Universidade de São Paulo
Escola Superior de Agricultura "Luiz de Queiroz"

Sensoriamento remoto para identificação taxonômica e mapeamento de espécies arbóreas em ambiente urbano

Caio Hamamura

Tese apresentada para obtenção do título de Doutor em Ciências. Programa: Recursos Florestais. Opção em: Conservação de Ecossistemas Florestais.

Piracicaba
2020

Caio Hamamura
Bacharel em Ciências Biológicas

Sensoriamento remoto para identificação taxonômica e mapeamento de espécies arbóreas em ambiente urbano

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **DEMÓSTENES FERREIRA DA SILVA FILHO**

Tese apresentada para obtenção do título de Doutor em Ciências. Programa: Recursos Florestais. Opção em: Conservação de Ecossistemas Florestais.

Piracicaba
2020

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA - DIBD/ESALQ/USP

Hamamura, Caio
Sensoriamento remoto para identificação taxonômica e mapeamento de espécies arbóreas em ambiente urbano / Caio Hamamura. – – versão revisada de acordo com a resolução CoPGr 6018 de 2011. – – Piracicaba, 2020.
103p.

Tese (Doutorado) – – USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Imagens RGB 2. LiDAR multiespectral 3. Arborização urbana 4. Aprendizado de máquina . I. Título.

AGRADECIMENTOS

À Deus.

À minha esposa, que a todo momento esteve ao meu lado me dando suporte e motivação para sempre estar crescendo e me aprimorando.

Aos meus sogros que sempre me apoiaram e ajudaram muito com os deveres domésticos, possibilitando minha dedicação à Tese.

À minha família e amigos pelo suporte e apoio emocional.

Ao meus cachorrinhos de estimação Keeki e Kohi que estão sempre alegres disponíveis para me confortar e trazer um pouco de paz a todo e qualquer momento.

Ao meu orientador, Demóstenes Ferreira da Silva Filho, que mesmo durante minhas ausências, sempre apoiou minhas escolhas e me deu autonomia para desenvolver o meu trabalho.

À Giovana Oliveira, amiga e parceira fundamental para o programa de pós-graduação em Recursos Florestais, pelo apoio, pelas trocas de ideias e conversas, além da disponibilidade para resolver os problemas e dúvidas.

Ao Jefferson Lordelo Polizel, pela amizade, companhia e competência, e praticamente co-orientador de todos os trabalhos que passam pelo Laboratório de Métodos Quantitativos.

Ao meu amigo Carlos Alberto Silva, que prestou orientação e suporte imprescindíveis para o desenvolvimento desta Tese.

Ao meu amigo, colega de pós-graduação e banca de qualificação Eric Bastos Görgens por estar sempre disponível para compartilhar ideias, com grandes contribuições para que este trabalho fosse realizado.

Ao meu amigo e colaborador nas pesquisas no Laboratório de Silvicultura Urbana, Flávio Henrique Mendes, que além da companhia e trocas de experiências e ideias, foi imprescindível para o desenvolvimento trabalho, ajudando na identificação das espécies.

Ao meu amigo Danilo Roberti de Almeida, parceiro de trabalho, confiando-me o seu drone pessoal por cerca de um mês para coleta de dados, além de me apresentar ao Carlos Alberto Silva.

Ao meu colega e co-orientador Steven Hancock, da Universidade de Edimburgo que me recebeu como pesquisador visitante durante dois meses de muito crescimento e aprendizado.

Ao Instituto Federal de Ciência, Educação e Tecnologia, que me concedeu licença remunerada para terminar o meu doutorado, sem a qual, dificilmente teria se concretizado.

À Teledyne Optech, pelo fornecimento dos dados LiDAR multiespectrais.

SUMÁRIO

Resumo . . . 6
Abstract . . . 7
Lista de Figuras . . . 8
Lista de Tabelas . . . 10
INTRODUÇÃO . . . 13
Referências . . . 15
1 Uso de sensoriamento remoto para o mapeamento de espécies em florestas urbanas, uma revisão . . . 19
Resumo . . . 19
1.1 Introdução . . . 19
1.2 Desenvolvimento . . . 20
1.2.1 Abordagem da revisão . . . 20
1.2.2 Tendências de publicação . . . 20
1.2.3 Abordagens para classificação . . . 21
1.2.4 Pré-tratamento de dados . . . 22
1.2.4.1 Fusão com a banda pancromática . . . 22
1.2.4.2 Correção geométrica . . . 26
1.2.5 Segmentação . . . 26
1.2.6 Extração de atributos . . . 27
1.2.7 Seleção de atributos . . . 33
1.2.8 Classificação supervisionada . . . 35
1.2.9 Aferimento da qualidade dos resultados . . . 36
1.3 Conclusão . . . 39
Referências . . . 40
2 Análise das variáveis extraídas de imagens RGB para diferenciação de espécies arbóreas da Universidade de São Paulo, campus Piracicaba . . . 47
Resumo . . . 47
2.1 Introdução . . . 47
2.2 Materiais e Métodos . . . 48
2.2.1 Área de Estudo . . . 48
2.2.2 Dados de sensorimento remoto . . . 48
2.2.3 Coleta de campo . . . 48
2.2.4 Extração de atributos . . . 49
2.2.5 Seleção de atributos e classificação . . . 49
2.2.6 Análise dos resultados . . . 50
2.3 Resultados . . . 50
2.4 Discussão . . . 51
2.5 Conclusão . . . 55
Referências . . . 56
3 LiDAR multiespectral para classificação de espécies arbóreas de clima temperado em arborização viária 59
Resumo . . . 59
3.1 Introdução . . . 59
3.2 Materiais e Métodos . . . 60
3.2.1 Descrição da área de estudo . . . 60
3.2.2 Aquisição de dados do LiDAR multiespectral . . . 61

3.2.3 Processamento dos dados 61
3.2.3.1 Correção da intensidade 62
3.2.3.2 Fusão das nuvens 63
3.2.3.3 Delineamento Individual das Copas de Árvore 64
3.2.3.4 Extração de atributos 64
3.2.3.5 Seleção de Atributos e Classificação 67
3.3 Resultados e Discussão 70
3.3.1 Normalização da intensidade com base no ângulo de escaneamento 70
3.3.2 Fusão das Nuvens 70
3.3.3 Delineamento Individual das Copas de Árvore 71
3.3.4 Seleção de atributos e classificação 75
3.4 Conclusão 85
Referências 86
CONSIDERAÇÕES FINAIS 93
APÊNDICES 96
A. radarBoxplot: pacote em R que implementa o radar-boxplot. 96
B. MultiSpecLiDAR: pacote em R para análise de dados LiDAR multiespectrais 98
ANEXOS 100
A. Matrizes de erros 100

RESUMO

Sensoriamento remoto para identificação taxonômica e mapeamento de espécies arbóreas em ambiente urbano

O mapeamento das espécies no ambiente urbano é uma importante ferramenta para a gestão da floresta urbana. As diferentes espécies arbóreas apresentam características peculiares de formato e densidade de copa, além de formato e estrutura foliares distintas. Esses dados geométricos das copas e folhas de diferentes espécies arbóreas provenientes de nuvem LiDAR, em conjunto com dados de reflectância espectral obtidas por sensoriamento remoto podem ser explorados visando a classificação taxonômica dos indivíduos arbóreos. A análise aprofundada dos dados disponíveis a partir de LiDAR pode revelar novas formas de classificação, de detecção e identificação dos indivíduos arbóreos. Nesse contexto, esta tese tem por objetivo aferir diferentes métodos para o mapemento de espécies arbóreas em ambiente urbano, baseado na segmentação das copas das árvores e uso de diferentes sensores. O trabalho consiste em três capítulos: 1) Uma revisão sistemática do mapeamento de espécies ou tipos de árvores em ambiente urbano; 2) Analisar a possibilidade do uso de imagens RGB provenientes de veículos aéreos não tripulados (VANT) para o mapemento de espécies arbóreas em ambiente urbano; 3) Análise do uso de um sensor LiDAR multiespectral como fonte única de dados para a classificação de espécies arbóreas. O trabalho demonstra duas possíveis formas de mapear as espécies arbóreas no meio urbano, uma utilizando método de baixo custo, porém com mais limitações, e outro com sensor LiDAR multiespectral de alto custo operacional, no entanto com resultados satisfatórios, obtendo índice Kappa de até 0,9.

Palavras-chave: Imagens RGB, LiDAR multiespectral, Arborização urbana, Aprendizado de máquina

ABSTRACT

Remote sensing for mapping and identifying tree species in urban environment.

Mapping tree species in the urban environment can be an important tool for the urban forest management. The different tree species have peculiar characteristics of canopy shape and density, as well as distinct leaf shape and structure. These geometric data of the crown and leaves of different tree species from the LiDAR cloud, together with spectral reflectance data obtained by other remote sensing sources can be explored aiming at the taxonomic classification of tree individuals. In-depth analysis of the data available from LiDAR can reveal new ways of classifying, detecting and identifying tree individuals. In this context, this thesis aims to assess different methods for mapping tree species in an urban environment, based on the individual segmentation of tree crown and the use of different sensors. The work consists of three chapters: 1) A systematic review on mapping urban tree species or types of trees; 2) assessment of RGB images from unmanned aerial vehicles (UAV) for mapping urban tree species; 3) multispectral LiDAR sensor as a single source of data for classifying urban tree species. The work demonstrates two possible ways of mapping tree species in the urban environment, one using a low cost method, but with more limitations, and a second with a multispectral LiDAR sensor high operational at a more expensive budget, however achieving better results, obtaining a Kappa index of up to 0.9.

Keywords: RGB Imagery, Multispectral LiDAR, Urban forestry, Machine learning

LISTA DE FIGURAS

1.1 Frequência de estudos entre 2003 a 2018. Os valores das linhas referentes ao uso de dados Hiperespectral e Combinado (Imagem + LiDAR) e tiveram um deslocamento em y de 0.15 e 0.3 respectivamente para melhorar a leitura. 21
1.2 Frequência de utilização dos diferentes classificadores por abordagem. CART (*Classification and Regression Trees*): árvores de decisão, k-NN: k vizinhos mais próximos, ADBC: árvore de decisão baseada em conhecimento, LDA (*Linear Discriminant Analysis*): análise discriminante linear, MCC (*Multi Class Classifier*): classificador multiclasse de Zhang et al. (2016), MLC (*Maximum Likelihood Classifier*): máxima verossimilhança, RF: *Random Forest*, SVM (*Support Vector Machine*): máquina de suporte a vetores. 36

2.1 Área de estudo. a) Estado de São Paulo, b) Município de Piracicaba, c) Campus da ESALQ com imagem drone destacada. 49
2.2 Imagem demonstrando a vetorização manual das árvores resultante da metodologia proposta. 50
2.3 Exemplo do gráfico radar-boxplot. Em vermelho a variação dentro dos percentis 25-75% e em azul a amplitude removendo os outliers representados como pontos abertos. 51
2.4 Gráfico demonstrando o incremento de acurácia em relação ao número de variáveis utilizando o classificador Random Forest 52
2.5 Gráfico de radar-boxplot. A área em vermelho representa a variabilidade da variável dentro dos percentis 25-75%, a área em azul demonstra a amplitude total da variável sem os outliers. 53

3.1 Área de estudo. a) Estado de Ontário, b) Município de Oshawa, c) Recorte da área de estudo em amarelo, com as amostras selecionadas para identificação e treinamento. 61
3.2 Canais de aquisição do sensor *Optech Titan*. 62
3.3 Fluxograma de processamento dos dados 62
3.4 Esquema das métricas utilizadas para as árvores. 64
3.5 Polígono de exemplo de pontos da copa em cinza, extraindo o polígono convexo, seus vértices P, medianas M e centroide G. 66
3.6 Nuvem de pontos com a métrica BEST_SHAPE extraída utilizando o algoritmo desenvolvido na tese. 67
3.7 Efeito da normalização da intensidade por classe de intensidade. 70
3.8 Nuvem de pontos em falsa cor, vermelho=C1, Verde=C2 e Azul=C3, após fusão das nuvens independentes. a) Todos os retornos da nuvem. b) Apenas retornos únicos. 71
3.9 Detalhe de corpo d'água colorido por: a) falsa cor; b) por canal, vermelho C1, verde C2 e azul C3. 72
3.10 Relação entre altura da base da copa (CBH) e outras métricas extraídas da nuvem de pontos. 72
3.11 Relações alométricas entre altura (m) x altura da copa (m) e altura (m) x largura da copa (m). 73
3.12 Resultado da individualização das copas de árvores pelo algoritmo Mean Shift adaptativo de Ferraz et al. (2016). As árvores estão coloridas aleatoriamente, cores contíguas representam um segmento. 74
3.13 Remoção dos segmentos que não possuem características de copa de árvores utilizando limiares de métricas espaciais extraídas da nuvem. Azul: árvores mantidas; vermelho: remoção baseada na divisão em fatias de altura e número mínimo de retornos não colineares; amarelo: CV/CSA <= 0,33 (objetos chatos, muita superfície pouco volume); verde: diâmetro máximo/diâmetro mínimo > 2,5 74

3.14 Gráfico de acurácia do usuário x acurácia do produtor para os quatro algoritmos testados: random forest (RF), MLC (máxima verossimilhança), LDA (análise discriminante linear) e SVM (máquina de suporte a vetores). Os conjuntos de variáveis (V_SPEC: variáveis espectrais apenas; V_3D: variáveis estruturais apenas; V_COMB: combinação de espectrais e estruturais; V_UNI: simulação de LiDAR uniespectral com uso de atributos estruturais e espectrais do canal 1064 nm) estão em cores diferentes e as espécies com tipos de ponto diferente conforme a legenda. No limite esquerdo e superior de cada painel temos a acurácia geral média para cada conjunto de atributos com a mesma cor utilizada para a representação dos pontos. 80
3.15 Correlação entre as diferentes métricas de acurácia: acurácia geral (OA), F1-macro, F1-sd, MCC e Kappa. 82
3.16 Matriz de concordância entre os diferentes classificadores, demonstrando o Kappa ± intervalo de confiança de 95%. 84
3.17 Gráfico de acurácia do usuário x acurácia do produtor para os quatro algoritmos diferenciados pela cor e espécies com tipos de ponto diferente, conforme legenda. No limite esquerdo e superior de cada painel estão retratados o Kappa ± intervalo de confiança de 95% representados com a mesma cor utilizada para os pontos. 84
3.18 Gráfico aluvial da classificação gerada por MLC. Do lado esquerdo estão as classes reais e a direita o predito. Em verde, demonstra o que foi corretamente classificado e vermelho incorretamente classificado. 85
3.19 Mapa do resultado da classificação sobre toda a área de estudo. 86
A.1 Exemplo de radar-boxplot para o conjunto de dados de vinho tinto de Cortez et al. (2009). Cada radar-boxplot representa uma nota de 3 a 8 atribuída por enólogos e nos eixos as propriedades físico-químicas dos vinhos. 97

LISTA DE TABELAS

1.1 Tabela demonstrando a quantidade de trabalhos que realizam os diferente pré-tratamentos de dados de imagem 22
1.2 Tabela de atributos extraídos da nuvem de pontos do 27
1.3 Acurácia final dos diferentes estudos, com a abordagem utilizada, menor classe, número de classes de vegetação e classificador com melhor resultado. 37
1.4 Matriz para teste χ^2 do teste de McNemar 39

2.1 Árvores identificadas na região amostrada. 52
2.2 Tabela de variáveis mais importantes escolhidas para gerar o classificador Random Forest 54
2.3 Matriz de erros, as classes correspondem a: A - Araçá, Ce - Cedrinho, Ci - Cipreste italiano, Ib - Ipê-branco, Ir - Ipê-roxo, Ja - Jaboticaba-sabará, Je - Jerivá, Mi - Mirindiba, Mu - Mulunguba, Pf - Palmeira-fênix, Pi - Palmeira imperial, Pl - Palmeira-leque, Pb - Pau-brasil, Pt - Pitanga, Se - Seafortia, Si - Sibipiruna . . . 54

3.1 Tabela de atributos extraídos da nuvem de pontos do LiDAR multiespectral. . . 65
3.2 Árvores identificadas nas cinco amostras de 200 x 200 metros. 75
3.3 Atributos estruturais e espectrais (V_COMB) selecionados por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold. 76
3.4 Atributos espectrais selecionados (V_SPEC) por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold. 77
3.5 Atributos estruturais (V_3D) selecionados por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold. 78
3.6 Atributos selecionados para simulação de LiDAR uniespectral (V_UNI) por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold. 78
3.7 Resultado da validação cruzada *leave-on-out* dos classificadores testados com diversas métricas de qualidade: acurácia geral, F1-macro ± desvio padrão do escore F1, Coeficiente de Correlação de Matthew (MCC) e Kappa de Cohen. 81
3.8 Classificação da área de estudo completa, demonstrando a quantidade de indivíduos em cada espécie por classificador. 83
anexo1 Matriz de erros para o algoritmo LDA variáveis espectrais e espaciais (V_COMB). 100
anexo2 Matriz de erros para o algoritmo LDA e conjunto de variáveis V_SPEC. 100
anexo3 Matriz de erros para o algoritmo LDA e conjunto de variáveis V_3D. 100
anexo4 Matriz de erros para o algoritmo LDA e conjunto de variáveis V_UNI. 100
anexo5 Matriz de erros para o algoritmo MLC variáveis espectrais e espaciais (V_COMB). 101
anexo6 Matriz de erros para o algoritmo MLC e conjunto de variáveis V_SPEC. 101
anexo7 Matriz de erros para o algoritmo MLC e conjunto de variáveis V_3D. 101

anexo8 Matriz de erros para o algoritmo MLC e conjunto de variáveis V_UNI. 101
anexo9 Matriz de erros para o algoritmo RF variáveis espectrais e espaciais (V_COMB). 101
anexo10 Matriz de erros para o algoritmo RF e conjunto de variáveis V_SPEC. 102
anexo11 Matriz de erros para o algoritmo RF e conjunto de variáveis V_3D. 102
anexo12 Matriz de erros para o algoritmo RF e conjunto de variáveis V_UNI. 102
anexo13 Matriz de erros para o algoritmo SVM variáveis espectrais e espaciais (V_COMB). 102
anexo14 Matriz de erros para o algoritmo SVM e conjunto de variáveis V_SPEC. 102
anexo15 Matriz de erros para o algoritmo SVM e conjunto de variáveis V_3D. 103
anexo16 Matriz de erros para o algoritmo SVM e conjunto de variáveis V_UNI. 103

INTRODUÇÃO

O meio urbano é um ambiente altamente antropizado de modo a causar mudanças estruturais e arquitetônicas que podem levar ao desequilíbrio ambiental, causando ou acentuando problemas que afetam diretamente ou indiretamente a saúde pública e o bem estar social, tais como: enchentes e inundações, baixa umidade relativa, poluição atmosférica, poluição visual, ilhas de calor e degradação dos recursos hídricos. Tais problemas podem ser atenuados, utilizando-se, por exemplo, da arborização urbana de forma a restaurar ou mimetizar parte do ambiente natural (TAHA, 1996; ZÖLCH et al., 2017; SMARDON, 1988; TYRVÄINEN; SILVENNOINEN; KOLEHMAINEN, 2003).

Entretanto, a arborização urbana requer planejamento e gestão para que, de um lado ela possa fornecer os serviços desejados e, ao mesmo tempo, cause o mínimo de impactos negativos que podem incorrer como: obstrução das vias, interferência com o sistema elétrico e hidráulico, queda e danos à infraestrutura.

