas temáticos das classificações

Os resultados obtidos pelo processamento no programa eCognition® puderam ser convertidos em vetores preservando a diferenciação entre as classes criadas. Para cada uma dos algoritmos testados, foi gerada um perfil de uso e ocupação do solo para a área de estudo, que foram levadas para o sistema de informações geográficas ArcGis. Com isso, mapas temáticos puderam ser criados para cada uma das metodologias aplicadas.

Foram gerados três mapas temáticos baseados nos resultados dos três diferentes algoritmos testados neste trabalho. A Figura 08 representam, os resultados da classificação realizada pelos classificadores Árvore de Decisão, *Support Vector Machine* e Bayes.

Figura 08 – Recorte da (a) área de estudo e das classificações usando os algoritmos de (b) árvore de decisão, (c) Bayes e (d) SVM.



Fonte: Do Autor (2019).

4.2 Matrizes de confusão

Os dados de referência foram usados para criar as matrizes de confusão. A Tabela 02 expressa os erros de inclusão e omissão de cada uma das classes para os classificadores aplicados neste trabalho.

Tabela 02 – Matrizes confusão dos classificadores.

Classificador	Classes			Total	Erro Inclusão (%)	
	Permeável	Impermeável	Árvore			
Árvore de Decisão	Permeável	17	4	0	21	19,05
	Impermeável	10	29	0	39	25,64
	Árvore	1	2	22	25	12,00
	Total	28	35	22	85	
	Erro Omissão (%)	39,29	17,14	0,00		
SVM	Permeável	23	2	0	25	8,00
	Impermeável	5	33	1	39	15,38
	Árvore	0	0	21	21	0,00
	Total	28	35	22	85	
	Erro Omissão (%)	17,86	5,71	4,55		
Bayes	Permeável	23	4	1	28	17,86
	Impermeável	3	30	0	33	9,09
	Árvore	2	1	21	24	12,50
	Total	28	35	22	85	
	Erro Omissão (%)	17,86	14,29	4,55		

Fonte: Do Autor (2019).

Os resultados apresentados pela matriz confusão mostram que o algoritmo SVM demonstrou os menores valores de erro de inclusão e erro de omissão entre os três classificadores. Para a classe Permeável, o classificador obteve erro de inclusão de 8%, ou seja, menos de um décimo dos objetos foram classificados erroneamente como parte desta classe. Ainda, a mesma classe apresentou erro de omissão elevado, concluindo que muitos objetos que deveriam pertencer a esta classe não foram atribuídos a ela. Apesar do alto valor de erro de omissão para a classe Permeável, comparando-o os demais classificadores, é possível perceber que o valor elevado esteve presente em todos os casos.

A classe Impermeável mostrou o maior erro de inclusão no SVM e o segundo maior da classe entre os classificadores, totalizando 15,38%. Contudo, apresentou erro de omissão baixo

entre as classes no SVM e o menor erro de omissão da classe Impermeável entre os classificadores. Todos os objetos avaliados pelos dados de referência da classe Árvore foram classificados corretamente pelo algoritmo, conferindo nenhum erro de inclusão, não obstante o erro de omissão da classe foi o menor para este algoritmo.

Apesar de não ter os melhores erros, o classificador *normal* Bayes demonstrou melhores resultados quando comparado à Árvore de Decisão. Os erros de inclusão apresentados por Bayes foram menores em todas as classes, com exceção da classe Árvore, entretanto a diferença entre os valores desta última é pequeno e considerado pouco significativo. A mesma relação acontece ao se analisar os erros de omissão, uma vez que apenas a classe Árvore exibe valores de erro maiores que os encontrados pelo método da Árvore de Decisão. Além de tudo, verifica-se que os erros de omissão são semelhantes ao classificador SVM, a única ressalva a isto está na classe Impermeável.

A Árvore de Decisão teve os maiores valores de erro entre os três classificadores estudados. Em questão de inclusão, os erros encontrados foram elevados para todas as classes, sendo maiores que os valores para as mesmas classes nos demais classificadores em quase todos os casos. Os erros de omissão do classificador também foram os mais elevados para as classes Permeável e Impermeável, todavia a classe Árvore mostrou não apresentar erro nesta categoria, indicando que o classificador conseguiu, apesar dos altos erros, incluir os objetos reais de árvore dentro desta classe.

4.3 Comparação dos três classificadores

A avaliação dos erros de inclusão e omissão ajuda a entender o comportamento dos classificadores, mas não traz confiabilidade suficiente para sozinha permitir a escolha de qual das metodologias utilizar na elaboração dos mapa temático mais confiável. A acurácia global e o índice Kappa são medidas mais confiáveis para este objetivo, porque levam em consideração um balanço entre estes erros para chegar em valores que podem ser avaliados e comparados.

A Tabela 03 aponta a acurácia global e índice Kappa calculados para cada um dos três classificadores. A partir desta análise é possível perceber que o classificador SVM realmente apresenta resultados superiores para a classificação da área de estudo em relação aos outros algoritmos utilizados. O SVM é o único a apresentar acurácia global maior que 90%,

considerada bem alta para este tipo de classificação. O método de Bayes também apresentou valor de acurácia global bastante elevado. O valor alcançado pela Árvore de Decisão é substancial para a classificação de imagens de altíssima resolução espacial.