Nesse contexto, a informação taxonômica espacializada das árvore no ambiente urbano pode ser uma ferramenta muito importante para a gestão da arborização urbana. Além da análise de diversidade, essa informação pode fornecer indicativos para a sistematização da poda, análise de risco de pragas e doenças, risco de dano a infraestrutura e estimação dos potenciais benefícios dependentes da espécie como controle de poluição atmosférica (TAHA, 1996), captação de água da chuva (ZÖLCH et al., 2017) e ornamentação (SMARDON, 1988; TYRVÄINEN; SILVENNOINEN; KOLEHMAINEN, 2003).

De posse dessas informações os gestores podem, por exemplo, obter indicativos de locais nos quais seria preciso programar a manutenção em decorrência da ocorrência de espécies de grande porte que podem vir a ter contato com a rede elétrica ou cujo sistema radicular costuma apresentar conflito com a estrutura urbana, ou simplesmente necessidade de limpeza sazonal em época de queda de flores e folhas característica de certas espécies como os diversos ipês. Com essa informação espacializada, pode-se evitar a agregação de táxons próximos suscetíveis aos mesmos tipos de pragas e doenças, visando reduzir o risco de propagação.

No Brasil, os municípios, em geral, possuem poucos dados a respeito dos indivíduos, como a classificação taxonômica e a localização das árvores presentes na floresta urbana, dificultando assim a gestão da arborização urbana. Grande parte desses dados são provenientes de estudos de natureza científica nos quais foram realizados inventários por diferentes métodos, normalmente por amostragem de campo (DANTAS; SOUZA, 2004; FARIA; MONTEIRO; FISCH, 2007; ROSSATTO et al., 2008).

Considerando essas questões, o desenvolvimento de metodologias automatizadas que visam mapear a arborização por meio de sensoriamento remoto, extraindo informações dos indivíduos em grandes áreas poderiam suprir tais informações para a gestão pública de forma mais prática, viabilizando a atualização dos dados em um intervalo de tempo menor. Diversos estudos, apontam o potencial do uso de imagens multiespectrais (SUGUMARAN; PAVULURI; ZERR, 2003; YAN et al., 2018), hiperespectrais (JENSEN; HARDIN; HARDIN, 2012; LAUNEAU et al., 2017) e LiDAR (VOSS; SUGUMARAN, 2008; LIU et al., 2017) para esse propósito.

As imagens multiespectrais são obtidas por sensores capazes de obter simultaneamente diversas regiões do espectro, incluindo o espectro visível e infravermelho. De maneira semelhante, os sensores hiperespectrais registram os dados espectrais, mas apresentam larguras das bandas mais estreitas, dividindo o espectro em uma quantidade maior de bandas. Porém, os sensores hiperespectrais são mais caros e resultam em uma pior resolução espacial quando os dados são capturados na mesma altitude (MOZGERIS et al., 2016).

Alguns estudos indicam a possibilidade de classificação taxonômica por meio de imagens multiespectrais, obtendo resultados expressivos com índice Kappa superiores a 0,9 (SHEEREN et al., 2016). No entanto, o estudo é realizado em florestas temperadas, bastante homogêneas, valendo-se de classificação

por pixel em grandes agregados arbóreos.

A tecnologia LiDAR, do acrônimo *Light Detection And Ranging*, utiliza feixes de laser e um sensor capaz de calcular a distância dos retornos da emissão de cada pulso do laser baseado no tempo de retorno. Esse procedimento é repetido de forma a varrer uma determinada área e gera dados que, após serem corregistrados, resulta em uma nuvem de pontos espacializados tridimensionalmente. Entretanto, a extração de informações a partir da nuvem LiDAR não é um procedimento simples e bem estabelecido, exceto para algumas aplicações específicas e ainda necessita de um extenso estudo sobre os dados para cada aplicação específica. Diversos estudos científicos têm sido efetuados nesse sentido para tentar estabelecer procedimentos para extração das informações a partir de dados oriundos de LiDAR (DÍAZ-VILARIÑO et al., 2016; CÔTÉ et al., 2009; KATO et al., 2009; KIM et al., 2009; CENTENO; MITISHITA, 2007).

Dentre alguns desses estudos destacam-se: aplicações florestais, de análise da estrutura viária e entorno para o desenvolvimento de veículos autônomos e estudos de enchentes em ambiente urbano. Algumas aplicações florestais inclusive indicam a possibilidade de identificação das espécies, sobretudo em contexto silvicultural ou florestas de coníferas mais homogêneas com poucas espécies (SURATNO; SEIELSTAD; QUEEN, 2009).

Na área urbana brasileira, por outro lado, a diversidade do plantio é maior e os espaçamentos são esparsos o que permitiria a vetorização e isolamento dos indivíduos, consistindo em um excelente caso para a realização de classificação objeto-orientada. Existe assim a possibilidade da extração de uma enorme diversidade de atributos texturais, espectrais e geométricos das feições vetorizadas, o que permite uma descrição detalhada da árvore e a exploração desses atributos para discriminar as espécies.

O isolamento dos indivíduos é uma tarefa em que já existem diversos algoritmos propostos como em Sačkov et al. (2017), que utiliza uma janela deslizante para encontrar o ponto de máxima altura local e depois avalia a validade geo-dendromética da árvore baseando-se em sua altura e largura de copa, além da comparação de sua altura e distância com as árvores vizinhas. Cumpre salientar que o algoritmo foi desenvolvido para identificar coníferas, portanto provavelmente necessitará de adaptações, dadas as diferenças da arquitetura da copa em relação às árvores tropicais.

O uso combinado de LiDAR e imagens multiespectrais não é comum, no entanto foi utilizado em certos trabalhos como Kukunda et al. (2018) para distinguir entre *Pinus uncinata* e *P. sylvestris*. O trabalho demonstrou que o uso combinado das características geométricas e espectrais de fato aumentam a capacidade discriminatória do classificador. Cabe ressaltar que não foram utilizadas métricas de simetria de copa, que de fato não seria um bom descritor para diferenciar as coníferas, mas que podem ser importantes para diferenciar espécies arbóreas tropicais, já que essas possuem copas mais assimétricas.

Nesse contexto, o LiDAR multiespectral vem ganhando espaço como alternativa à fusão dos dados separados LiDAR e imagens multiespectrais. Esses sensores são capazes de capturar simultaneamente nuvens de pontos em diferentes comprimentos de onda. Dessa forma, há menor necessidade de pré-processamento dos dados para buscar compatibilizar os dados do LiDAR e das imagens multiespectrais, além disso isso permite obter os dados espectrais espacializados tridimensionalmente, diferentemente do que ocorreria no processo de fusão Teledyne Optech (2014).

Dessa forma, um estudo aprofundado dos dados LiDAR, principalmente os geométricos, pode revelar informações significativas para a classificação das espécies por meio de sensoriamento remoto que normalmente se restringe a utilizar sensores multi ou hiperespectrais (ALBA et al., 2015; IMMITZER; ATZBERGER; KOUKAL, 2012), ou ainda apenas os valores de intensidade de retorno do LiDAR (KIM et al., 2009; KIM; HINCKLEY; BRIGGS, 2011), deixando de explorar as propriedades geométricas das copas (PETEAN, 2015; KIM; HINCKLEY; BRIGGS, 2011) e obtendo baixo grau de separação das classes de espécies.

O objetivo neste trabalho foi analisar o potencial do uso do sensoriamento remoto para mapeamento das espécies arbóreas em ambiente urbano.

A tese foi dividida em capítulos, apresentando inicialmente uma revisão de trabalhos que abordam o mapeamento de espécies ou tipos de vegetação no meio urbano, demonstrando a existência de diferentes padrões de abordagem: pixel, segmentação e individualização das copas de árvores.

O capítulo seguinte demonstra uma abordagem utilizando imagens que capturam apenas o espectro visível dividido nas bandas vermelho, verde e azul (RGB) obtidas por meio de drone como uma alternativa de baixo custo para a classificação e mapeamento de espécies em relação ao uso de sobrevoo com aeronaves tripuladas e sensores sofisticados multiespectrais, hiperespectrais e LiDAR. O resumo desse capítulo foi publicado no Simpósio Brasileiro de Sensoriamento Remoto (SBSR) de 2019 (HAMAMURA et al., 2019).

O último capítulo avalia o potencial do uso do LiDAR multiespectral obtido por sobrevoo para o mapeamento das espécies arbóreas. Nesse capítulo foi desenvolvido o multipecLiDAR um pacote em R para trabalhar com os dados multiespectrais, implementando os algoritmos descritos na tese .

Ambas as soluções se mostram viáveis do ponto de vista técnico, no entanto ainda são necessários estudos para estabelecer padrões, identificar as melhores aplicações e limitações de cada tecnologia, bem como testar, comparar e validar os diversos métodos já desenvolvidos por diversos pesquisadores para diferentes contextos.

Referências

ALBA, Elisiane et al. Uso da resposta espectral na identificação e monitoramento de espécies florestais a partir de imagens de média resolução espacial. In: 25 a 29 de abril. ANAIS XVII Simpósio Brasileiro de Sensoriamento Remoto. João Pessoa, PB, Brasil: INPE, 2015. P. 2900–2906.

CENTENO, Jorge Antonio Silva; MITISHITA, Edson Aparecido. Laser scanner aerotransportado no estudo de áreas urbanas: A experiência da UFPR. In: ANAIS XIII Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis, Vrasil: INPE, 2007. v. 1, p. 3645–3652.

CÔTÉ, Jean François et al. The structural and radiative consistency of three-dimensional tree reconstructions from terrestrial lidar. **Remote Sensing of Environment**, Elsevier Inc., v. 113, n. 5, p. 1067–1081, 2009. ISSN 00344257. DOI: `10.1016/j.rse.2009.01.017`. Disponível em: <`http://dx.doi.org/10.1016/j.rse.2009.01.017`>.

DANTAS, Ivan Coelho; SOUZA, Cinthia Maria Carlos De. Arborização urbana na cidade de Campina Grande - PB: inventário e suas espécies. **Revista de Biologia e Ciências da Terra**, v. 4, n. 2, p. 1–18, 2004.

DÍAZ-VILARIÑO, L. et al. Automatic classification of urban pavements using mobile LiDAR data and roughness descriptors. en. **Construction and Building Materials**, v. 102, n. 102, p. 208–215, jan. 2016. ISSN 09500618. DOI: `10.1016/j.conbuildmat.2015.10.199`. Disponível em: <`https://www.infona.pl//resource/bwmeta1.element.elsevier-c112ab7c-762f-3023-a43d-a813f2d24456`>.

FARIA, José Luiz Guisard; MONTEIRO, Evoni Antunes; FISCH, Simey Thury Vieira. Arborização De Vias Públicas Do Município De Jacareí – Sp. **Journal of Brasilian Society of Urban Forest**, v. 2, n. 4, p. 20–33, 2007.

HAMAMURA, Caio et al. Identificação de espécies arbóreas a partir de imagem de sensoriamento remoto. In: ANAIS do XIX Simpósio Brasileiro de Sensoriamento Remoto. Santos, SP: Galoá anais e proceedings, 2019. P. 3120–3123.

IMMITZER, Markus; ATZBERGER, Clement; KOUKAL, Tatjana. Tree species classification with Random forest using very high spatial resolution 8-band worldView-2 satellite data. **Remote Sensing**, v. 4, n. 9, p. 2661–2693, 2012. ISSN 20724292. DOI: `10.3390/rs4092661`.

JENSEN, Ryan R.; HARDIN, Perry J.; HARDIN, Andrew J. Classification of urban tree species using hyperspectral imagery. **Geocarto International**, v. 27, n. 5, p. 443–458, 2012. ISSN 10106049. DOI: 10.1080/10106049.2011.638989.

KATO, Akira et al. Capturing tree crown formation through implicit surface reconstruction using airborne lidar data. **Remote Sensing of Environment**, Elsevier Inc., v. 113, n. 6, p. 1148–1162, 2009. ISSN 00344257. DOI: 10.1016/j.rse.2009.02.010. Disponível em: <http://dx.doi.org/10.1016/j.rse.2009.02.010>.

KIM, Sooyoung; HINCKLEY, Thomas; BRIGGS, David. Classifying individual tree genera using stepwise cluster analysis based on height and intensity metrics derived from airborne laser scanner data. **Remote Sensing of Environment**, Elsevier Inc., v. 115, n. 12, p. 3329–3342, 2011. ISSN 00344257. DOI: 10.1016/j.rse.2011.07.016. Disponível em: <http://dx.doi.org/10.1016/j.rse.2011.07.016>.

KIM, Sooyoung et al. Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. **Remote Sensing of Environment**, Elsevier Inc., v. 113, n. 8, p. 1575–1586, 2009. ISSN 00344257. DOI: 10.1016/j.rse.2009.03.017. Disponível em: <http://dx.doi.org/10.1016/j.rse.2009.03.017>.

KUKUNDA, Collins B. et al. Ensemble classification of individual Pinus crowns from multispectral satellite imagery and airborne LiDAR. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 65, July 2017, p. 12–23, 2018. ISSN 1872826X. DOI: 10.1016/j.jag.2017.09.016. Disponível em: <https://doi.org/10.1016/j.jag.2017.09.016>.

LAUNEAU, Patrick et al. Airborne hyperspectral mapping of trees in an urban area. **International Journal of Remote Sensing**, v. 38, n. 5, p. 1277–1311, 2017. ISSN 13665901. DOI: 10.1080/01431161.2017.1285080.

LIU, Luxia et al. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. **Remote Sensing of Environment**, Elsevier, v. 200, p. 170–182, out. 2017. ISSN 0034-4257. DOI: 10.1016/J.RSE.2017.08.010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717303620?via%7B%5C%%7D3Dihub>.

MOZGERIS, Gintautas et al. Hyperspectral and color-infrared imaging from ultralight aircraft: Potential to recognize tree species in urban environments. In: 2016 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Los Angeles, USA: IEEE, ago. 2016. P. 1–5. ISBN 978-1-5090-0608-3. DOI: 10.1109/WHISPERS.2016.8071756. Disponível em: <http://ieeexplore.ieee.org/document/8071756/>.

PETEAN, Felipe Coelho de Souza. **Uso de imagens hiperespectrais e da tecnologia LiDAR na identificação de espécies florestais em ambiente urbano na cidade de Belo Horizonte , Minas Gerais**. 2015. F. 132. Tese (Doutorado) – USP, Piracicaba, SP, Brasil.

ROSSATTO, Davi Rodrigo et al. Arborização Urbana Na Cidade De Assis-Sp : Uma Abordagem Quantitativa. **Rev. SBAU, Piracicaba, v.3, n.3, set. 2008, p. 1-16.**, v. 1, p. 1–16, 2008.

SAČKOV, Ivan et al. Integration of tree allometry rules to treetops detection and tree crowns delineation using airborne lidar data. **IForest**, v. 10, n. 2, p. 459–467, 2017. ISSN 19717458. DOI: 10.3832/ifor2093-010.

SHEEREN, David et al. Tree Species Classification in Temperate Forests Using Formosat-2 Satellite Image Time Series. **Remote Sensing**, v. 8, n. 9, p. 734, 2016. ISSN 2072-4292. DOI: 10.3390/rs8090734. Disponível em: <http://www.mdpi.com/2072-4292/8/9/734>.

SMARDON, Richard C. Perception and aesthetics of the urban environment: Review of the role of vegetation. **Landscape and Urban Planning**, Elsevier, v. 15, n. 1-2, p. 85–106, jun. 1988. ISSN 0169-2046. DOI: 10.1016/0169-2046(88)90018-7. Disponível em: <https://www.sciencedirect.com/science/article/pii/0169204688900187>.

SUGUMARAN, Ramanathan; PAVULURI, M.K. Manoj Kumar; ZERR, Daniel. The use of high-resolution imagery for identification of urban climax forest species using traditional and rule-based classification approach. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, 9 PART I, p. 1933–1939, set. 2003. ISSN 01962892. DOI: 10.1109/TGRS.2003.815384. Disponível em: <http://ieeexplore.ieee.org/document/1232207/>.

SURATNO, Agus; SEIELSTAD, Carl; QUEEN, Lloyd. Tree species identification in mixed coniferous forest using airborne laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier B.V., v. 64, n. 6, p. 683–693, 2009. ISSN 09242716. DOI: 10.1016/j.isprsjprs.2009.07.001. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2009.07.001>.

TAHA, Haider. Modeling impacts of increased urban vegetation on ozone air quality in the South Coast Air Basin. **Atmospheric Environment**, Pergamon, v. 30, n. 20, p. 3423–3430, out. 1996. ISSN 1352-2310. DOI: 10.1016/1352-2310(96)00035-0. Disponível em: <https://www.sciencedirect.com/science/article/pii/1352231096000350>.

TELEDYNE OPTECH. **Optech Titan Multispectral Lidar System: High Precision Environmental Mapping**. Canada: [s.n.], 2014. P. 8. Disponível em: <https://geo3d.hr/sites/default/files/2018-06/Titan-Specsheet-150515-WEB.pdf>.

TYRVÄINEN, Liisa; SILVENNOINEN, Harri; KOLEHMAINEN, Osmo. Ecological and aesthetic values in urban forest management. **Urban Forestry & Urban Greening**, Urban & Fischer, v. 1, n. 3, p. 135–149, jan. 2003. ISSN 1618-8667. DOI: 10.1078/1618-8667-00014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S161886670470014X>.

VOSS, Matthew; SUGUMARAN, Ramanathan. Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach. **Sensors**, Molecular Diversity Preservation International, Basel, Switzerland, v. 8, n. 5, p. 3020–3036, mai. 2008. ISSN 1424-8220. DOI: 10.3390/s8053020. Disponível em: <http://www.mdpi.com/1424-8220/8/5/3020>.

YAN, Jingli et al. Mapping vegetation functional types in urban areas with WorldView-2 imagery: Integrating object-based classification with phenology. **Urban Forestry & Urban Greening**, v. 31, p. 230–240, abr. 2018. ISSN 16188667. DOI: 10.1016/j.ufug.2018.01.021. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S1618866717300729>.

ZÖLCH, Teresa et al. Regulating urban surface runoff through nature-based solutions – An assessment at the micro-scale. **Environmental Research**, Elsevier Inc., Amsterdam, NL, v. 157, n. 5, p. 135–144, 2017. ISSN 0013-9351. DOI: 10.1016/j.envres.2017.05.023. Disponível em: <http://dx.doi.org/10.1016/j.envres.2017.05.023>.

1 USO DE SENSORIAMENTO REMOTO PARA O MAPEAMENTO DE ESPÉCIES EM FLORESTAS URBANAS, UMA REVISÃO

O mapeamento das espécies arbóreas no ambiente urbano pode fornecer informações importantes para o manejo e análise da diversidade na paisagem. Esta revisão consiste da análise sistemática de artigos coletados por meio de uma busca de publicações sobre sensoriamento remoto em ambiente urbano, com objetivo de mapear espécies ou tipos de vegetação. A revisão faz uma análise dos métodos utilizados nos diferentes trabalhos para a classificação de espécies. Foram analisados 33 trabalhos, sendo que em 23 deles, sobretudo os mais recentes, foi utilizada a abordagem orientada a objetos, principalmente realizando a individualização das copas de árvore. Notou-se que a maior diferença entre os estudos está na extração e teste de diferentes atributos. Além disso, os estudos indicam maior relevância do conjunto de atributos utilizados do que dos diferentes classificadores.

1.1 Introdução

A espacialização e identificação das espécies arbóreas por meio de sensoriamento remoto pode fornecer informações importantes para o manejo e análise da diversidade na paisagem urbana. Os trabalhos envolvendo essa questão são recentes, sobretudo no ambiente urbano, onde existem características peculiares como a quantidade de árvores sombreadas pelas construções e a complexidade inerente dos diversos materiais utilizados na paisagem. Por outro lado, neste ambiente a densidade de árvores é menor, facilitando assim a individualização das árvores. A possibilidade de localizar e individualizar as árvores permite explorar melhor as características dos objetos, o que normalmente resulta em melhores resultados na classificação.

O mapeamento das árvores urbanas com a informação taxonômica consiste em uma informação relevante para o manejo da arborização urbana realizado tanto pelas prefeituras quanto pelas empresas concessionárias de energia. Essa informação permite analisar a diversidade e o risco de ameaças climáticas e doenças, além da possibilidade de predizer o crescimento da árvore e possíveis conflitos com a infraestrutura urbana, ou estimar os possíveis benefícios ambientais trazidos pelas árvores. Isso porque muitos benefícios estão diretamente relacionados às características das espécies como: para interceptação de água da chuva que depende do porte e do índice de área foliar (ZÖLCH et al., 2017); o benefício estético que está relacionado à presença de flores ornamentais ou à sistematização do plantio (SMARDON, 1988; TYRVÄINEN; SILVENNOINEN; KOLEHMAINEN, 2003); valoração das árvore que depende da raridade da espécie no ambiente (SILVA FILHO et al., 2002); redução da poluição, devido a variação específica na emissão de hidrocarbonetos voláteis de origem orgânica (TAHA, 1996).

Apesar de existir uma revisão recente na área de classificação de espécies arbóreas (FASSNACHT et al., 2016), a peculiaridade da área urbana com sombreamento, podas frequentes, restrição do crescimento pelas construções e a menor densidade de árvores em relação ao meio natural, se faz necessária a análise das abordagens utilizadas nos trabalhos realizados nesse ambiente.

Dadas essas questões, o enfoque deste capítulo de revisão será na análise das abordagens utilizadas para a classificação de espécies ou grupos taxonômicos no ambiente urbano, evidenciando os tratamentos específicos utilizados sobre os dados para lidar com as peculiaridades desse ambiente.

Os objetivos dessa revisão são:

1. Analisar a abordagem de estudos que utilizam sensoriamento remoto para classificação de espécies arbóreas ou grupos taxonômicos.

2. Quantificar e determinar os sensores utilizados nesses estudos, verificando tendências nas abordagens para diferentes tipos de sensores.

3. Determinar os principais atributos utilizados para a classificação das espécies.

4. Quantificar e analisar a qualidade dos resultados obtidos pelos classificadores utilizados nos estudos.

5. Identificar lacunas de pesquisa e possíveis tendências para a classificação de espécies arbóreas utilizando sensoriamento remoto.

1.2 Desenvolvimento

1.2.1 Abordagem da revisão

Para a seleção de artigos a serem utilizados neste trabalho foram selecionados trabalhos da base de dados do Web of Knowledge utilizando a pesquisa avançada com os termos: TI=((”Remote Sensing”OR LiDAR OR SAR OR Multispectral OR Hyperspectral OR Image* OR Object*) AND (Vegetation OR Tree* OR Plant* OR Forest*) AND (Map* OR Classif* OR Identi* OR Classif* OR Detect* OR Discriminat* OR Inventor* OR Recogni*) AND (urban OR city OR cities)) AND TS=(Species OR taxon* OR genus OR taxa OR family OR ”vegetation type*”). Dentre os artigos foram escolhidos apenas os que identificaram pelo menos duas espécies ou grupos taxonômicos distintos. A busca resultou em 41 artigos, dos quais foram removidos 8 artigos, pois não tratavam da questão do mapeamento visando discriminar tipos ou espécies arbóreas, restando assim 33 para a análise desta revisão.

A revisão está estruturada em seções para comparação das diferentes abordagens utilizadas nos estudos de maneira geral e nas etapas específicas, conforme padrões identificados neste estudo.

1.2.2 Tendências de publicação

Pode-se notar pela Figura 2.1. que houve uma tendência de crescimento no número de publicações nos anos de 2003-2018. Destaca-se que o artigo mais antigo é de 2003 que sucedeu uma lacuna de cinco anos, além disso, metade se concentra nos últimos quatro anos, o que demonstra o recente desenvolvimento da área. Vale ressaltar que a metodologia da busca utilizada nesta revisão pode ter deixado de encontrar outras referências que trabalharam com a mesma questão.

Quanto à distribuição espacial, existe maior concentração de estudos (25) em cidades de clima temperado, apenas 3 em boreal e 3 em tropical. Os países em que mais aparecem estudos são China e os Estados Unidos da América com 10 cada, no Canadá e França existem 3 artigos em cada e os demais apresentam apenas uma publicação em cada país. São eles: Eslovênia, Lituânia, Irã, Índia, Japão, Indonésia e Malásia. Portanto, mais estudos, sobretudo em cidades tropicais são importantes, pois podem relevar outros desafios que não foram enfrentados e/ou abordados nos três anteriores.

Foram encontrados 22 trabalhos que utilizam apenas imagens multiespectrais, perfazendo 2/3 do total. A metodologia menos comum é a utilização apenas de dados hiperespectrais, com apenas três estudos encontrados. Isso pode ser reflexo da maior dificuldade em se obter imagens de natureza hiperespectral, e a menor viabilidade prática para mapear grandes áreas devido à necessidade de voar a altitudes mais baixas para atingir a mesma resolução espacial. E.g. Mozgeris et al. (2016) obtiveram os dados com um sobrevoo a altitude média de 1000m coletando simultaneamente dados multiespectrais e hiperespectrais, resultando em resoluções de 0.17m e 0.6m respectivamente. Além disso, com a disponibilização de satélites de altíssima resolução espacial de 2 metros ou menos, em 1999 com o satélite IKONOS e em 2009 pelo satélite Worldview-2, viabilizou-se o uso a preços mais acessíveis e em áreas amplas de até 6598 km² (ZHANG; FENG; JIANG, 2010; CAVAYAS; RAMOS; BOYER, 2012; LI, F.

Figura 1.1. Frequência de estudos entre 2003 a 2018. Os valores das linhas referentes ao uso de dados Hiperespectral e Combinado (Imagem + LiDAR) e tiveram um deslocamento em y de 0.15 e 0.3 respectivamente para melhorar a leitura.

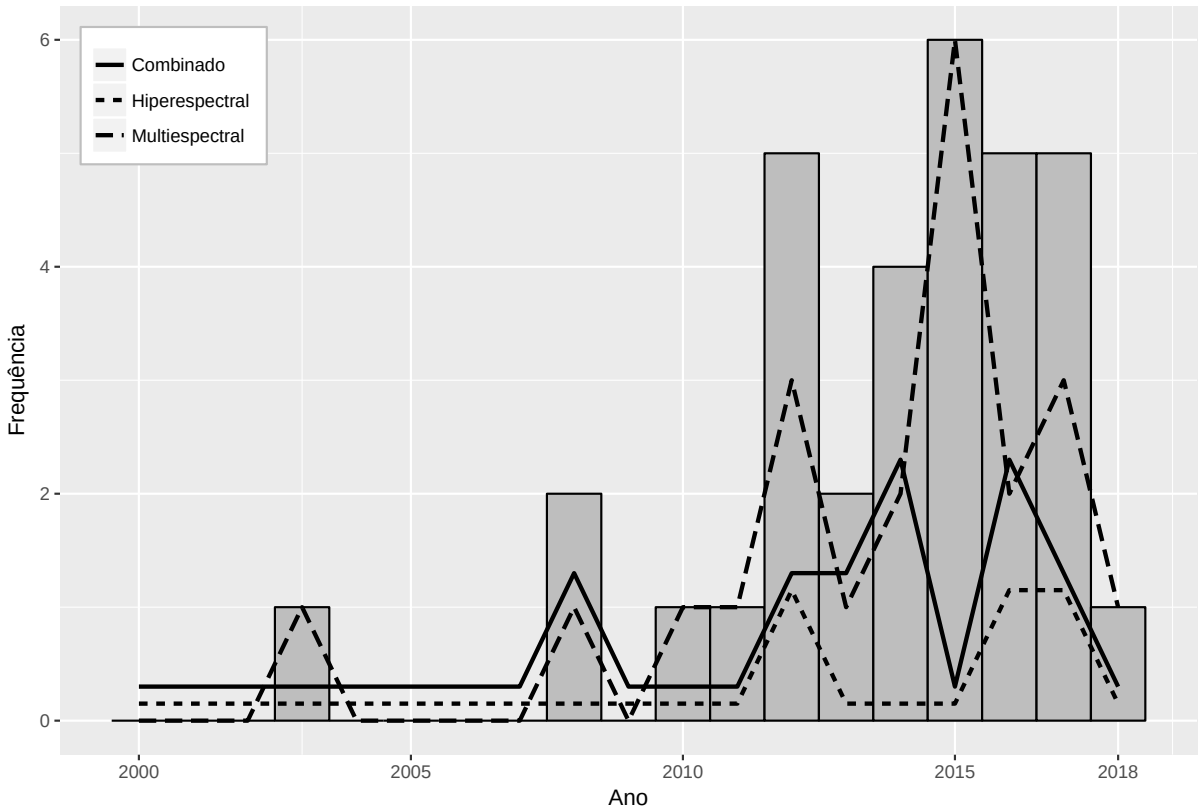

et al., 2015). Apenas 3 estudos utilizavam exclusivamente imagens hiperespectrais ou comparando-as com imagens multiespectrais e apenas 7 considerados utilizam o LiDAR sempre em conjunto com imagens.

1.2.3 Abordagens para classificação

Dependendo dos dados de sensoriamento remoto utilizados a abordagem para classificação segue alguns padrões, ainda assim, todas as metodologias seguem algumas etapas definidas com pequenas variantes, são elas: pré-tratamento dos dados, tratamento dos dados para extração de atributos, seleção de atributos, aquisição de amostras, classificação supervisionada, aferimento da qualidade dos resultados. Podemos agrupar as abordagens em três classes distintas: por pixel (PIXEL), baseada em objetos por segmentação (SEG), baseada em objetos por individualização das árvores (ITD, do acrônimo em inglês *individual tree crown delineation*).

O artigo mais antigo encontrado foi do ano de 2003 (SUGUMARAN; PAVULURI; ZERR, 2003), utilizando a abordagem de classificação por pixel (PIXEL). Nesse tipo de abordagem, a unidade de análise para o classificador consiste em cada pixel da imagem do sensoriamento remoto, isso não significa que os atributos estejam restritos aos valores espectrais da imagem. Além dos atributos espectrais da imagem é possível a derivação de outros dados matriciais que podem ser calculados por meio de índices relativos aos dados espectrais (PU, 2011; YU; LI; ZHANG, 2015; TRISAKTI, 2017), ou ainda podem ser derivados das matrizes de ocorrência e co-ocorrência, extraindo-se atributos texturais que retratam os padrões de repetição dos dados em uma vizinhança (PU, 2011; KUKUNDA et al., 2017).

A segunda forma de classificação, encontrada pela primeira vez em 2008 (VOSS; SUGUMA-

RAN, 2008; LE LOUARN et al., 2017), utiliza a abordagem baseada em objetos (SEG). Nesse formato, a unidade de análise utilizada pelo classificador são objetos, ou agrupamentos de pixels que normalmente são obtidos por meio de algoritmos segmentadores automáticos, que divide a imagem em regiões, nem sempre correspondendo a um único objeto de interesse. Essa abordagem permite agregar os dados por diferentes estatísticas com a extração de diversos atributos (ZHANG; FENG; JIANG, 2010; LI, D. et al., 2014; YAN et al., 2018).

A terceira abordagem de classificação, também é baseada em objetos, mas visa individualizar as árvores (ITD). Esse tipo de classificação possui a vantagem de possibitar a extração de informações a respeito da arquitetura da copa da árvore, seja utilizando métricas da geometria dos polígonos das copas, ou derivados de dados de LiDAR. Ademais é possível a análise textural mais significativa uma vez que a vizinhança para comparação não é uma janela quadrada arbitrária, mas analisados quanto aos pixels referentes à copa da árvore em questão (IOVAN; BOLDO; CORD, 2008).

1.2.4 Pré-tratamento de dados

O pré-tratamento dos dados envolve certas categorias de processamento realizadas sobre os dados brutos para torná-los mais próximos das medições reais corrigindo as distorções, sejam elas causadas por interferência do ambiente ou decorrentes dos sensores. A tabela 1.1 sintetiza o processamento realizado sobre as imagens.

Tabela 1.1. Tabela demonstrando a quantidade de trabalhos que realizam os diferente pré-tratamentos de dados de imagem

Tratamento	Quantidade
Correção atmosférica	18
Fusão pancromática	8
Retificação e correção geométrica	11

Dentre as formas de pré-tratamento de imagens, a mais comum é a correção atmosférica, o que é interessante, pois segundo Pu, Landry e Zhang (2015), que realizaram um estudo comparativo entre os algoritmos para correção atmosférica, não há a necessidade de se realizar essa etapa de processamento para o satélite Worldview-2, pois não houve diferença significativa nos resultados por eles obtidos.

A correção atmosférica visa remover o ruído dos dados causado pela interferência atmosférica e quanto a posição do Sol e do sensor em relação ao alvo, além de reajustar os valores digitais para reflectância (KRUSE; BAUGH; PERRY, 2015). Esse procedimento é importante para realizar o mosaico de diferentes cenas, para análises multitemporais e para compatibilização e comparação de dados entre diferentes sensores.

Quanto às transformações disponíveis, os resultados obtidos por Pu, Landry e Zhang (2015) demonstraram que apenas a conversão direta dos números digitais para reflectância ao topo da atmosfera resultaram em valores mais próximos dos medidos *in situ* mesmo sem considerar a interferência atmosférica por aerossóis, o que pode ter ocorrido devido às imagens utilizadas apresentarem poucos aerossóis na época da aquisição, caso contrário a correção atmosférica por modelos mais complexos deve apresentar maior relevância.

1.2.4.1 Fusão com a banda pancromática

A fusão com a banda pancromática (*pansharpening*, em inglês), por outro lado, se mostra uma técnica importante para a qualidade dos resultados de classificação conforme discutido por Pu e Landry (2012). Esse procedimento visa melhorar a resolução espacial das bandas multiespectrais utilizando

diferentes métodos para realizar a fusão com a banda pancromática de melhor resolução espacial. Ainda que a fusão pancromática cause distorção espectral, a técnica permite melhor discriminação dos diferentes objetos, especialmente em áreas urbanas em que temos uma paisagem com alta heterogeneidade de materiais.

Tendo em vista a minimização da distorção espectral, diversos algoritmos foram propostos. Dentre os algoritmos existentes, Li, Jing e Tang (2017) testam diversos deles em ambiente urbano e demonstram que os algoritmos que apresentam os melhores resultados são os propostos por Aiazzi, Baronti e Selva (2007) (GSA), Jing e Cheng (2009) (HR) e Aiazzi et al. (2006) (GLP_ESDM e GLP_ECBD).

De maneira geral, os algoritmos de fusão com a banda pancromática operam da seguinte forma:

1. Derivação de banda pancromática sintética (PAN_s): a banda PAN_s pode ser derivada com base nas bandas multiespectrais (MS) ou da própria banda pancromática original (PAN).

2. Reamostragem das banda multiespectrais: processo para compatibilizar a resolução da banda MS utilizando a reamostragem pelo vizinho mais próximo, obtendo a banda $\widetilde{MS}$ de mesma resolução da PAN.

3. Cálculo da relação entre as bandas PAN e PAN_s (C_{PAN}): essa relação entre as bandas PAN e PAN_s servirá de base para corrigir os valores de ($\widetilde{MS}$).

4. Calcular os valores da banda multiespectral fusionada ($\widehat{MS}$): os valores de $\widetilde{MS}$ são ajustados com base na relação entre $\widetilde{MS}$, quanto maior a correlação entre as bandas pancromáticas e a banda multiespectral maior será o ganho, pois C_{PAN} tem maior poder de predizer $\widetilde{MS}$.

Os diferentes algoritmos apresentam apenas variações nas formas de calcular as etapas mencionadas. O GSA, acrônimo de *Gram-Schmidt* adaptativo, propõe uma modificação em relação ao Gram-Schmidt original (GS) (CRAIG A. LABEN; BERNARD V. BROWER, 1998). Este último deriva a banda PAN_s utilizando uma entre as duas opções: 1) Média simples entre todas as bandas MS reamostrado pelo vizinho mais próximo para a resolução de PAN; 2) Filtro passa-baixa sobre a banda PAN. O GSA, por sua vez, calcula PAN_s pela média ponderada entre as bandas MS calculando os pesos pela solução que minimiza o erro quadrático médio (MSE, do inglês *mean square error*) entre a banda calculada e a PAN original.

Depois da reamostragem de MS pelo vizinho mais próximo, as médias das bandas $\widetilde{MS}$ são subtraídas de cada pixel e então passam pela transformação Gram-Schmidt. A transformação Gram-Schmidt realiza a ortogonalização do vetor de dados das bandas e remove informações redundantes, de forma análoga à transformação realizada pela análise de componentes principais (PCA). Cada componente GS é calculado com base nas bandas GS anteriores, e é dado por:

$$GS_T(i,j) = (B_T(i,j) - \mu_T) - \sum_{I=1}^{T-1} \phi(B_T, GS_I) \cdot GS_I(i,j) \tag{1}$$

Para,

- T: índice da banda

- B_T: vetor do conjunto das bandas PAN_s e $\widetilde{MS}$, sendo que B_1 representa a banda PAN_s seguido das bandas multiespectrais.

- μ_T: média da banda T

- $\phi(B_T, GS_I)$: é a função de cálculo do ganho entre B_T e GS_I.

- GS_I: componente GS para o índice I do somatório.

A função de ganho $\phi(B_T, GS_I)$ é calculada por:

$$\phi(B_T, GS_I) = \frac{\sigma(B_T, GS_I)}{\sigma^2_{GS_I}} \tag{2}$$

Onde $\sigma(B_T, GS_I)$ representa a covariância entre B_T e GS_I, e $\sigma^2_{GS_I}$ a variância de GS_I.

No GS e GSA, a relação entre as bandas pancromáticas é estabelecida realizando a equalização do histograma de PAN para μ e σ da banda sintética PAN_s, utilizando a seguinte equação:

$$PAN_{hist} = (PAN - \mu_{PAN})\frac{\sigma_{PAN_s}}{\sigma_{PAN}} + \mu_{PAN_s} \tag{3}$$

Para obter as bandas fusionadas, aplica-se a função inversa da equação 1, isolando B_T e usando a banda pancromática original com histograma equalizado PAN_{hist} no lugar de PAN_s como a primeira banda B_1. Temos a seguinte equação:

$$B_T(i,j) = (GS_T(i,j) + \mu_T) + \sum_{I=1}^{T-1} \phi(B_T, GS_I) \cdot GS_I(i,j) \tag{4}$$

Li, Jing e Tang (2017) demonstram que o GSA possui vantagem sobre o GS, reduzindo as distorções espectrais causadas pelas bandas multiespectrais do WorldView-2 menos correlacionadas com a banda pancromática como as bandas de infravermelho próximo e azul costal. Essas bandas menos correlacionadas obtêm peso baixo na modelagem por GSA, enquanto GS sempre atribui peso igual.

O método HR, acrônimo de *Haze and Ratio*, utiliza uma abordagem bastante simples incorporando o efeito da névoa nos cálculos. Para determinar o efeito da névoa utiliza-se o método o objeto mais escuro da imagem, subtraindo o valor do pixel de menor valor para cada banda. O efeito de névoa pode ter grande interferência nos resultados da fusão pancromática, e muitos algoritmos não levam o efeito em consideração (JING; CHENG, 2009).