Tabela 03 – Acurácias globais e índices Kappa dos classificadores.

Algoritmo	Acurácia Global (%)	Índice Kappa
Árvore de Decisão	80,00	0,69
SVM	90,59	0,86
Bayes	87,06	0,80

Fonte: Do Autor (2019)

O coeficiente Kappa pode ser analisado tomando como base a relação de desempenho do classificador descrita por Fonseca (2000), de acordo com a Tabela 04. Nela, o índice é avaliado em uma escala de seis níveis. O classificador de Árvore de Decisão apresentou desempenho muito bom de acordo com esta denominação. Por outro lado, os classificadores SVM e Bayes obtiveram desempenho excelente para a classificação dos objetos nas três classes propostas.

Tabela 04 – Desempenho do classificador em relação ao índice Kappa

Índice Kappa	Desempenho
<0	Péssimo
$0 < k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito Bom
$0,8 < k \leq 1,0$	Excelente

Fonte: Fonseca (2000)

Os resultados obtidos neste trabalho são semelhantes aos encontrados por Qian et al. (2015), que utilizou quatro algoritmos, estando os três classificadores estudados neste trabalho incluídos em seu estudo. Os autores buscaram comparar o desempenho dos algoritmos de aprendizagem de máquina para a classificação do uso da terra usando imagens de altíssima resolução, sendo o SVM o superior. O resultado encontrado por eles evidencia o uso dos classificadores *normal* Bayes e SVM para este tipo de análise. Sulma et al. (2016) utilizaram SVM em uma abordagem orientada à objetos com o objetivo de classificar os espaços urbanos em áreas verdes e áreas não verdes na Indonésia. Os autores alcançaram bons resultados,

atingindo acurácia global de 86%. Tanto Qian et al. (2015) quanto Sulma et al. (2016) ressaltam a importância da seleção apropriadas dos parâmetros do classificadores para a obtenção de resultados de qualidade.

É importante ressaltar que apesar do melhor resultado encontrado pelo classificador SVM, ele permite maior customização de seus parâmetros quando comparado ao método utilizado em Bayes. Isso faz com que testes sejam necessários para decidir os fatores que otimizarão a classificação dos dados pelo SVM, buscando os melhores resultados de acurácia e coeficiente Kappa e, conseqüentemente, a melhor classificação.

5 CONCLUSÕES

Conclui-se com este trabalho que é possível obter uma classificação detalhada de ocupação do solo nas classes de uso permeável, impermeável e árvore com alta acurácia para a área da Universidade Federal de Lavras usando imagens de altíssima resolução obtidas através de VANT para serem usados na melhor estimativa de um dos indicadores do *GreenMetric*.

Os três algoritmos de classificação utilizados apresentaram bons resultados, sendo a metodologia baseada em *Support Vector Machine* a superior com acurácia global de 90,59%. Não distante disso, o algoritmo de Bayes obteve acurácia elevada e índice Kappa excelente. Ambos os classificadores podem ser usados para a obtenção da classificação, contudo para a utilização de SVM o é necessário conhecimento na decisão dos parâmetros do algoritmo para a estimativa adequada da permeabilidade ou não das superfícies.

REFERÊNCIAS BIBLIOGRÁFICAS

ANDRADE, A. F. **Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificiais**. Dissertação de Mestrado, Universidade Federal do Paraná, 2003.

ARNOLD, C. L., JR., GIBBONS, C. J. Impervious surface coverage: The emergence of a key environmental indicator. **Journal of the American Planning Association**, 1996.

AVERY, T. E.; BERLIN, G. L. **Fundamentals of Remote Sensing and Airphoto Interpretation**. Prentice-Hall. New Jersey, U.S.A., 1992.

BABOULET, O., LENZEN, M. **Evaluating the environmental performance of a university**. *Journal of Cleaner Production*, ed. 18, 2010.

BARBOSA, C.C.F.; NOVO, E.M.L.M.; MARTINS, V.S. **Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: princípios e aplicações**. 1ª edição. Instituto Nacional de Pesquisas Espaciais. São José dos Campos. 161p. 2019.

CLARK, R. N.; ROUSH, T. L. Reflectance spectroscopy - Quantitative analysis techniques for remote sensing applications. **Journal of Geophysical Research**, v. 89, p. 6329–6340, 1984.

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.

DRONEDEPLOY. **Documentação DroneDeploy**. Disponível em: <<https://support.dronedeploy.com/>> Acesso em: 20 outubro de 2019.

DURO, D.C.; FRANKLIN, S.E.; DUBE, M.G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, 118, p. 259-272, 2012

ERENER, A. Classification method, spectral diversity, band combination and accuracy assessment evaluation for urban feature detection. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 397-408, 2013.

FONSECA, L. M. G. **Processamento digital de imagens**. Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105p.