Inicialmente o HR deriva a banda pancromática sintética PAN_s utilizando uma reamostragem com base na média dos valores de pixels da banda PAN, agregando-os para corresponder aos pixels de resolução mais baixa das bandas MS. Em seguida essa banda é reamostrada novamente para a resolução de PAN utilizando interpolação bicúbica. A mesma reamostragem bicúbica é realizada para as bandas MS compatibilizando a resolução de todos os dados (JING; CHENG, 2009). As bandas fusionadas podem ser então calculadas pela equação 5 de acordo com a metodologia proposta:

$$\widehat{MS}_T = (\widetilde{MS}_T - h_T)\frac{PAN - h_{PAN}}{PAN_s - h_{PAN}} + h_T s \tag{5}$$

Onde,

- $\widetilde{MS}_T$: a banda multiespectral reamostrada para a resolução de PAN.
- h_T: efeito névoa da banda MS_T
- h_{PAN}: efeito névoa da banda PAN

No HR a relação entre a banda pancromática original e a sintética é comparada apenas pela razão entre as duas, removendo o efeito da névoa. Ainda que não utilize qualquer correção em relação às correlações entre a banda pancromática e as bandas multiespectrais, o HR apresentou bom desempenho nas análises de Li, Jing e Tang (2017), o que indica que a interferência atmosférica tem grande impacto na fusão.

Os outros dois algoritmo que apresentaram bom desempenho utilizam métodos GLP, acrônimo para *Generalized Laplacian Pyramid*. Essa abordagem faz o uso das características da função modulação

de transferência (MTF, *Modulation Transfer Function*) para melhorar os detalhes espaciais. A MTF é uma função utilizada para descrever o desempenho de sensores e pode ser entendida como a atenuação da amplitude do sinal (constraste) em função da frequência espacial (tamanho do objeto). I.e. o contraste de objetos pequenos tende a ser atenuado, assim como ocorre nos limites entre objetos com contrastes diferentes. Sabendo qual o comportamento da MTF para o sistema é possível corrigir a imagem e melhorar os detalhes espaciais perdidos em decorrência das características sensor e dos efeitos atmosféricos (KUMAR; KARTIKEYAN; MAJUMDAR, 2000).

Como banda sintética (PAN_s), o GLP utiliza a reamostragem reduzida da banda PAN ajustada pela MTF e posterior reamostragem retornando à resolução original por meio de um filtro de expansão ideal. As variantes ESDM (*enhanced spectral distortion minimizing*) e ECDB (*enhanced context-based decision*) utilizam diferentes modelos para calcular o ganho que será injetado em cada banda a partir da diferença entre PAN_s e PAN.

O ESDM calcula o ganho pela razão entre $\widetilde{MS}$ e PAN_s ajustada pela média do desvio padrão local médio das bandas $\widetilde{MS}$ em relação ao PAN_s, pela seguinte equação:

$$ganho_T(i,j) = \beta(i,j)\frac{\widetilde{MS}_T}{PAN_s(i,j)} \tag{6}$$

Onde $\beta(i,j)$ é a função de ajuste pela média do desvio padrão local, definida por:

$$\beta(i,j) = \sqrt{\frac{\frac{1}{N}\sum_{k=1}^{N} var\left[\widetilde{MS}_k\right](i,j)}{var\left[PAN_s\right](i,j)}} \tag{7}$$

O GLP baseado em ECDB, por outro lado, utiliza um modelo condicional na qual se a correlação entre $\widetilde{MS}$ e PAN_s for menor que o o limiar θ o ganho da banda passa a ser 0, i.e. não se realiza a fusão do pixel evitando a distorção espectral, já que não há correlação suficiente. A equação é definida como:

$$ganho_T(i,j) = \begin{cases} \text{mínimo}\left(\frac{\sigma_{\widetilde{MS}_T}(i,j)}{\sigma PAN_s(i,j)}, c\right), & \text{se } \rho_T(i,j) \geq \theta_T \\ 0, & \textit{senão} \end{cases} \tag{8}$$

Onde $\rho_T(i,j)$ representa o coeficiente de correlação entre $\widetilde{MS}_T$ e as variâncias das bandas são calculada pela janela deslizante de tamanho $L \times L$ centralizada no pixel (i,j) (AIAZZI; BARONTI; SELVA, 2007). Ambos os métodos GLP analisam os desvios locais por subjanelas e não apenas os globais, o que permite que o algoritmo se adapte as dissimilaridades locais dependendo dos tipos de uso de solo e das transições encontradas na imagem.

Li, Jing e Tang (2017) demonstram que o os algoritmos GLP_ESDM e GLP_ECDB (AIAZZI; BARONTI; SELVA, 2007) conseguem preservar mais a informação entre bandas para o cálculo de índices como NDVI e NDWI, justamente em decorrência do uso das dissimilaridades locais, portanto sendo mais recomendadas para aplicações que analisem a vegetação.

Contudo, apesar de esses algoritmos terem sido propostos em 2007 eles não foram utilizados pelos estudos aqui considerados, sendo o Gram-Schimidt não adaptativo o mais utilizado (CRAIG A. LABEN; BERNARD V. BROWER, 1998). Isso pode se justificar por ser a implementação mais comum ocorrendo em diversos softwares. É importante notar que o procedimento não faz sentido para dados hiperespectrais ou em bandas do infravermelho curto (SWIR), pois ocorreria distorção no comportamento espectral. O satélite Worldview-3, por exemplo, captura a banda pancromática na faixa de 450-800nm de comprimento de onda, enquanto que as bandas SWIR capturam o espectro fora da faixa pancromática no intervalo de 1195-2365nm, portanto sem correspondência direta (DIGITALGLOBE, 2014).

1.2.4.2 Correção geométrica

A retificação ou correção geométrica foi realizada em 11 estudos, esse procedimento por vezes é realizado pelo próprio distribuidor das imagens e visa corrigir distorções na imagem causadas pela lente ou, no caso da ortorretificação, pela perspectiva da aquisição; ela pode ser realizada por meios automáticos, com base em dados de distorção do sensor, por pontos de controle e/ou ainda por ortorretificação, utilizando-se os metadados como ângulo zênite do sensor e dados de elevação que podem ser derivados de estéreo imagens. A retificação dos dados é essencial quando desejamos realizar a fusão de dados, compatibilizando diferentes fontes como LiDAR e multiespectral.

1.2.5 Segmentação

Essa etapa não é necessária para a classificação por pixel (10 trabalhos). A segmentação, ou individualização das copas de árvores pode ser realizada de forma manual (6 trabalhos) ou de forma automática (18 trabalhos). Embora para grandes áreas o delineamento manual não seja prático, esse método é comum em estudos para reduzir o erro que seria introduzido pelo algoritmo de segmentação automático, dessa forma é possível separar os erros e trabalhar com a segmentação ótima, ajustando o modelo classifcador para o resultado ideal em vez de ajustá-lo para dados com erro.

Conforme discutido anteriormente existem dois tipos diferentes de análise orientada a objetos, na primeira ocorre a segmentação em nível de raster, onde os segmentos não representam necessariamente copas de árvores individuais (SEG), e na segunda abordagem se efetua a individualização das copas de árvores (ITD, do inglês *Individual Tree crown Delineation*).

Quando se usa a abordagem SEG (13 trabalhos) utiliza-se algoritmos de segmentação como crescimento de regiões ou outros como o algoritmo de Baatz e Schäpe (2000). A abordagem SEG não visa individualizar as copas de árvores em si, portanto neste tipo de abordagem é comum que copas de árvores sejam agrupadas, impossibilitando a identificação dos indivíduos separadamente se pertencerem a diferentes taxa.

Na abordagem ITD todos os estudos, exceto Zhang e Qiu (2012), utilizaram métodos de individualização baseado no modelo de altura do dossel (CHM, *canopy height model*). Além de derivar o CHM, os métodos raster precisam definir pontos que determinam os locais das copas de árvores, denominado de sementes, a partir dos quais se delimitará o segmento da copa da árvore, para então aplicar o algoritmo de segmentação. Normalmente as sementes são determinadas por algoritmos que buscam encontrar o topo das árvores, sendo que o mais comum (4 estudos) foram os algoritmos de máxima local, os quais utilizam janelas deslizantes de busca (LIU et al., 2017a; ZHANG et al., 2016; ALONZO; BOOKHAGEN; ROBERTS, 2014; ZHANG; QIU, 2012).

A outra abordagem utilizou-se apenas dos limiares de NDVI e separadamente índice de verde (GI), filtrando e combinando os dois produtos (ZHANG; QIU, 2012). Esse tipo de metodologia não funciona bem para locais com maciços de árvores no qual as copas não são divididas por outro tipo de uso do solo.

No ITD as copas de árvores são idealmente individualizadas possibilitando assim a identificação do indivíduo e a extração de informações sobre a forma da copa. Além disso, por meio da nuvem de pontos é possível derivar dados biométricos da árvore como diâmetro da copa e altura. Embora os erros de subsegmentação e supersegmentação sejam comuns, nem sempre a qualidade dos resultados é informada detalhadamente, restrigindo-se por vezes apenas à contagem de segmentos em relação ao número de árvores identificadas em campo ou então à inspeção visual.

1.2.6 Extração de atributos

A extração de atributos derivados dos dados originais permite a análise de características que não são evidentes ao se utilizar apenas os dados brutos ou pré-tratados. Na análise por pixel, a extração de atributos foi considerada como o processo de derivar novos atributos com base em métricas como diferenças normalizadas, textura, análise de componentes principais, dentre outras.

Para o LiDAR, a extração pode compatibilizar os atributos para o mesmo vetor utilizado pelas imagens, agrupando-os em grades na análise por pixel, por exemplo. Por outro lado, na análise baseada em objetos a extração dos atributos sumariza os dados para cada objeto, sejam eles resultados da segmentação ou individualização das copas de árvores.

Nesse ponto, apenas 2 estudos não apresentaram tratamento para extração de novos atributos. Esses trabalhos discriminam poucas classes de tipos de vegetação, portanto necessitam de poucos atributos para obter os resultados desejados (SUGUMARAN; PAVULURI; ZERR, 2003; DOKO et al., 2014).

Essa é a etapa que mais se diferencia entre os artigos revisados, também é a que traz maior novidade. A tabela 1.2 demonstra os diferentes atributos utilizados pelos trabalhos.

Tabela 1.2. Tabela de atributos extraídos da nuvem de pontos do .

Origem	Tipo	Métrica	Qde	Referências
Hiperespectral	Componentes Principais	CDA	1	Alonzo, Bookhagen e Roberts (2014)
Hiperespectral	Componentes Principais	LDA	1	Alonzo, Bookhagen e Roberts (2014)
Hiperespectral	Componentes Principais	MNF	4	Dian et al. (2016), Zhang et al. (2016), Voss e Sugumaran (2008) e Sugumaran e Voss (2007)
Hiperespectral	Componentes Principais	PCA	5	Launeau et al. (2017), Liu et al. (2017a), Zhang et al. (2016), Alonzo, Roth e Roberts (2013) e Jensen, Hardin e Hardin (2012)
Hiperespectral	Componentes Principais	SDA	1	Alonzo, Roth e Roberts (2013)
Hiperespectral	Espectral	Bandas	4	Liu et al. (2017a), Alonzo, Roth e Roberts (2013), Jensen, Hardin e Hardin (2012) e Zhang e Qiu (2012)
Hiperespectral	Multi	Vog_a	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	Vog_b	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	Vog_c	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	CI	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	EVI	1	Dian et al. (2016)
Hiperespectral	Multi	GMI	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	NDI	1	Liu et al. (2017a)
Hiperespectral	Multi	NDIs	1	Launeau et al. (2017)
Hiperespectral	Multi	NDVI	2	Liu et al. (2017a) e Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	RESP	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	RI1	1	Jensen, Hardin e Hardin (2012)
Hiperespectral	Multi	RI2	1	Jensen, Hardin e Hardin (2012)

LiDAR	Espacial	DSM	1	Iovan, Boldo e Cord (2008)
LiDAR	Espacial	Elevação	1	Sugumaran e Voss (2007)
LiDAR	Espectral	Intensidade	2	Liu et al. (2017a) e Alonzo, Bookhagen e Roberts (2014)
LiDAR	Estrutural	Altura	2	Liu et al. (2017a) e Alonzo, Bookhagen e Roberts (2014)
LiDAR	Estrutural	CD	1	Liu et al. (2017a)
LiDAR	Estrutural	CL/CW	1	Liu et al. (2017a)
LiDAR	Estrutural	CL/H	2	Liu et al. (2017a) e Alonzo, Bookhagen e Roberts (2014)
LiDAR	Estrutural	CW/H	1	Alonzo, Bookhagen e Roberts (2014)
LiDAR	Estrutural	CW_25/CW_50	1	Liu et al. (2017a)
LiDAR	Estrutural	CW_75/CW_50	1	Liu et al. (2017a)
LiDAR	Estrutural	HQR	1	Liu et al. (2017a)
LiDAR	Estrutural	Largura da copa multipla	1	Alonzo, Bookhagen e Roberts (2014)
LiDAR	Estrutural	Percentis Altura	1	Liu et al. (2017a)
LiDAR	Estrutural	Razão CW NS/CW LO	1	Alonzo, Bookhagen e Roberts (2014)
LiDAR	Estrutural	Retornos fatia 0,5 m p90/CW	1	Alonzo, Bookhagen e Roberts (2014)
LiDAR	Espectral	Intensidade	1	Sugumaran e Voss (2007)
Multiespectral	Componentes Principais	PCA	5	Le Louarn et al. (2017), Dan Li et al. (2015), Yu, Li e Zhang (2015), Verlic et al. (2014) e Zhang, Feng e Jiang (2010)
Multiespectral	Espectral	Bandas	17	Yan et al. (2018), Trisakti (2017), Mozgeris et al. (2016), Shojanoori et al. (2016), Dan Li et al. (2015), Pu, Landry e Zhang (2015), Yu, Li e Zhang (2015), Doko et al. (2014), Dan Li et al. (2014), Verlic et al. (2014), Agarwal et al. (2013), Pu e Landry (2012), Pu (2011), Iovan, Boldo e Cord (2008), Sugumaran e Voss (2007) e Sugumaran, Pavuluri e Zerr (2003)
Multiespectral	Espectral	Densidade bandas	1	Zhou et al. (2016)
Multiespectral	Espectral	HSV	1	Pu e Landry (2012)
Multiespectral	Espectral	Razão	2	Yan et al. (2018) e Dan Li et al. (2014)
Multiespectral	Forma	Área	2	Yan et al. (2018) e Shojanoori et al. (2016)
Multiespectral	Forma	Assimetria	1	Yan et al. (2018)
Multiespectral	Forma	Compactação	2	Yan et al. (2018) e Shojanoori et al. (2016)
Multiespectral	Forma	Comprimento	1	Yan et al. (2018)
Multiespectral	Forma	Comprimento/Largura	1	Yan et al. (2018)
Multiespectral	Forma	Densidade	1	Yan et al. (2018)

Multiespectral	Forma	Densidade de esqueletos	1	Kukunda et al. (2017)
Multiespectral	Forma	Fit Elíptico	1	Yan et al. (2018)
Multiespectral	Forma	Índice de circularidade	1	Shojanoori et al. (2016)
Multiespectral	Forma	Índice de forma	2	Yan et al. (2018) e Shojanoori et al. (2016)
Multiespectral	Forma	Largura	1	Yan et al. (2018)
Multiespectral	Forma	Largura máxima	1	Shojanoori et al. (2016)
Multiespectral	Forma	Retangularidade	2	Yan et al. (2018) e Shojanoori et al. (2016)
Multiespectral	Forma	Solidez	1	Shojanoori et al. (2016)
Multiespectral	Índice de vegetação	NDVI	1	Zhang, Feng e Jiang (2010)
Multiespectral	Multi	Brilho	2	Yan et al. (2018) e Agarwal et al. (2013)
Multiespectral	Multi	Densidade NDSV	1	Kukunda et al. (2017)
Multiespectral	Multi	Densidade NDVI	2	Zhou et al. (2016) e Kukunda et al. (2017)
Multiespectral	Multi	Densidade vegetação NDVI	1	Kukunda et al. (2017)
Multiespectral	Multi	NDSV	1	Zhou et al. (2016)
Multiespectral	Multi	NDVI	12	Yan et al. (2018), Le Louarn et al. (2017), Trisakti (2017), Shojanoori et al. (2016), Dan Li et al. (2015), Mustafa et al. (2015), Pu, Landry e Zhang (2015), Dan Li et al. (2014), Agarwal et al. (2013), Cavayas, Ramos e Boyer (2012) e Pu e Landry (2012)
Multiespectral	Multi	Razão	4	Shojanoori et al. (2016), Dan Li et al. (2015), Pu e Landry (2012) e Zhang, Feng e Jiang (2010)
Multiespectral	Multi	SAVI	1	Pu (2011)
Multiespectral	Multi	SI	1	Mustafa et al. (2015)
Multiespectral	Multi	Vector orientation	1	Cavayas, Ramos e Boyer (2012)
Multiespectral	Multi	VEVI	1	Wen et al. (2017)
Multiespectral	Textura	Amplitude	1	Shojanoori et al. (2016)
Multiespectral	Textura	ASM	2	Dan Li et al. (2015, 2014)
Multiespectral	Textura	Contraste	3	Wen et al. (2017) e Dan Li et al. (2015, 2014)
Multiespectral	Textura	Correlação	2	Dan Li et al. (2015, 2014)
Multiespectral	Textura	Densidade de brilho	1	Kukunda et al. (2017)
Multiespectral	Textura	Densidade de cantos	1	Kukunda et al. (2017)

Multiespectral	Textura	Densidade de detalhes escuros	1	Kukunda et al. (2017)
Multiespectral	Textura	Densidade de ondulação	1	Kukunda et al. (2017)
Multiespectral	Textura	Desnidade de elementos similares	1	Zhou et al. (2016)
Multiespectral	Textura	Desvio padrão	2	Dan Li et al. (2015, 2014)
Multiespectral	Textura	Dissimilaridade	2	Dan Li et al. (2015, 2014)
Multiespectral	Textura	Entropia	4	Wen et al. (2017), Shojanoori et al. (2016) e Dan Li et al. (2015, 2014)
Multiespectral	Textura	Gradiente de cinza relativo	1	Kukunda et al. (2017)
Multiespectral	Textura	Homogeneidade	3	Wen et al. (2017) e Dan Li et al. (2015, 2014)
Multiespectral	Textura	Média	2	Shojanoori et al. (2016) e Dan Li et al. (2015)
Multiespectral	Textura	Ordenação	1	Wen et al. (2017)
Multiespectral	Textural	Entropia	1	Mustafa et al. (2015)
Multiespectral	Textural	Homogeneidade	1	Mustafa et al. (2015)
Pancromática	Textura	Amplitude	1	Iovan, Boldo e Cord (2008)
Pancromática	Textura	ASM	3	Yan et al. (2018), Pu e Landry (2012), Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	Cluster Prominence	1	Le Louarn et al. (2017)
Pancromática	Textura	Cluster Shade	1	Le Louarn et al. (2017)
Pancromática	Textura	Contraste	3	Yan et al. (2018), Pu e Landry (2012) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	Correlação	4	Le Louarn et al. (2017), Pu e Landry (2012), Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	Correlação de Haralick	1	Le Louarn et al. (2017)
Pancromática	Textura	Desvio padrão	3	Pu e Landry (2012), Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	Dissimilaridade	4	Yan et al. (2018), Le Louarn et al. (2017), Pu e Landry (2012) e Zhang, Feng e Jiang (2010)
Pancromática	Textura	Entropia	5	Yan et al. (2018), Le Louarn et al. (2017), Pu e Landry (2012), Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	GLCM	1	Pu (2011)
Pancromática	Textura	Homogeneidade	3	Yan et al. (2018), Pu e Landry (2012) e Zhang, Feng e Jiang (2010)
Pancromática	Textura	IDM	1	Iovan, Boldo e Cord (2008)

Pancromática	Textura	Informação da Correlação	1	Le Louarn et al. (2017)
Pancromática	Textura	Média	1	Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	Soma da Variância	1	Le Louarn et al. (2017)
RGB	Espectral	HSI	1	Yan et al. (2018)
RGB	Espectral	HSV	4	Shojanoori et al. (2016), Dan Li et al. (2014), Pu (2011) e Iovan, Boldo e Cord (2008)
RGB	Espectral	LAB	1	Iovan, Boldo e Cord (2008)
RGB	Espectral	XYZ	1	Iovan, Boldo e Cord (2008)
RGB	Textura	Textura	1	Iovan, Boldo e Cord (2008)
Segmentos	Forma	Brilho	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Compact	1	Pu e Landry (2012)
Segmentos	Forma	CompactP	1	Pu e Landry (2012)
Segmentos	Forma	FD	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Índice de forma	2	Pu e Landry (2012) e Zhang, Feng e Jiang (2010)
Segmentos	Forma	Location	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	LW	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Máxima diferença	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Número de arestas	1	Pu e Landry (2012)
Segmentos	Forma	Razão	1	Zhang, Feng e Jiang (2010)
Temporal	Multi	Filtro S-G	1	Dan Li et al. (2015)
Multiespectral	Textura	Desnidade de elementos similares	1	Zhou et al. (2016)
Multiespectral	Textura	Dissimilaridade	1	Dan Li et al. (2015)
Multiespectral	Textura	Entropia	1	Dan Li et al. (2015)
Multiespectral	Multi	Vector orientation	1	Cavayas, Ramos e Boyer (2012)
Multiespectral	Textura	Entropia	1	Dan Li et al. (2014)
Multiespectral	Textura	Homogeneidade	1	Dan Li et al. (2015)
Multiespectral	Textural	Entropia	1	Mustafa et al. (2015)
Multiespectral	Multi	NDVI	1	Pu e Landry (2012)
Multiespectral	Multi	Razão	1	Pu e Landry (2012)
Multiespectral	Componentes Principais	PCA	1	Zhang, Feng e Jiang (2010)
Multiespectral	Multi	Razão	1	Zhang, Feng e Jiang (2010)
Multiespectral	Espectral	Bandas	1	Iovan, Boldo e Cord (2008)
Pancromática	Textura	Correlação	3	Le Louarn et al. (2017), Pu e Landry (2012) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	ASM	2	Pu e Landry (2012), Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)

Pancromática	Textura	Contraste	2	Yan et al. (2018) e Pu e Landry (2012)
Pancromática	Textura	Entropia	2	Le Louarn et al. (2017) e Pu e Landry (2012)
Pancromática	Textura	Entropia	2	Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
Pancromática	Textura	Homogeneidade	2	Yan et al. (2018) e Zhang, Feng e Jiang (2010)
Pancromática	Textura	ASM	1	Yan et al. (2018)
Pancromática	Textura	Cluster Prominence	1	Le Louarn et al. (2017)
Pancromática	Textura	Soma da Variância	1	Le Louarn et al. (2017)
Pancromática	Textura	Cluster Shade	1	Le Louarn et al. (2017)
Pancromática	Textura	Desvio padrão	1	Pu e Landry (2012)
Pancromática	Textura	Dissimilaridade	1	Pu e Landry (2012)
Pancromática	Textura	Correlação de Haralick	1	Le Louarn et al. (2017)
Pancromática	Textura	Homogeneidade	1	Pu e Landry (2012)
Pancromática	Textura	Desvio padrão	1	Iovan, Boldo e Cord (2008)
Pancromática	Textura	Dissimilaridade	1	Yan et al. (2018)
Pancromática	Textura	Dissimilaridade	1	Le Louarn et al. (2017)
Pancromática	Textura	GLCM	1	Pu (2011)
Pancromática	Textura	Entropia	1	Yan et al. (2018)
Pancromática	Textura	Correlação	1	Zhang, Feng e Jiang (2010)
Pancromática	Textura	Desvio padrão	1	Zhang, Feng e Jiang (2010)
Pancromática	Textura	Dissimilaridade	1	Zhang, Feng e Jiang (2010)
Pancromática	Textura	IDM	1	Iovan, Boldo e Cord (2008)
Pancromática	Textura	Informação da Correlação	1	Le Louarn et al. (2017)
Pancromática	Textura	Amplitude	1	Iovan, Boldo e Cord (2008)
Pancromática	Textura	Contraste	1	Iovan, Boldo e Cord (2008)
Pancromática	Textura	Média	1	Zhang, Feng e Jiang (2010) e Iovan, Boldo e Cord (2008)
RGB	Espectral	HSV	2	Dan Li et al. (2014) e Iovan, Boldo e Cord (2008)
RGB	Espectral	HSV	1	Shojanoori et al. (2016)
RGB	Espectral	HSV	1	Pu (2011)
RGB	Espectral	HSI	1	Yan et al. (2018)
RGB	Espectral	LAB	1	Iovan, Boldo e Cord (2008)
RGB	Espectral	XYZ	1	Iovan, Boldo e Cord (2008)
RGB	Textura	Textura	1	Iovan, Boldo e Cord (2008)
Segmentos	Forma	Compact	1	Pu e Landry (2012)
Segmentos	Forma	CompactP	1	Pu e Landry (2012)
Segmentos	Forma	Brilho	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	FD	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Índice de forma	1	Pu e Landry (2012)
Segmentos	Forma	Índice de forma	1	Zhang, Feng e Jiang (2010)

Segmentos	Forma	Localização	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	LW	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Máxima diferença	1	Zhang, Feng e Jiang (2010)
Segmentos	Forma	Número de arestas	1	Pu e Landry (2012)
Segmentos	Forma	Razão	1	Zhang, Feng e Jiang (2010)
Temporal	Multi	Filtro S-G	1	Dan Li et al. (2015)

Os atributos estão categorizados em origem e tipo de dado. A origem se refere a fonte de onde os dados são derivados como do resultado da segmentação, dos dados espectrais diretamente, da nuvem de pontos LiDAR ou de informações multitemporais. O tipo de dado à informação que o dado busca descrever:

- Espectral: dados brutos ou pré-tratados que refletem o comportamente espectral do objeto.
- Componentes principais: derivado por métodos de extração de componentes principais.
- Forma: forma dos polígonos bidimensionais resultantes da segmentação.
- Multi: obtidos pela composição sobre mais de um atributo.
- Textura: derivados da matriz de co-ocorrência revelando padrões de repetição.
- Espacial: dados referentes à distribuição espacial do objeto como latitude, longitude e altitude.
- Estrutural: obtido da nuvem de pontos tridimensional, buscando descrever a estrutura da árvore como diâmetro e altura da copa.

A maior parte dos estudos com dados multiespectrais faz o uso apenas dos dados diretos obtidos das bandas (seja diretamente os números digitais ou reflectância) e do NDVI, agrupados por estatísticas descritivas em trabalhos orientados a objeto.

Nos trabalhos que usam dados hiperespectrais é comum o uso de métodos para reduzir a dimensionalidade, selecionando componentes principais como a análise de componentes principais (PCA), análise discriminante canônica (CDA) e fração de ruído mínima (MNF).

Poucos dos trabalhos analisados exploram com mais profundidade os atributos estruturais extraídos da nuvem LiDAR (LIU et al., 2017b), o que demonstra que o potencial do LiDAR ainda é pouco explorado.

1.2.7 Seleção de atributos

Nem todos os estudos discutem a importância dos diferentes atributos extraídos, sobretudo os estudos por pixel que possuem menor dimensionalidade.

Podemos destacar aqui cinco formas diferentes para extração dos atributos:

1. Baseado em conhecimento (3) (YAN et al., 2018; ZHANG; HU, 2012; VOSS; SUGUMARAN, 2008)
2. Filtro de multicolinearidade (1) (LIU et al., 2017a)
3. Por métodos de extração de componentes principais (8) (DIAN et al., 2016; ZHANG et al., 2016; MOZGERIS et al., 2016; PU; LANDRY; ZHANG, 2015; ALONZO; BOOKHAGEN; ROBERTS, 2014; ALONZO; ROTH; ROBERTS, 2013; JENSEN; HARDIN; HARDIN, 2012; PU; LANDRY, 2012; ZHANG; FENG; JIANG, 2010)

4. Por medidas importância (13) (YAN et al., 2018; LE LOUARN et al., 2017; LIU et al., 2017a; SHOJANOORI et al., 2016; ZHANG et al., 2016; LI, D. et al., 2015; PU; LANDRY; ZHANG, 2015; YU; LI; ZHANG, 2015; PU; LANDRY, 2012; ZHANG; HU, 2012; ZHANG; FENG; JIANG, 2010; VOSS; SUGUMARAN, 2008; SUGUMARAN; PAVULURI; ZERR, 2003)

5. Métodos *wrapper* (ALONZO; BOOKHAGEN; ROBERTS, 2014; ALONZO; ROTH; ROBERTS, 2013)

O método baseado em conhecimento foi utilizado para gerar árvores de decisão com base em limiares normalmente definidos interativamente por visualização dos dados ou ainda por padrões esperados/conhecidos para as diferentes classes.

O filtro de multicolinearidade foi utilizado apenas por Liu et al. (2017a), onde um entre os pares de atributos que possuem alta correlação entre si e são removidos da análise por algum limiar de correlação, no estudo foi utilizado o limiar de $r > 0.85$ para a correlação de Pearson. A alta correlação entre as variáveis preditoras pode causar problemas e desempenho de alguns classificadores, entretando, já existem evidências de que a colinearidade não causa problemas em classificadores não lineares, ademais o uso no modelo de um dos pares pode resultar em um preditor com desempenho bem superior, por isso retirar arbitrariamente um dos pares correlacionados pode ter impacto negativo para esses modelos não lineares (MORLINI, 2006). Contudo, Liu et al. (2017a) utilizam dados hiperespectrais com elevada dimensionalidade, assim o uso do filtro pode simplificar bastante o problema reduzindo consideravelmente o custo computacional, o que justifica o uso desse fitro.

Outra forma de reduzir a dimensionalidade que foi mais explorada nos estudos foi a análise componentes componentes principais. Essa análise utiliza de métodos matemáticos para calcular a projeção ortogonal dos vetores de dados. A análise de componentes principais (PCA, *principal component analysis*) encontra a projeção ortogonal por meio dos vetores de eigen da matriz de covariância entre todas as variáveis, sendo o vetor eigen aquele que multiplicado pela matriz retorna outro vetor de mesma direção. Em relação aos dados, a PCA pode ser interpretada como uma transformação sobre os dados gerando novas variáveis (componentes) que capturam a maior variabilidade de dados possível em ordem decrescente, sendo que os primeiros componentes normalmente já capuram a maior parte da variabilidade (SMITH, 1988).

Quando se trata do PCA, nem todos os estudos o utilizam como método para reduzir a dimensionalidade, mas sim para derivar novos atributos (LE LOUARN et al., 2017; VERLIC et al., 2014). Dentre os utilizados são citados: a Análise Discriminante *Stepwise* utilizada em quatro estudos (MOZGERIS et al., 2016; PU; LANDRY; ZHANG, 2015; ALONZO; ROTH; ROBERTS, 2013; PU; LANDRY, 2012); a análise discriminante canônica, dois estudos (ALONZO; BOOKHAGEN; ROBERTS, 2014; ALONZO; ROTH; ROBERTS, 2013); fração mínima de ruído (MNF), dois estudos (DIAN et al., 2016; ZHANG et al., 2016) e o PCA, apenas um estudo (ZHANG; FENG; JIANG, 2010). No entanto, esses métodos representam apenas uma transformação sobre os atributos originais, dificultando assim a interpretação da importância de cada atributo para a obtenção do resultado final.

No âmbito da análise de dados hiperespectrais é comum o uso da fração mínima de ruído (MNF, *Minimum Noise Fraction*) que consiste em uma extensão da PCA aplicado ao processamento de imagens. A MNF visa maximizar o a relação sinal-ruído (SNR, *Signal to Noise Ratio*), combinando os vetores de eigen do sinal e do ruído, sendo que o ruído é extraído das estatísticas das bandas. A análise comparativa entre MNF e PCA indica que a MNF atinge níveis mais altos de SNR para dados experimentais, mas PCA tem melhor desempenho com dados experimentais adicionando ruído branco gaussiano (LUO et al., 2016).

Tanto a PCA quanto a MNF atuam apenas sobre os vetores de dados como um todo, visando capturar a variabilidade, seja a geral ou baseado na fração sinal-ruído. A análise discriminante canônica

(CDA, *Canonical Discriminant Analysis*), por outro lado, analisa a variabilidade dentro das classes com base em uma amostra de treinamento, assim, a CDA busca obter os vetores de dados que maximizem a diferença entre as classes e ao mesmo tempo minimize as variância interna de cada classe. Esse cálculo é baseado no vetor de eigen derivado da multiplicação de duas matrizes: 1) a matriz inversa da soma das matrizes de covariância de cada classe; 2) a matriz de espalhamento entre as classes, calculada pelo somatório das matrizes de desvio médio multiplicada pelo número de amostras para cada classe. Zhao e Maclean (2000) comparam a PCA e a CDA usando as 4 componentes principais usando-as para classificação de vegetação em imagens Landsat demonstrando obter acurácias de 6 a 7% melhores em favor da CDA. Contudo, os estudos analisados pela revisão não fazem uma comparação entre os três métodos que poderia revelar o desempenho desses diferentes métodos no contexto de classificação de espécies.

A PCA, MNF e CDA são utilizados sobretudo para redução e extração de informação de imagens multi e hiperespectrais. Ainda que essas técnicas possam reduzam o número componentes na análise, a análise orientada a objetos ainda permite derivar muitos atributos desses componentes. Por conseguinte, a maioria dos estudos (13) utilizam métricas de importância para selecionar os melhores atributos, entretanto, nem sempre o fazem como uma etapa a parte no estudo, muitas vezes utilizam apenas classificadores que já realizam esse processo como parte de seu funcionamento como nas árvores de decisão e *Random Forest* (LI, D. et al., 2015; PU; LANDRY; ZHANG, 2015).

Os métodos *wrapper* são utilizados apenas em dois estudos ambos pelo mesmo primeiro autor (ALONZO; BOOKHAGEN; ROBERTS, 2014; ALONZO; ROTH; ROBERTS, 2013). Os autores utilizam a seleção do tipo gulosa para frente (*greedy forward feature seletion*), na qual é selecionado um atributo em cada etapa e em cada uma dessas etapas testam-se todos os atributos. O selecionado em é aquele que apresenta menor taxa de erro de classificação baseada na validação cruzada. Essa forma de seleção permite a escolha de um conjunto de atributos que normalmente obtém alta acurácia , embora existam modelos de seleção mais sofisticados geralmente eles não se justificam, dado o número reduzido de atributos que esse modelo consegue selecionar e à própria estrutura de decisão iterativa que pode facilitar a interpretação dos dados, além de ser um algoritmo que não requer muito custo computacional (WITTEN; FRANK; HALL, 2011). No entanto os métodos *wrapper* precisam ser usados com certa cautela pois podem ser selecionados muitos atributos que resultam em um modelo sobreajustado aos dados.

1.2.8 Classificação supervisionada

Um dos estudos analisados desenvolveu um classificador que foi denominado MCC (*Multi Class Classifier*) (ZHANG et al., 2016). Este é um classificador baseado em código de correção de erros (ECOC, *Error Correcting Output Code*). O ECOC foi concebido para transmitir dados digitais binários em meios sujeito a perda e/ou ruído no qual as mensagens são codificadas em códigos binários com mais dígitos do que o mínimo necessário para possibilitar restaurar a mensagem. Assim, se apenas poucos dígitos forem alterados na mensagem transmitida é possível analisar a distância do código recebido em relação aos códigos válidos para as mensagens. Por exemplo, se tivermos um sistema em que seja necessário enviar uma resposta como sendo ”sim”ou ”não”poderíamos representar a mensagem com apenas 1 bit, sendo 0 ”não”e 1 ”sim”. No entanto, como forma de assegurar que a mensagem será recebida podemos determinar ”não”como sendo 00000 e sim como sendo 11111, dessa forma se houver ruído ou perda em até dois bits, a mensagem ainda será recebida corretamente calculando a distância entre o código recebido e os códigos válidos. Por exemplo, ao receber o código 00110, a menor distância seria para a mensagem ”não”00000, com 2 bits trocados, em vez de 3 bits trocados para obter 11111.

No contexto da classificação, o ECOC pode ser usado de forma análoga, realizando o treinamento de diversos classificadores binários para gerar os códigos que representam as classes. No caso de algum dos classificadores retornar a resposta incorreta, o código da classe correta ainda pode ser deter-

minado pela menor distância. Existem algumas regras para determinar o comprimento do código e o valor dos códigos para cada classe conforme Dietterich e Bakiri (1995) que adaptaram o método para classificação. Na realidade o ECOC pode ser pode ser considerado um sistema de classificadores do tipo assembleia (*ensamble*) como ocorre com o *Random Forests*.

Os demais estudos analisados utilizaram classificadores já utilizados e mais bem documentados na literatura, a utilização está distribuída conforme a figura 1.2.

Figura 1.2. Frequência de utilização dos diferentes classificadores por abordagem. CART (*Classification and Regression Trees*): árvores de decisão, k-NN: k vizinhos mais próximos, ADBC: árvore de decisão baseada em conhecimento, LDA (*Linear Discriminant Analysis*): análise discriminante linear, MCC (*Multi Class Classifier*): classificador multiclasse de Zhang et al. (2016), MLC (*Maximum Likelihood Classifier*): máxima verossimilhança, RF: *Random Forest*, SVM (*Support Vector Machine*): máquina de suporte a vetores.

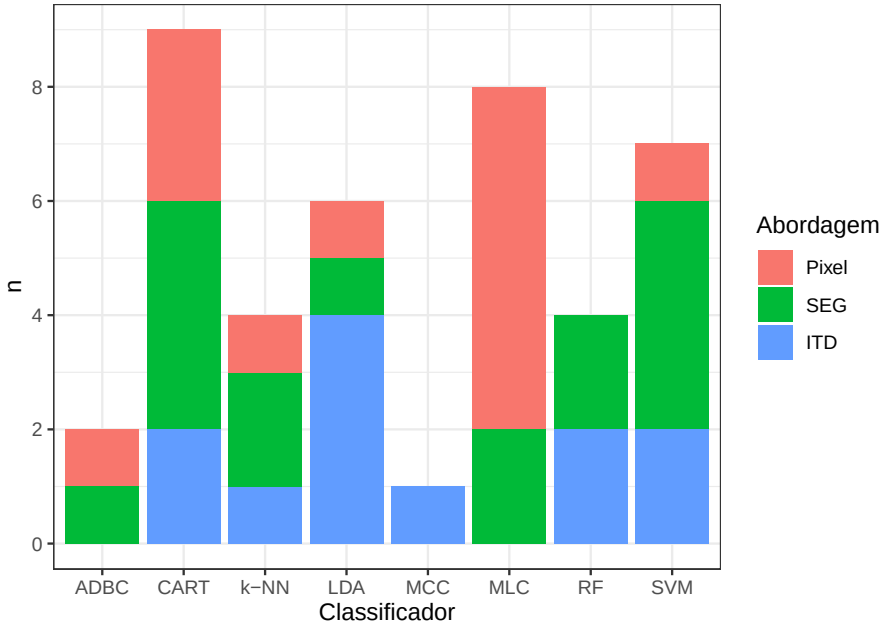

Dentre os classificadores utilizados podemos verificar a predominância da árvore de decisão (CART) com 9 estudos, seguido pela máxima verossimilhança (MLC) e SVM, com 8 e 7 estudos. Nota-se, pela figura 1.2 que enquanto o CART é utilizado para as três abordagens, na abordagem por pixel predomina o classificador MLC, enquanto SVM é mais utilizado para análise orientada a objeto tanto SEG como ITD. O RF, por outro lado, é utilizado apenas na abordagem por objetos. Essa distribuição pode ter relação com a implementação dos classificadores nos softwares utilizados nas pesquisas. Por exemplo, o CART é implementado no eCognition, software muito utilizado nos estudos do tipo SEG, mas só implementou o RF recentemente. O RF é implementado em alguns software mencionados como Weka (ZHANG et al., 2016) e R (LE LOUARN et al., 2017).