FOODY, G.M.; MATHUR, A.; SANCHEZ-HERNANDEZ, C.; BOYD, D.S. Training set size requirements for the classification of a specific class. **Remote Sensing of Environment**, v. 104, p. 1-14, 2006.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo. Editora Pearson Education do Brasil, 2010.

GRINDSTED, T. S. Sustainable universities - from declarations on sustainability in higher education to national law. **Journal of Environmental Economics**, v. 2, 2011.

JENSEN, J. R., COWEN, D. C. Remote Sensing of Urban/Suburban Infrastructure and Socioeconomic Attributes. **Photogrammetric Engineering and Remote Sensing**, v. 65, p. 611-622, 1999.

KAVZOGLU, T., ERDEMIR, M. Y., TONBUL, H. A region-based multi-scale approach for object-based image analysis. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLI-B7, p. 241-247, 2016.

KIM, M., WARNER, T. A., MADDEN, M., ATKINSON, D. S. Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects. **International Journal of Remote Sensing**, v. 32, p. 2825-2850, 2011.

LEMOS, P. F. I., BRANDO, F. D., GOMES, T. M. **University of São Paulo Environmental Policy: Master Plan and Pilot Projects for Pirassununga and Ribeirão Preto Campuses**. Sustainability on University Campuses: Learning, Skills Building and Best Practices. p. 73-90, 2018.

LU, D., WENG, Q. Extraction of urban impervious surfaces from an IKONOS image. **International Journal of Remote Sensing**, v. 30, 2009.

LUKMAN, R., KRANJC, D., GLAVIC, P. University ranking using research, educational and environmental indicators. **Journal of Cleaner Production**, ed. 18, 2010.

MENESES, P. R.; ALMEIDA, T. D. **Introdução ao processamento de imagem de sensoriamento remoto**. CNPq/UnB, p. 266, 2012.

MOGO, S. **Radiometria e fotometria**. Percepção visual. 2011.

MORAES, E. C. DE. **Fundamentos de sensoriamento remoto**. Instituto Nacional de Pesquisas Espaciais. Ministério da Ciência e Tecnologia, v. Capítulo 1, p. 3–12, 2002.

PIX4D. **Pix4D Mapper 4.1 User Manual**. Pix4D SA. Switzerland, 2018.

QIAN, Y., ZHOU, W., YAN, J., LI, W., HAN, L. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, v. 7, p. 153-168, 2015.

SCHNEIDER, W.; STEINWENDNER, J. Landcover Mapping by Interrelated Segmentation and Classification of Satellite Images. **Photogrammetric and Remote Sensing**. v. 32, 1999.

SULMA, S., YALIANTO, F., NUGROHO, J. T., SOFAN, P. A support vector machine object based image analysis approach on urban green space extraction using Pleiades-1A imagery. **Modeling Earth Systems and Environment**, v. 54, 2016.

SUWARTHA, N., SARI, R. F. Evaluating UI GreenMetric as a tool to support green universities development: assessment of the year 2011 ranking. **Journal of Cleaner Production**, v. 61, p. 46-53, 2013.

TOKARCZYK, P., LEITÃO, J. P., RIECKERMANN, J., BLUMENSAAT, F. **Enabling high-quality observations of surface imperviousness for water runoff modelling**. EGU General Assembly, p. 12-17, 2015.

TRIMBLE. **ECognition® Developer 8.7 Reference Book**; Trimble: Munich, Germany, 2011.

TROYA-GALVIS, A., GANÇARSKI, P., BERTI-ÉQUILLE, L. **Collaborative segmentation and classification for remote sensing image analysis**. 23rd International Conference on Pattern ReCognition® (ICPR). IEEE, Cancun, Mexico, p. 829–834, 2016.

TURNER, M. G. **Landscape ecology: The effect of pattern on process**. Annual Review of Ecology, Evolution, and Systematics, 1989.

TZOTSOS, A., KARANTZALOS, K., ARGIALAS, D. Object based image analysis through nonlinear scale-space filtering. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.66, p. 2-16, 2011.

UFLA. **Sobre a UFLA**. Disponível em: <<https://ufla.br/>> Acesso em: 28 maio de 2019.

UNESCO CEPES, 2004. **European Centre for Higher Education. Higher Education Ranking Systems and Methodologies: How They Work, What They Do**. Disponível online: <<http://www.rektorat.unibe.ch/unibe/rektorat/unistab>>. Acesso em: 13 de outubro de 2019.

VAPNIK, V.; CHERVONENKIS, A. On the uniform convergence of relative frequencies of events to their probabilities. **Theory of Probability and its Applications**, v. 16, p. 264-280, 1971.

VISOCKIENE, J. S., BRUCAS, D., RAGAUSKAS, U. Comparison of UAV images processing softwares. **Journal of Measurements in Engineering**, v. 2, 2014.

VOORDE, T. V., JACQUET, W., CANTERS, F. Mapping form and function in urban areas: An approach based on urban metrics and continuous impervious surface data. **Landscape and Urban Planning**, v. 102, 2011.

WENG, Q. Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends. **Remote Sensing of Environment**, v. 117, p. 34-49, 2012.