1.2.9 Aferimento da qualidade dos resultados

O aferimento da qualidade dos resultados é um tópico que merece destaque, pois apesar de a maioria dos estudos usar as mesmas métricas (kappa e acurácia geral) para aferir a qualidade, não podemos comparar os valores obtidos pelos diferentes trabalhos de forma simples e direta por alguns motivos:

- Existe diferença no número de classes: quanto maior o número de classes, mais difícil será a tarefa de classificação;

- A diferente quantidade de amostras: quanto mais amostras obtidas, maior a capacidade de generalização do classificador.
- Diferentes formas de validação do classificador.

O último item é o principal empecilho para permitir a comparação entre os classificadores, mas ao mesmo tempo o que poderia ser mais facilmente solucionada se certos padrões fossem seguidos nas análises. Muitos estudos não deixam claro se utilizaram validação cruzada, i.e. separação entre amostras para treinamento do classificador e amostras para validação usadas para comparar o resultado obtido pelo classificador. Ou seja, o treinamento do classificador não pode levar em conta as amostras de validação para poder aferir a capacidade de generalização do modelo, caso contrário podemos simplesmente ter um modelo sobreajustado nos dados de treinamento, mas com baixo poder de classificar novas amostras (IGUAL; SEGUÍ, 2017). A tabela 1.3 demonstra o melhor resultado obtido pelos diferentes trabalhos.

Tabela 1.3. Acurácia final dos diferentes estudos, com a abordagem utilizada, menor classe, número de classes de vegetação e classificador com melhor resultado.

Referência	Abordagem	Validação	Menor Classe	# Classes	Classificador	Acurácia
Pu (2011)	Pixel	*hold-out*	152	8	ML	0.86
Jensen, Hardin e Hardin (2012)	Pixel	-	39	10	LDA	0.90
Doko et al. (2014)	Pixel	-	5730	5	k-NN	0.97
Yu, Li e Zhang (2015)	Pixel	-	-	11	CART	0.87
Mustafa et al. (2015)	Pixel	*hold-out*	28	15	SVM	0.89
Zhou et al. (2016)	Pixel	*hold-out*	20	11	SVM	0.79
Trisakti (2017)	Pixel	*hold-out*	30	3	ML	0.99
Iovan, Boldo e Cord (2008)	SEG	*hold-out*		2	SVM	1.00
Voss e Sugumaran (2008)	SEG	*hold-out*	50	8	CART	0.57
Zhang, Feng e Jiang (2010)	SEG	-	20	5	CART	0.88
Pu e Landry (2012)	SEG	LOO	45	7	CART	0.67
Agarwal et al. (2013)	SEG	-		6	LDA	0.90
Dan Li et al. (2014)	SEG	*hold-out*	30	4	ML	0.81
Verlic et al. (2014)	SEG	*hold-out*		5	LDA	0.58
Kukunda et al. (2017)	SEG	*hold-out*	20	10	ADBC	0.61
Dan Li et al. (2015)	SEG	10-fold	31	4	SVM	0.90
Shojanoori et al. (2016)	SEG	*hold-out*		5	SVM	0.88

Le Louarn et al. (2017)	SEG	10-fold	101	6	RF	0.79
Yan et al. (2018)	SEG		500	3	CART	0.91
Zhang e Hu (2012)	ITD	*hold-out*	16	6	CART	0.86
Zhang e Qiu (2012)	ITD	-	2	40	k-NN	0.69
Alonzo, Roth e Roberts (2013)	ITD	*hold-out*	41	15	LDA	0.86
Alonzo, Bookhagen e Roberts (2014)	ITD	*hold-out*	25	29	SVM	0.83
Pu, Landry e Zhang (2015)	ITD	*hold-out*	7	7	CART	0.55
Zhang et al. (2016)	ITD	10-fold	12	7	MCC	0.89
Dian et al. (2016)	ITD	5-fold	2	8	SVM	0.79
Mozgeris et al. (2016)	ITD	*hold-out*	95	6	LDA	0.66
Liu et al. (2017a)	ITD	-		15	RF	0.70

Vale ressaltar que 8 estudos sequer mencionam como é feita a validação dos resultados, enquanto 15 deles utilizam a validação *hold-out*, i.e. separam aleatoriamente uma única vez as amostras de treinamento e teste. Contudo antes de 2003 (primeira publicação considerada) essa técnica de validação vem sendo descartada por não levar em conta a variância decorrente da seleção da amostra de treinamento, em vez disso recomenda-se a validação *K-fold*, se possível repetidamente (KIM et al., 2009; BENGIO; GRANDVALET, 2004; DIETTERICH, 1997).

A validação K-fold separa as amostras em K partes gerando o mesmo número de treinamento e validação, a cada etapa uma parte é usada para validação e as demais para treinamento. Apenas 5 estudos utilizam a validação do tipo K-fold, ainda assim não retratam os valores do erro de predição causados pela variância da escolha das amostras, de maneira que não se pode determinar a estabilidade dos valores de acurácia. A validação do tipo *Leave-one-out* (LOO) é um caso particular de K-fold onde K é igual ao tamanho da amostra, de forma a reservar apenas um exemplo em cada iteração para ser classificado. A validação *leave-one-out* é indicada sobretudo para situações com número reduzido de amostras, uma vez que exclui apenas uma instância por iteração, reduzindo o impacto de uma amostra de treinamento muito pequena, mas ao mesmo tempo gerando grande demanda computacional.

Le Louarn et al. (2017) apresentam o teste de McNemar para diferença entre as tabelas de contingência. Esse teste constroi uma matriz X de dimensão 2 x 2, com os termos segundo a tabela 1.4. A seguir, realiza-se um teste a hipótese nula de igualdade χ^2 com os valores esperados para a diagonal principal igual à diagonal principal de X, e a diagonal secudária equivalente à média da diagonal secundária de X. Entretanto, Dietterich e Bakiri (1995) apontam que o teste de McNemar não mede a variabilidade decorrente da escolha da amostra de treinamento ou da aleatoriedade interna do classificador, portanto ele só pode ser aplicado se essas fontes de variabilidade forem muito pequenas.

Tabela 1.4. Matriz para teste χ^2 do teste de McNemar

# amostras classificadas incorretamente pelos dois algoritmos	# amostras classificadas corretamente por A e incorretamente por B
# amostras classificadas corretamente por B e incorretamente por A	# amostras classificadas corretamente por A e B

É possível possível notar que para o classificador CART, com exceção do estudo de Zhang e Hu (2012), os demais apresentam acurácia abaixo de 70%, enquanto os que não determinam qual o processo de validação utilizado apresentam valores acima de 87%. Isso demonstra como o processo de validação é importante para que o resultado tenha representatividade, pois já é conhecido a tendência de sobreajuste nos classificadores como CART e SVM, e por esse motivo esses classificadores têm sido utilizado apenas em sistema de asembleia com muitos modelos treinados com diferentes parâmtros, e.g. *Bagging*, *Boosting* ou mesmo *Random Forest* (IGUAL; SEGUÍ, 2017).

Outro fator a ser considerado é a seleção dos hiperparâmetros do SVM utilizando otimizadores, que em determinados estudos levam a acurácia muito elevadas. Neste caso, esse tipo de otimização também pode levar a sobreajuste, mesmo utilizando validação cruzada, e dessa forma deve ser utilizada a validação por três amostras: treino (para ajuste do modelo), validação (para ajuste dos hiperparâmetros) e teste (para aferir o resultado final) (IGUAL; SEGUÍ, 2017). Isso não foi observado nos estudos aqui analisados.

Conforme já discutido o RF é mais robusto a sobreajuste, por isso, dependendo de como se faz a análise de acurácia, pode-se assumir incorretamente que ele sistematicamente apresenta desempenho pior que o SVM. No entanto, já é conhecida a tendência do SVM de sobreajustar na amostra (CAWLEY; TALBOT, 2010). Por isso os estudos que apontam o RF como o melhor apresentam acurácia baixa, pois os valores obtidos devem ser mais condizentes com a performance esperada para novas observações.

Dadas essas incompatibilidades para comparação entre os estudos, é possível analisar os estudos individualmente e notar alguns fatos interessantes. Dentre eles, o classificador MCC proposto por Zhang et al. (2016) apresentou desempenho melhor que o RF, sobretudo para o conjunto de atributos restrito ao MNF. No entanto, o fato mais notável é a diferença nos resultados quando comparados diferentes conjuntos de atributos, no qual ao usar todos os atributos a diferença entre os classificadores RF e MCC é de apenas 1,9%, enquanto que ao usar as bandas do MNF houve ganho de acurácia de 40,7% para RF e 9,3% para MCC.

Para dados multiespectrais bitemporais o mesmo ocorre no estudo de Dan Li et al. (2015) no qual a diferença entre a acurácia de RF e SVM é de apenas 1,8% para os dados bitemporais, no entanto, comparando ao uso de imagens do Worldview-2 e bitemporais (Wordview-3 e Worldview-2) há uma melhora de 16,1% e 20,2% na acurácia de SVM e RF respectivamente. Essas amplas diferenças entre os diferentes conjunto de variáveis utilizados indicam a extração e seleção de atributos como principal fator para obter classificações acuradas, tendo maior relevância do que o uso de diferentes algoritmos de aprendizado modernos.

1.3 Conclusão

Em 23 dos 33 estudos analisados nessa revisão, sobretudo nos mais recentes, os autores utilizaram metodologias de classificação baseada em objetos, utilizando o mesmo modelo de análise: tratamento dos dados, segmentação, extração de atributos, classificação supervisionada.

No tratamento dos dados de satélite multiespectrais, há consenso a respeito da utilização da fusão com a banda pancromática de melhor resolução espacial para refinar os detalhes das bandas multi-

espectrais, mas deve-se destacar que os estudos não utilizam os algoritmos mais bem avaliados como os desenvolvidos por Jing e Cheng (2009) e Aiazzi, Baronti e Selva (2007).

A extração de atributos é a etapa onde existe a maior diferença entre os estudos. Existem inúmeros atributos de ordem espectral, textural, geométricos e espaciais possíveis para utilização. São necessários mais estudos que discutam o grau de relevância dos atributos possíveis de se extrair levando em consideração as características do sensor utilizado buscando padrões que revelem os atributos que tenham maior relevância.

Ao utilizar o LiDAR, o uso de dados da geometria da copa são pouco explorados, apesar de evidências da alta importância que esses atributos apresentam quando utilizados (ALONZO; BOOKHAGEN; ROBERTS, 2014; LIU et al., 2017b). Mais estudos poderiam ser realizados para caracterizar, sob diversas condições, dentre os inúmeros atributos possíveis de se extrair quais podem ser mais relevantes para a classificação.

Nos estudos considerados, são utilizados diversos algoritmos de classificação, obtendo resultados próximos entre si, sugerindo assim que o algoritmo classificador é menos importante para o resultado final do que as etapas anteriores.

Em todos os estudos em que a identificação chegou a identificação em nível de espécies foi utilizado apenas um subconjunto das espécies que se encontravam no local e apenas 4 trabalhos desenvolvem uma metodologia que permite classificar as árvores como não pertencente a nenhuma das espécies consideradas. Esse dado já possui grande validade, pois pode localizar algumas poucas espécies de interesse para determinados estudos.

Notou-se certa deficiência nos estudos quanto à forma de validação da qualidade dos resultados finais. Já existem estudos (KIM et al., 2009) e livros-texto de ciência de dados (IGUAL; SEGUÍ, 2017) que indicam a utilização da validação cruzada *K-fold*, e quando se otimizam hiperparâmetros o uso de amostras de treinamento, validação e teste.

Apesar de já existir uma base de trabalhos que exploraram a questão, parece não haver uma tendência clara de desenvolvimento e incremento da metodologia utilizada. Nenhum dos estudos realiza um trabalho comparando claramente os resultados obtidos utilizando a metodologia desenvolvida com a de outros trabalhos consideram os mesmos dados de entrada. Um reflexo do fato de não haver um consenso sobre qual a metodologia que reflete o atual estado da arte, já que nenhuma delas foi amplamente estudada e validada com replicações suficientes. Além disso, não é possível comparar diretamente as métricas de acurácia entre os trabalhos, já que existem diferenças quanto ao número de espécies, métodos de amostragem e de validação dos resultados, que causam levam a grande discrepância nos valores obtidos.

Considerando o contexto acima fica evidente a necessidade de estudos que validem as metodologias já desenvolvidas, pois em todos os trabalhos encontrados nesta revisão, a metodologia foi utilizada apenas para localidades específicas, identificando apenas as espécies mais comuns na área de estudo. Ressaltando assim a importância de trabalhos que validem as metodologias e atestem sua replicabilidade para outras localidades e identificação de outras espécies.

Após validar as metodologias, seria importante também definir as situações em que as diferentes metodologias seriam mais apropriadas, dependendo da disponibilidade de recursos do projeto, da escala de trabalho, das características dos dados já disponíveis e da existência de dados auxiliares.

Referências

AGARWAL, Shivani et al. Mapping Urban Tree Species Using Very High Resolution Satellite Imagery: Comparing Pixel-Based and Object-Based Approaches. **ISPRS INTERNATIONAL JOURNAL OF GEO-INFORMATION**, MDPI AG, Basel, Switzerland, v. 2, n. 1, p. 220–236, mar. 2013. ISSN

2220-9964. DOI: 10.3390/ijgi2010220. Disponível em: <http://www.mdpi.com/2220-9964/2/1/220>.

AIAZZI, B.; BARONTI, S.; SELVA, M. Improving Component Substitution Pansharpening Through Multivariate Regression of MS $+$Pan Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 10, p. 3230–3239, out. 2007. ISSN 0196-2892. DOI: 10.1109/TGRS.2007.901007. Disponível em: <http://ieeexplore.ieee.org/document/4305344/>.

AIAZZI, B. et al. MTF-tailored multiscale fusion of high-resolution MS and pan imagery. **Photogrammetric Engineering and Remote Sensing**, Bethesda, MD, USA, v. 72, n. 5, p. 591–596, 2006. ISSN 00991112. DOI: 10.14358/PERS.72.5.591.

ALONZO, Michael; BOOKHAGEN, Bodo; ROBERTS, Dar A. Urban tree species mapping using hyperspectral and lidar data fusion. **Remote Sensing of Environment**, Elsevier, v. 148, p. 70–83, mai. 2014. ISSN 0034-4257. DOI: 10.1016/J.RSE.2014.03.018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425714001047?via%7B%5C%%7D3Dihub>.

ALONZO, Mike; ROTH, Keely; ROBERTS, Dar. Identifying Santa Barbara's urban tree species from AVIRIS imagery using canonical discriminant analysis. **Remote Sensing Letters**, TAYLOR & FRANCIS LTD, Oxon, England, v. 4, n. 5, p. 513–521, mai. 2013. ISSN 2150-704X. DOI: 10.1080/2150704X.2013.764027. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/2150704X.2013.764027>.

BAATZ, Martin; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: _____. **Angewandte Geographische Informations-Verarbeitung XII**. Salzburg, Alemanha: Beiträge zum AGIT-Symposium, 2000. P. 12–23.

BENGIO, Yoshua; GRANDVALET, Yves. No Unbiased Estimator of the Variance of K-Fold Cross-Validation. **Journal of Machine Learning Research**, v. 5, p. 1089–1105, 2004. ISSN 0006291X. DOI: 10.1016/S0006-291X(03)00224-9.

CAVAYAS, François; RAMOS, Yuddy; BOYER, André. Mapping urban vegetation cover using WorldView-2 imagery. Edição: Sylvia S. Shen e Paul E. Lewis. **Proc. SPIE 8390, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII, 83900O**, International Society for Optics e Photonics, v. 8390, 83900o–1–83900o–10, mai. 2012. DOI: 10.1117/12.918655. Disponível em: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?articleid=1354545%20http://dx.doi.org/10.1117/12.918655>.

CAWLEY, Gavin C.; TALBOT, Nicola L.C. On over-fitting in model selection and subsequent selection bias in performance evaluation. **Journal of Machine Learning Research**, v. 11, p. 2079–2107, 2010. ISSN 15324435.

CRAIG A. LABEN; BERNARD V. BROWER. **Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening**. [S.l.]: US Grant, abr. 1998. P. 4. Disponível em: <https://patents.google.com/patent/US6011875A/en>.

DIAN, Yuanyong et al. Urban Tree Species Mapping Using Airborne LiDAR and Hyperspectral Data. **Journal of the Indian Society of Remote Sensing**, Springer India, v. 44, n. 4, p. 595–603, ago. 2016. ISSN 0255-660X. DOI: 10.1007/s12524-015-0543-4. Disponível em: <http://link.springer.com/10.1007/s12524-015-0543-4>.

DIETTERICH, T. G.; BAKIRI, G. Solving Multiclass Learning Problems via Error-Correcting Output Codes. **Journal of Artificial Intelligence Research**, v. 2, p. 263–286, 1995. ISSN 1076-9757. DOI: 10.1613/jair.105. arXiv: 9501101 [cs].

DIETTERICH, Thomas G. Approximate Statistical Tests for Comparing Supervised Classification Learning Algorithms. **Neural Computation**, Massachusetts, USA, v. 10, n. 7, p. 1895–1924, 1997.

DIGITALGLOBE. **Worldview-3 specifications**. [S.l.: s.n.], 2014. P. 2. Disponível em: <https://www.spaceimagingme.com/downloads/sensors/datasheets/DG%7B%5C_%7DWorldView3%7B%5C_%7DDS%7B%5C_%7D2014.pdf>.

DOKO, T et al. Potential plant biomass estimation through field measurement and vegetation cover mapping using ALOS satellite imagery: Case study of Fujiyoshida City, Japan. In: _____. 1. **35TH INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT (ISRSE35)**. Bristol, England: IOP PUBLISHING LTD, mar. 2014. v. 17. (IOP Conference Series-Earth and Environmental Science, 1). Chinese Acad Sci; Int Ctr Remote Sensing Environm; Int Soc Photogrammetry & Remote Sensing; Grp Earth Observat; Int Soc Digital Earth; Chinese Acad Sci; Natl Remote Sensing Ctr China; LDE; REIS; LIESMARS; State Key Laboratory of Remote Sensing Science, p. 012078. DOI: 10.1088/1755-1315/17/1/012078. Disponível em: <http://stacks.iop.org/1755-1315/17/i=1/a=012078?key=crossref.9432f016a4b6bcd883c438e28f81e9e3>.

FASSNACHT, Fabian Ewald et al. Review of studies on tree species classification from remotely sensed data. **Remote Sensing of Environment**, Elsevier, Amsterdam, NL, v. 186, p. 64–87, dez. 2016. ISSN 0034-4257. DOI: 10.1016/J.RSE.2016.08.013. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425716303169?via%7B%5C%%7D3Dihub>.

IGUAL, Laura; SEGUÍ, Santi. **Introduction to Data Science: A Python Approach to Concepts, Techniques and Applications**. 1. ed. Switzerland: Springer, 2017. P. 218. ISBN 9783319098876.

IOVAN, Corina; BOLDO, Didier; CORD, Matthieu. Detection, Characterization, and Modeling Vegetation in Urban Areas From High-Resolution Aerial Imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 1, n. 3, p. 206–213, set. 2008. ISSN 1939-1404. DOI: 10.1109/JSTARS.2008.2007514. Disponível em: <http://ieeexplore.ieee.org/document/4682675/>.

JENSEN, Ryan R.; HARDIN, Perry J.; HARDIN, Andrew J. Classification of urban tree species using hyperspectral imagery. **Geocarto International**, v. 27, n. 5, p. 443–458, 2012. ISSN 10106049. DOI: 10.1080/10106049.2011.638989.

JING, Linhai; CHENG, Qiuming. Two improvement schemes of PAN modulation fusion methods for spectral distortion minimization. **International Journal of Remote Sensing**, Taylor & Francis, v. 30, n. 8, p. 2119–2131, abr. 2009. ISSN 0143-1161. DOI: 10.1080/01431160802549260. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/01431160802549260>.

KIM, Sooyoung et al. Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. **Remote Sensing of Environment**, Elsevier Inc., v. 113, n. 8, p. 1575–1586, 2009. ISSN 00344257. DOI: 10.1016/j.rse.2009.03.017. Disponível em: <http://dx.doi.org/10.1016/j.rse.2009.03.017>.

KRUSE, Fred A.; BAUGH, William M.; PERRY, Sandra L. Validation of DigitalGlobe WorldView-3 Earth imaging satellite shortwave infrared bands for mineral mapping. **Journal of Applied Remote Sensing**, International Society for Optics e Photonics, v. 9, n. 1, p. 096044, mai. 2015. ISSN 1931-3195. DOI: 10.1117/1.JRS.9.096044. Disponível em: <http://remotesensing.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JRS.9.096044>.

KUKUNDA, Collins B. et al. Feature-location analyses for identification of urban tree species from very high resolution remote sensing data. pt. Edição: A Liu, Y and Chen. **Remote Sensing of Environment**, Elsevier, Amsterdam, NL, v. 17, n. 5, p. 16–24, jun. 2017. ISSN 00344257. DOI: 10.3390/ijgi2010220. Disponível em: <http://ieeexplore.ieee.org/document/4309314/%20https://www.sciencedirect.com/science/article/pii/0034425782900438%20http://search.datapages.com/data/doi/10.1306/44B4C288-170A-11D7-8645000102C1865D%20https://pubs.er.usgs.gov/publication/70016614%20https://www.scie>.

KUMAR, A. S.; KARTIKEYAN, B.; MAJUMDAR, K. L. Band sharpening of IRS-multispectral imagery by cubic spline wavelets. **International Journal of Remote Sensing**, London, v. 21, n. 3, p. 581–594, 2000. ISSN 13665901. DOI: 10.1080/014311600210768.

LAUNEAU, Patrick et al. Airborne hyperspectral mapping of trees in an urban area. **International Journal of Remote Sensing**, v. 38, n. 5, p. 1277–1311, 2017. ISSN 13665901. DOI: 10.1080/01431161.2017.1285080.

LE LOUARN, Marine et al. "Kill Two Birds with One Stone": Urban Tree Species Classification Using Bi-Temporal Pléiades Images to Study Nesting Preferences of an Invasive Bird. **Remote Sensing**, v. 9, n. 9, p. 916, set. 2017. ISSN 2072-4292. DOI: 10.3390/rs9090916. Disponível em: <http://www.mdpi.com/2072-4292/9/9/916>.

LI, Dan et al. Object-Based Urban Tree Species Classification Using Bi-Temporal WorldView-2 and WorldView-3 Images. **Remote Sensing**, v. 7, n. 12, p. 16917–16937, dez. 2015. ISSN 2072-4292. DOI: 10.3390/rs71215861. Disponível em: <http://www.mdpi.com/2072-4292/7/12/15861/htm%20http://www.mdpi.com/2072-4292/7/12/15861>.

LI, Dan et al. Tree species classification based on WorldView-2 imagery in complex urban environment. In: CENT S UNIV FORESTRY & TECHNOL UNIV; CENT S UNIV; HUNAN UNIV SCI & TECHNOL; INDIANA STATE UNIV; IEEE GEOSCIENCE & REMOTE SENSING SOC; INT SOC PHOTOGRAMMETRY & REMOTE SENSING; GRP EARTH OBSERVAT; NAT SCI FDN CHINA. 2014 THIRD INTERNATIONAL WORKSHOP ON EARTH OBSERVATION AND REMOTE SENSING APPLICATIONS (EORSA 2014). 345 E 47TH ST, NEW YORK, NY 10017 USA: IEEE, 2014. (International Workshop on Earth Observation and Remote Sensing Applications). ISBN 978-1-4799-4184-1.

LI, Feng et al. Urban Vegetation Classification Based on Phenology using HJ-1A/B time series imagery. In: ECOLE POLYTECHNIQUE FED LAUSANNE; UNIV LAUSANNE INST GEOG DURABILITE; UNIV ZURICH. 2015 JOINT URBAN REMOTE SENSING EVENT (JURSE). 345 E 47TH ST, NEW YORK, NY 10017 USA: IEEE, 2015. ISBN 978-1-4799-6652-3.

LI, Hui; JING, Linhai; TANG, Yunwei. Assessment of Pansharpening Methods Applied to WorldView-2 Imagery Fusion. **Sensors (Basel, Switzerland)**, Multidisciplinary Digital Publishing Institute (MDPI), v. 17, n. 1, jan. 2017. ISSN 1424-8220. DOI: 10.3390/s17010089. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/28067770%20http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC5298662>.

LIU, Luxia et al. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. **Remote Sensing of Environment**, Elsevier, v. 200, p. 170–182, out. 2017. ISSN 0034-4257. DOI: 10.1016/J.RSE.2017.08.010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717303620?via%7B%5C%%7D3Dihub>.

LIU, Luxia et al. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. **Remote Sensing of Environment**, Elsevier, v. 200, p. 170–182, out. 2017. ISSN 0034-4257. DOI: 10.1016/J.RSE.2017.08.010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717303620?via%7B%5C%%7D3Dihub>.

LUO, Guangchun et al. Minimum Noise Fraction versus Principal Component Analysis as a Preprocessing Step for Hyperspectral Imagery Denoising. **Canadian Journal of Remote Sensing**, London, v. 42, n. 2, p. 106–116, 2016. ISSN 17127971. DOI: 10.1080/07038992.2016.1160772.

MORLINI, Isabella. On multicollinearity and concurvity in some nonlinear multivariate models. **Statistical Methods and Applications**, Berlin, v. 15, n. 1, p. 3–26, 2006. ISSN 16182510. DOI: 10.1007/s10260-006-0005-9.

MOZGERIS, Gintautas et al. Hyperspectral and color-infrared imaging from ultralight aircraft: Potential to recognize tree species in urban environments. In: 2016 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Los Angeles, USA: IEEE, ago. 2016. P. 1–5. ISBN 978-1-5090-0608-3. DOI: 10.1109/WHISPERS.2016.8071756. Disponível em: <http://ieeexplore.ieee.org/document/8071756/>.

MUSTAFA, Y T et al. IDENTIFICATION AND MAPPING OF TREE SPECIES IN URBAN AREAS USING WORLDVIEW-2 IMAGERY. In: _____. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. Kuala Lumpur, MY: ISPRS, 2015. P. 175–181. DOI: 10.5194/isprsannals-II-2-W2-175-2015. Disponível em: <https://www.isprs-ann-photogramm-remote-sens-spatial-inf-sci.net/II-2-W2/175/2015/isprsannals-II-2-W2-175-2015.pdf>.

PU, Ruiliang. Mapping urban forest tree species using IKONOS imagery: preliminary results. **Environmental Monitoring and Assessment**, Springer Netherlands, v. 172, n. 1-4, p. 199–214, jan. 2011. ISSN 0167-6369. DOI: 10.1007/s10661-010-1327-5. Disponível em: <http://link.springer.com/10.1007/s10661-010-1327-5>.

PU, Ruiliang; LANDRY, Shawn. A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. **Remote Sensing of Environment**, Elsevier Inc., v. 124, p. 516–533, set. 2012. ISSN 00344257. DOI: 10.1016/j.rse.2012.06.011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425712002477?via%7B%5C%%7D3Dihub%20http://dx.doi.org/10.1016/j.rse.2012.06.011>.

PU, Ruiliang; LANDRY, Shawn; ZHANG, Jingcheng. Evaluation of Atmospheric Correction Methods in Identifying Urban Tree Species With WorldView-2 Imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 5, p. 1886–1897, mai. 2015. ISSN 1939-1404. DOI: 10.1109/JSTARS.2014.2363441. Disponível em: <http://ieeexplore.ieee.org/document/6971089/>.

SHOJANOORI, Razieh et al. The Use of WorldView-2 Satellite Data in Urban Tree Species Mapping by Object-Based Image Analysis Technique. **SAINS MALAYSIANA**, v. 45, n. 7, p. 1025–1034, jul. 2016. ISSN 0126-6039.

SILVA FILHO, D.F. et al. Banco de dados relacional para cadastro, avaliação e manejo da arborização em vias públicas. **Revista Árvore**, Sociedade de Investigações Florestais, v. 26, p. 629–642, 2002. Disponível em: <http://agris.fao.org/agris-search/search/display.do?f=2008/XS/XS0812.xml;XS2002220514>.

SMARDON, Richard C. Perception and aesthetics of the urban environment: Review of the role of vegetation. **Landscape and Urban Planning**, Elsevier, v. 15, n. 1-2, p. 85–106, jun. 1988. ISSN 0169-2046. DOI: 10.1016/0169-2046(88)90018-7. Disponível em: <https://www.sciencedirect.com/science/article/pii/0169204688900187>.

SMITH, Lindsay. **A tutorial on Principal Components Analysis**. v. 17. Montreal: [s.n.], 1988. P. 3157–3175. ISBN 0471852236. DOI: 10.1080/03610928808829796. Disponível em: <http://www.mendeley.com/research/computational-genome-analysis-an-introduction-statistics-for-biology-and-health/%7B%5C%%7D5Cnhttp://www.tandfonline.com/doi/abs/10.1080/03610928808829796>.

SUGUMARAN, Ramanathan; PAVULURI, M.K. Manoj Kumar; ZERR, Daniel. The use of high-resolution imagery for identification of urban climax forest species using traditional and rule-based classification approach. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, 9 PART I, p. 1933–1939, set. 2003. ISSN 01962892. DOI: 10.1109/TGRS.2003.815384. Disponível em: <http://ieeexplore.ieee.org/document/1232207/>.

SUGUMARAN, Ramanathan; VOSS, Matthew. Object-oriented classification of LIDAR-fused hyperspectral imagery for tree species identification in an Urban environment. **2007 Urban Remote Sensing Joint Event, URS**, 2007. DOI: 10.1109/URS.2007.371845.

TAHA, Haider. Modeling impacts of increased urban vegetation on ozone air quality in the South Coast Air Basin. **Atmospheric Environment**, Pergamon, v. 30, n. 20, p. 3423–3430, out. 1996. ISSN 1352-2310. DOI: 10.1016/1352-2310(96)00035-0. Disponível em: <https://www.sciencedirect.com/science/article/pii/1352231096000350>.

TRISAKTI, Bambang. Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery. **IOP Conf. Ser.: Earth Environ. Sci.**, IOP Publishing Ltd, v. 54, p. 1–7, 2017. Disponível em: <http://iopscience.iop.org/article/10.1088/1755-1315/54/1/012003/pdf>.

TYRVÄINEN, Liisa; SILVENNOINEN, Harri; KOLEHMAINEN, Osmo. Ecological and aesthetic values in urban forest management. **Urban Forestry & Urban Greening**, Urban & Fischer, v. 1, n. 3, p. 135–149, jan. 2003. ISSN 1618-8667. DOI: 10.1078/1618-8667-00014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S161886670470014X>.

VERLIC, Andrej et al. TREE SPECIES CLASSIFICATION USING WORLDVIEW-2 SATELLITE IMAGES AND LASER SCANNING DATA IN A NATURAL URBAN FOREST. **SUMARSKI LIST**, v. 138, n. 9-10, p. 477–488, 2014. ISSN 0373-1332.

VOSS, Matthew; SUGUMARAN, Ramanathan. Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach. **Sensors**, Molecular Diversity Preservation International, Basel, Switzerland, v. 8, n. 5, p. 3020–3036, mai. 2008. ISSN 1424-8220. DOI: 10.3390/s8053020. Disponível em: <http://www.mdpi.com/1424-8220/8/5/3020>.

WEN, Dawei et al. Semantic Classification of Urban Trees Using Very High Resolution Satellite Imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 4, p. 1413–1424, abr. 2017. ISSN 1939-1404. DOI: 10.1109/JSTARS.2016.2645798. Disponível em: <http://ieeexplore.ieee.org/document/7828096/>.

WITTEN, Ian H; FRANK, Eibe; HALL, Mark a. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. ed. San Francisco, CA, USA: Elsevier, 2011. P. 664. ISBN 0080890369. Disponível em: <http://books.google.com/books?id=bDtLM8CODsQC%7B%5C&%7Dpgis=1>.

YAN, Jingli et al. Mapping vegetation functional types in urban areas with WorldView-2 imagery: Integrating object-based classification with phenology. **Urban Forestry & Urban Greening**, v. 31, p. 230–240, abr. 2018. ISSN 16188667. DOI: 10.1016/j.ufug.2018.01.021. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S1618866717300729>.

YU, Chao; LI, Mingyang; ZHANG, Mifang. Classification of Dominant Tree Species in An Urban Forest Park Using the Remote Sensing Image of WorldView-2. In: 2015 8TH INTERNATIONAL CONGRESS ON IMAGE AND SIGNAL PROCESSING (CISP). 345 E 47TH ST, NEW YORK, NY 10017 USA: IEEE, 2015. P. 742–747. ISBN 978-1-4673-9098-9.

ZHANG, Caiyun; QIU, Fang. Mapping Individual Tree Species in an Urban Forest Using Airborne Lidar Data and Hyperspectral Imagery. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 10, p. 1079–1087, out. 2012. ISSN 00991112. DOI: 10.14358/PERS.78.10.1079. Disponível em: <http://openurl.ingenta.com/content/xref?genre=article%7B%5C&%7Dissn=0099-1112%7B%5C&%7Dvolume=78%7B%5C&%7Dissue=10%7B%5C&%7Dspage=1079>.

ZHANG, Kongwen; HU, Baoxin. Individual Urban Tree Species Classification Using Very High Spatial Resolution Airborne Multi-Spectral Imagery Using Longitudinal Profiles. **Remote Sensing**, MDPI AG, BASEL, SWITZERLAND, v. 4, n. 6, p. 1741–1757, jun. 2012. ISSN 2072-4292. DOI: 10.3390/rs4061741. Disponível em: <http://www.mdpi.com/2072-4292/4/6/1741>.

ZHANG, Xiuying; FENG, Xuezhi; JIANG, Hong. Object-oriented method for urban vegetation mapping using IKONOS imagery. **International Journal of Remote Sensing**, Taylor & Francis, v. 31, n. 1, p. 177–196, jan. 2010. ISSN 0143-1161. DOI: 10.1080/01431160902882603. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/01431160902882603>.

ZHANG, Zhongya et al. Object-Based Tree Species Classification in Urban Ecosystems Using LiDAR and Hyperspectral Data. **Forests**, Multidisciplinary Digital Publishing Institute, v. 7, n. 12, p. 122, jun. 2016. ISSN 1999-4907. DOI: 10.3390/f7060122. Disponível em: <http://www.mdpi.com/1999-4907/7/6/122>.

ZHAO, Guang; MACLEAN, Ann L. A comparison of canonical discriminant analysis and principal component analysis for spectral transformation. **Photogrammetric Engineering and Remote Sensing**, Bethesda, MD, USA, v. 66, n. 7, p. 841–847, 2000. ISSN 00991112.

ZHOU, Jianhua et al. SVM-based soft classification of urban tree species using very high-spatial resolution remote-sensing imagery. **International Journal of Remote Sensing**, v. 37, n. 11, p. 2541–2559, 2016. ISSN 13665901. DOI: 10.1080/01431161.2016.1178867.

ZÖLCH, Teresa et al. Regulating urban surface runoff through nature-based solutions – An assessment at the micro-scale. **Environmental Research**, Elsevier Inc., Amsterdam, NL, v. 157, n. 5, p. 135–144, 2017. ISSN 0013-9351. DOI: 10.1016/j.envres.2017.05.023. Disponível em: <http://dx.doi.org/10.1016/j.envres.2017.05.023>.

2 ANÁLISE DAS VARIÁVEIS EXTRAÍDAS DE IMAGENS RGB PARA DIFERENCIAÇÃO DE ESPÉCIES ARBÓREAS DA UNIVERSIDADE DE SÃO PAULO, CAMPUS PIRACICABA

Resumo

O planejamento das espécies arborização urbana é essencial para o que os benefícios provenientes das árvores sejam maximizados e para que haja resiliência às mudanças climáticas. Este estudo teve como objetivo identificar árvores a nível de espécie por meio de sensoriamento remoto com imagem RGB de altíssima resolução (drone 5 cm) levando em consideração padrões espectrais e texturais e estruturais da copa. Foram identificados e mapeados 139 indivíduos de 16 espécies. Os resultados mostraram que as palmeiras e as coníferas tiveram melhor diferenciação, com maior confusão entre as folhosas que apresentaram maior variabilidade. Por meio de classificadores *Random Forest* foi possível atingir acurácia de aproximadamente 60% por validação cruzada *leave-one-out*. Destacaram-se os atributos referentes à banda vermelha (R), a tonalidade e saturação do espaço de cores HSV, além da variável textural de correlação da banda R. Apresentamos um novo tipo de gráfico de radar para análise de dados multivariados, possibilitando melhor compreensão do problema da classificação.

Palavras-chave: Arborização urbana, drone, imagem de altíssima resolução, resposta espectral, copas de árvores

Abstract

Urban tree planting planning is essential to maximize benefits from trees and to provide resilience to climate changes. The aim of this study was to identify trees at the species level, by means of remote sensing with very high spatial resolution RGB imagery (drone 5 cm), dated September 2018, considering spectral, textural and structural patterns of the crowns. We mapped and identified 139 individuals from 16 different species. The results showed that the palm trees and conifers were better characterized, whereas broadleaved presented confusion due to higher variability. Using a Random Forest classifier we achieved 60% accuracy using leave-one-out cross validation scheme. The most important features were derived from the red band (R), furthermore the hue and saturation from HSV color space and the correlation textural feature from R band. We present a novel type of radar plot for analyzing multivariate data, which allows better comprehension over the classification issues.

Keywords: Urban forestry, drone, very high-resolution image, spectral patterns, tree canopy.

2.1 Introdução

A arborização urbana é parte integrante das cidades, mas muitas vezes, o tema é esquecido durante o planejamento urbano, comprometendo os benefícios provenientes da vegetação (BUCKERIDGE, 2015), como regulação microclimática, retenção de poluentes, ambientes esteticamente mais agradáveis entre outros (BURDEN, 2006). Muitos desses benefícios são sensíveis ao porte e a espécie plantada.

O sensoriamento remoto vem sendo utilizado como ferramenta para mapear as espécies de maneira mais rápida e menos onerosa que o inventário (DALPONTE; FRIZZERA; GIANELLE, 2019; ZHANG; QIU, 2012) utilizando imagens de satélite multiespectrais de alta resolução (ZHANG; QIU, 2012) ou ainda hiperespectrais (ALONZO; BOOKHAGEN; ROBERTS, 2014).

Recentemente, os veículos aéreos não tripulados (VANT), também chamados de drones ou sistemas aéreos remotamente pilotados (SARP) vêm sendo estudados como alternativa para obtenção dos dados remotos (NEZAMI et al., 2020; NATESAN; ARMENAKIS; VEPAKOMMA, 2019; FRANKLIN; AHMED, 2018; LISEIN et al., 2015). Os VANT podem ser adaptados para obtenção de diversos tipos de dados, em modelos maiores e com maior capacidade de carga é possível inclusive montar sistemas de aquisição de múltiplos sensores simultaneamente como o sistema GatorEye que agrega sensores LiDAR, hiperespectrais, termais e da luz visível (BROADBENT et al., 2020).

Contudo existem poucos estudos para identificação de espécies utilizando sistemas mais simples e com preços mais acessíveis com uso de sensores RGB apenas. Nezami et al. (2020) comparam os dados RGB com hiperespectrais obtidos com resolução média de 2,3 cm e 8,6 cm respectivamente e obtêm acurácia acima de 90% para ambos os dados utilizando redes neurais convolucionais, entretanto o estudo discrimina apenas entre três espécies coníferas.

Portanto, mais estudos com imagens RGB obtidas por meio de VANT poderiam demonstrar o potencial do uso desse sistema de baixo custo para identificar maior diversidade de espécies. Neste contexto o presente trabalho analisa a possibilidade de se classificar espécies arbóreas por meio de imagens aéreas RGB de altíssima resolução, investigando os atributos mais importantes para o modelo de classificação.

2.2 Materiais e Métodos

2.2.1 Área de Estudo

O estudo foi realizado em uma área do campus da Escola Superior de Agricultura "Luiz de Queiroz", da Universidade de São Paulo (ESALQ/USP) no município de Piracicaba, SP, situado nas coordenadas geográficas 22°42'30"S e 47°38'00"W 2.1. O clima da região é classificado como Cfa (clima subtropical com verão quente) na classificação de Köppen-Geiger, apresentando estações bem definidas com precipitação média anual de 1252 mm, temperatura média de $23,6 \deg C$, com estação seca bem definida com pluviosidade média nos últimos três anos 2017-2019 de 12 mm no mês de Junho (AGRITEMPO, 2020).

O paisagismo do campus possui estilo de jardim inglês com grande diversidade de espécies e indivíduos arbóreos espalhados de forma heterogênea na paisagem, plantadas tanto em maciços arbóreos como isoladamente. O campus apresenta 4867 indivíduos arbóreos cadastrados de 213 espécies em uma área de aproximadamente 15 hectares (MENDES et al., 2015).

2.2.2 Dados de sensorimento remoto

Foi utilizada uma imagem RGB de alta resolução com 5 cm. A imagem foi adquirida por meio de um sobrevoo de Drone eBee Classic, em um teste de campo da empresa Santiago & Cintra, datada de 10 de setembro de 2013, no campus da Escola Superior de Agricultura "Luiz de Queiroz", da Universidade de São Paulo (ESALQ/USP). As imagens foram pré-processadas pelo distribuidor que realizou o mosaico das imagens sem ortorretificação devido à baixa sobreposição das imagens.

2.2.3 Coleta de campo

Inicialmente, foram identificadas as árvores reconhecíveis na imagem nas quais foi possível identificar os limites de sua copa. A partir dessa amostra, as árvores foram identificadas em campo por reconhecimento de um especialista e utilizando a base de dados das árvores cadastradas no trabalho de Mendes et al. (2015). Do total da amostra, foram escolhidas apenas as árvores de espécies que possuíam

Figura 2.1. Área de estudo. a) Estado de São Paulo, b) Município de Piracicaba, c) Campus da ESALQ com imagem drone destacada.

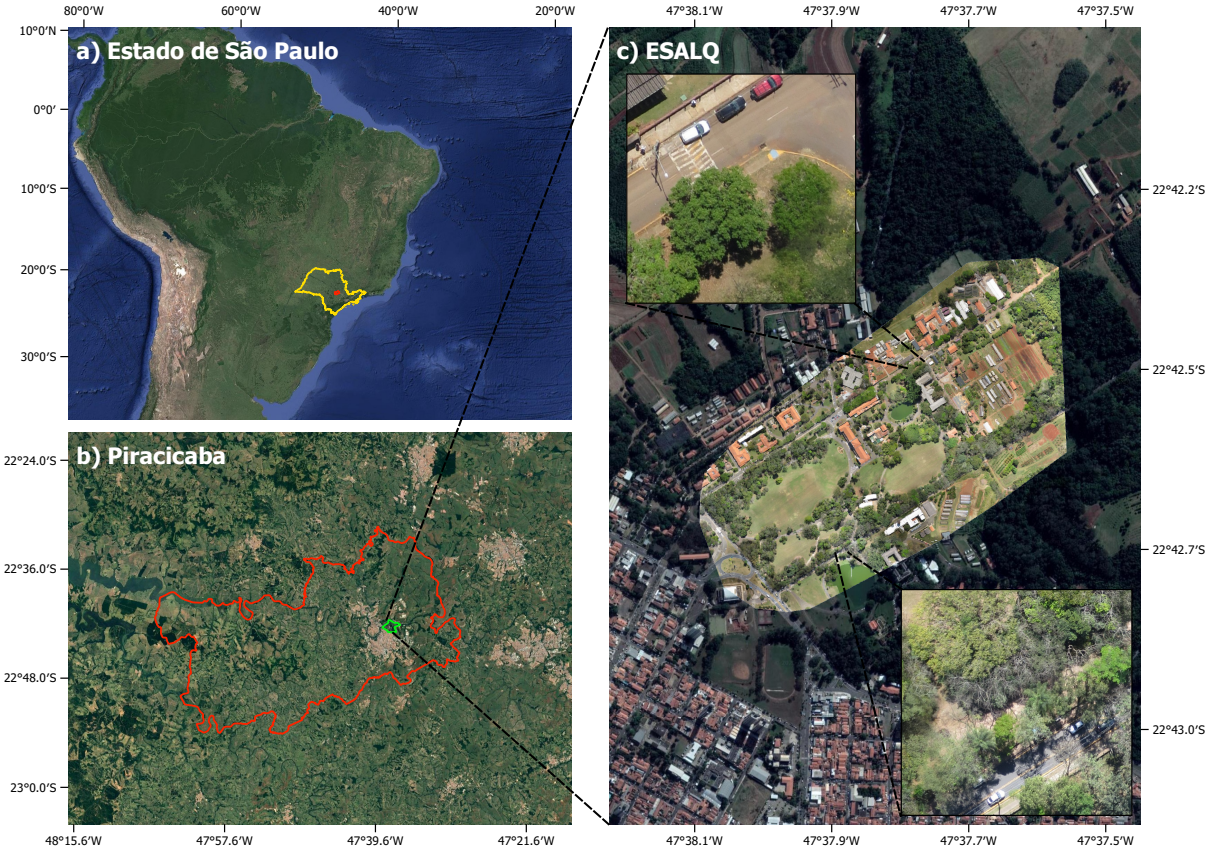

pelo menos 5 indivíduos. A Figura 2.2 demonstra uma faixa de árvores vetorizadas manualmente segundo a metodologia proposta.

2.2.4 Extração de atributos

A partir da imagem RGB foram derivadas novas camadas de dados, tais como: espaço de cores HSV (tonalidade, saturação e valor) e os componentes principais (PC) pela análise de componentes principais apenas dentre os pixels contidos pela vetorização das árvores. A partir dessas camadas foi extraído para cada árvore as estatísticas de média, máximo, mínimo, amplitude e desvio padrão.

Das camadas RGB, HSV e PC, também foram calculadas métricas texturais, utilizando a matriz de co-ocorrência de níveis de cinza (GLCM), obtendo-se valores de contraste, homogeneidade, correlação, energia, entropia e dissimilaridade. Para gerar as matrizes de co-ocorrência, não se utilizou janelas de tamanho arbitrários, mas foram utilizados os pixels dentro da vetorização, derivamos dados do perfil longitudinal das árvores, a partir do azimute, dados que se mostraram importantes para a classificação de espécies em estudo anterior (ZHANG; HU, 2012).

2.2.5 Seleção de atributos e classificação

Para selecionar as variáveis mais relevantes realizamos uma seleção em duas fases. Na primeira fase, por meio de um filtro de multicolinearidade, removendo as variáveis com correlação de Pearson $|r| > 0,7$ para reduzir a redundância, limiar definido conforme outros estudos (DORMANN et al., 2013).

Já na segunda fase utilizamos o índice de importância obtido pelo classificador Random Forest, escolhendo as n variáveis melhores posicionadas. Esse algoritmo foi utilizado com base em análises prévias

Figura 2.2. Imagem demonstrando a vetorização manual das árvores resultante da metodologia proposta.

que demonstraram ser o classificador que apresentou menor problema de sobreajustamento (*overfitting*), resultando em melhor acurácia. Para selecionar o número ideal de variáveis consideradas no modelo, analisamos o gráfico de acurácia em relação ao número de variáveis escolhidas. Com base nessa análise foi selecionando o menor número de variáveis a partir do qual a acurácia tende a estabilizar. A acurácia foi calculada pela validação cruzada *leave-one-out* devido ao reduzido número de amostras.

A partir dessa análise realizamos a classificação dos dados por meio do algoritmo Random Forest ajustado com 500 árvores.

2.2.6 Análise dos resultados

O resultado da classificação então foi analisado com base na matriz de erros e da análise exploratória com a proposição de uma nova modalidade de gráfico proposta neste trabalho que permite uma boa visão geral sobre dados multivariados.

Esse gráfico, une os conceitos do boxplot e do radar. Sendo que o radar clássico é demonstrado em termos de variação dentro do grupo por meio de áreas de duas cores distintas, uma representando a variação dentro dos percentis 25-75% e outra representando a amplitude total. Além disso, assim como o boxplot, apresenta os *outliers* como pontos 2.3. Para que o gráfico tenha maior legibilidade e comparabilidade entre as variáveis, todas elas foram padronizadas para valores entre 0,1 a 1, já que a amplitude do gráfico varia entre 0 a 1, visando evitar a sobreposição de pontos caso diversas variáveis apresentem valores baixos.

2.3 Resultados

Foram mapeados e identificados 139 indivíduos de 16 diferentes espécies conforme a tabela 2.3:

No total foram derivadas 84 variáveis da imagem original RGB que após a filtragem de colinearidade, restaram 23. Analisando o gráfico de incremento de acurácia com a inclusão das variáveis em ordem de importância (Figura 2.4), notamos uma tendência de estabilização da após a inclusão de 10 variáveis no modelo. As 10 variáveis escolhidas para gerar o modelo estão descritas na Tabela 2.2.

Figura 2.3. Exemplo do gráfico radar-boxplot. Em vermelho a variação dentro dos percentis 25-75% e em azul a amplitude removendo os outliers representados como pontos abertos.

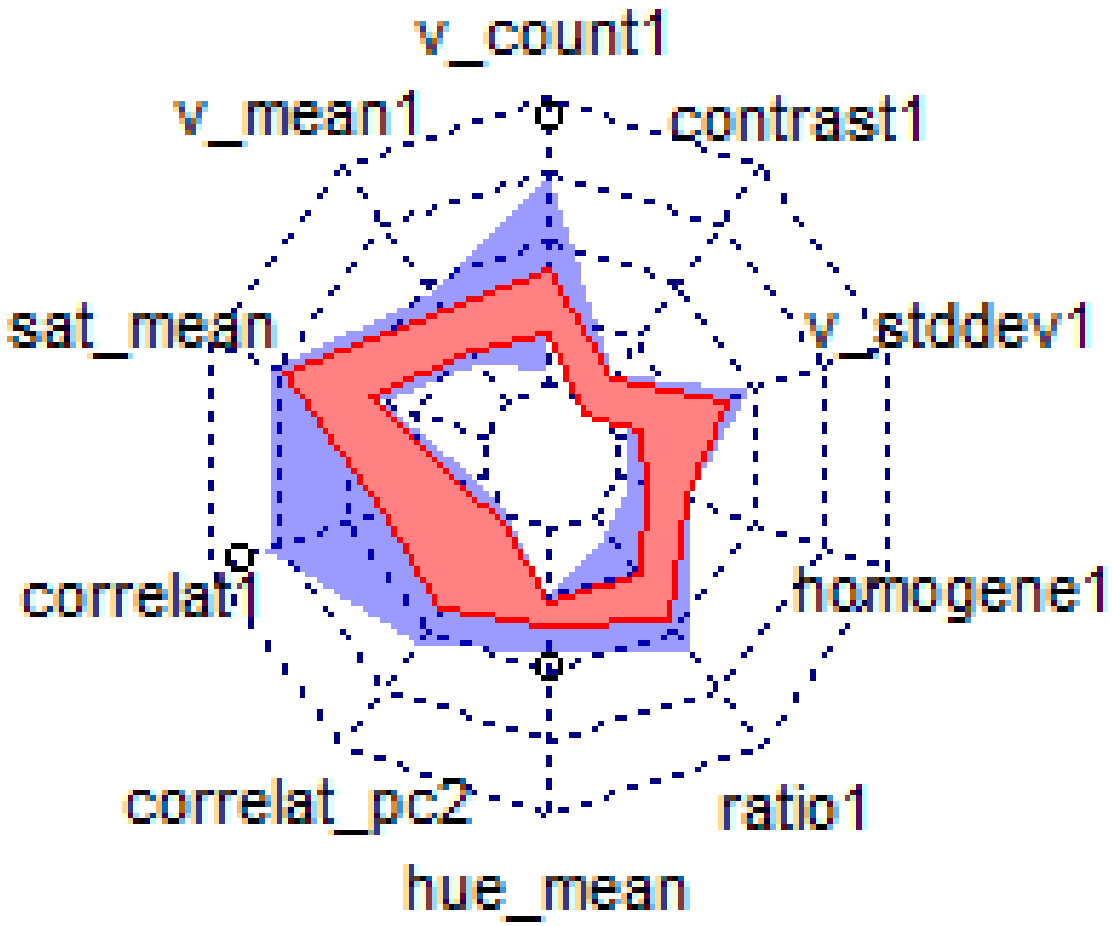

Utilizando as variáveis selecionadas é possível analisar o comportamento delas dentro de cada classe por meio do gráfico radar-boxplot (Figura 2.5). O gráfico apresenta uma área em vermelho que demonstra a distribuição dos percentis entre 25-75% e uma área em azul representando a amplitude, além dos outliers como definido em um boxplot e representado por pontos.

A classificação Random Forest atingiu acurácia geral de 61,87%, com um índice Kappa de 0,5887. A análise detalhada da confusão entre as classes e as acurácias de cada uma pode ser realizada pela matriz de erros da Figura 2.3.

2.4 Discussão

A metodologia apresentada mostrou-se eficiente para classificar cinco espécies das 16 encontradas, obtendo mais de 80% de acurácia na determinação destas. A acurácia geral foi baixa, situando-se em torno de 60%. Este fato pode ter decorrido da limitação no tamanho amostral, devido a baixa repetição de espécies dentro do campus, além disso, algumas árvores da mesma espécie apresentavam em estados fisiológicos bem distintos, conforme podemos observar em relação as Mirindibas na Figura 2.2, fato semelhante ocorreu com o Ipê-roxo. Isso pode ser atribuído a uma estiagem no mês anterior de Agosto de 2013, com precipitação de apenas 2,5mm acumulados durante todo o mês (LEB - ESALQ - USP, 2018).

Dentre as variáveis mais importantes para o modelo podemos notar a predominância de atributos da banda 1, correpondente ao vermelho, o que tem sentido prático uma vez que é o comprimento de

Tabela 2.1. Árvores identificadas na região amostrada.

Espécie	Quantidade
Roystonea oleracea (Palmeira Imperial)	16
Syagrus romanzoffiana (Jerivá)	14
Phoenix sp. (Palmeira fênix)	12
Handroanthus heptaphylla (Ipê roxo)	11
Lafoensia glyptocarpa (Mirindiba)	11
Pachira aquatica (Munguba)	9
Paubrasilia echinata (Pau-Brasil)	9
Archontophoenix alexandrae (Seafortia)	8
Thuja occidentalis (Cedrinho)	8
Cupressus sempervirens (Cipreste italiano)	7
Plinia cauliflora (Jaboticaba sabará)	7
Livistona chinensis (Palmeira leque)	6
Poincianella pluviosa (Sibipiruna)	6
Eugenia uniflora (Pitangueira)	5
Handroanthus roseo alba (Ipê branco)	5
Psidium cattleianum (Araçá)	5

Figura 2.4. Gráfico demonstrando o incremento de acurácia em relação ao número de variáveis utilizando o classificador Random Forest

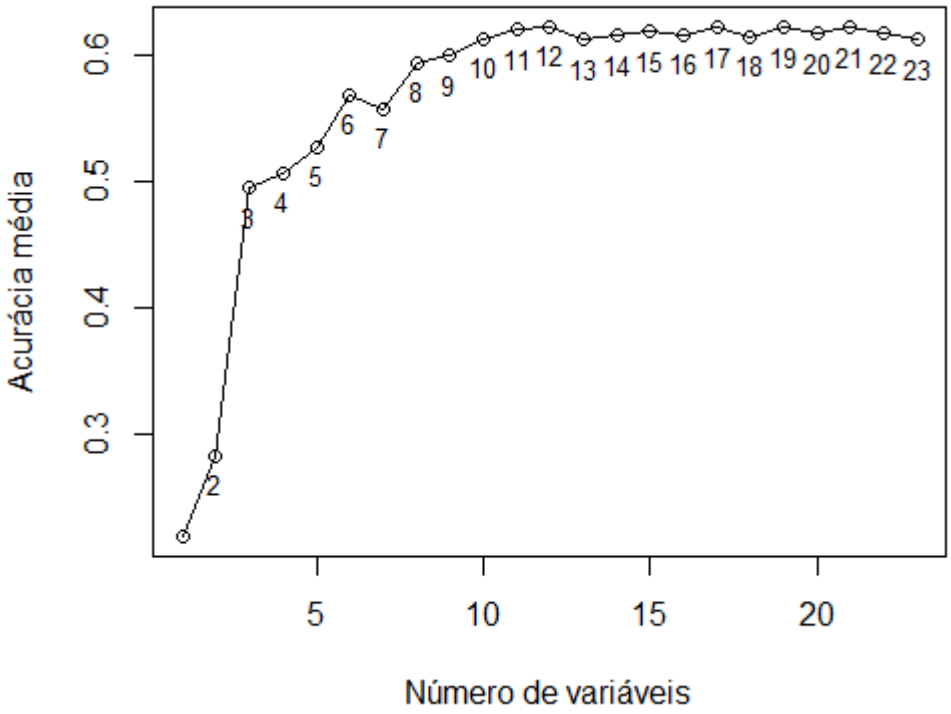

onda que apresenta maior interação com o pigmento clorofila A presente nas folhas (GUIDI; TATTINI; LANDI, 2017). É possível notar também a alta relevância dos componentes de saturação e tonalidade do espaço de cores HSV que pode ter correlação com aspectos como a composição de pigmentos nas folhas no caso da tonalidade e a concentração dos pigmentos, o que pode revelar o estado fisiológico da árvore no caso da saturação.

Contudo, a variável que apresentou maior importância para o modelo foi a área da copa, o que pode revelar o porte das árvores, bem como a própria conformação da copa, dado que árvores como as coníferas tendem a ter copas menos abertas. Além disso, considerando ser um plantio de manejo

Figura 2.5. Gráfico de radar-boxplot. A área em vermelho representa a variabilidade da variável dentro dos percentis 25-75%, a área em azul demonstra a amplitude total da variável sem os outliers.

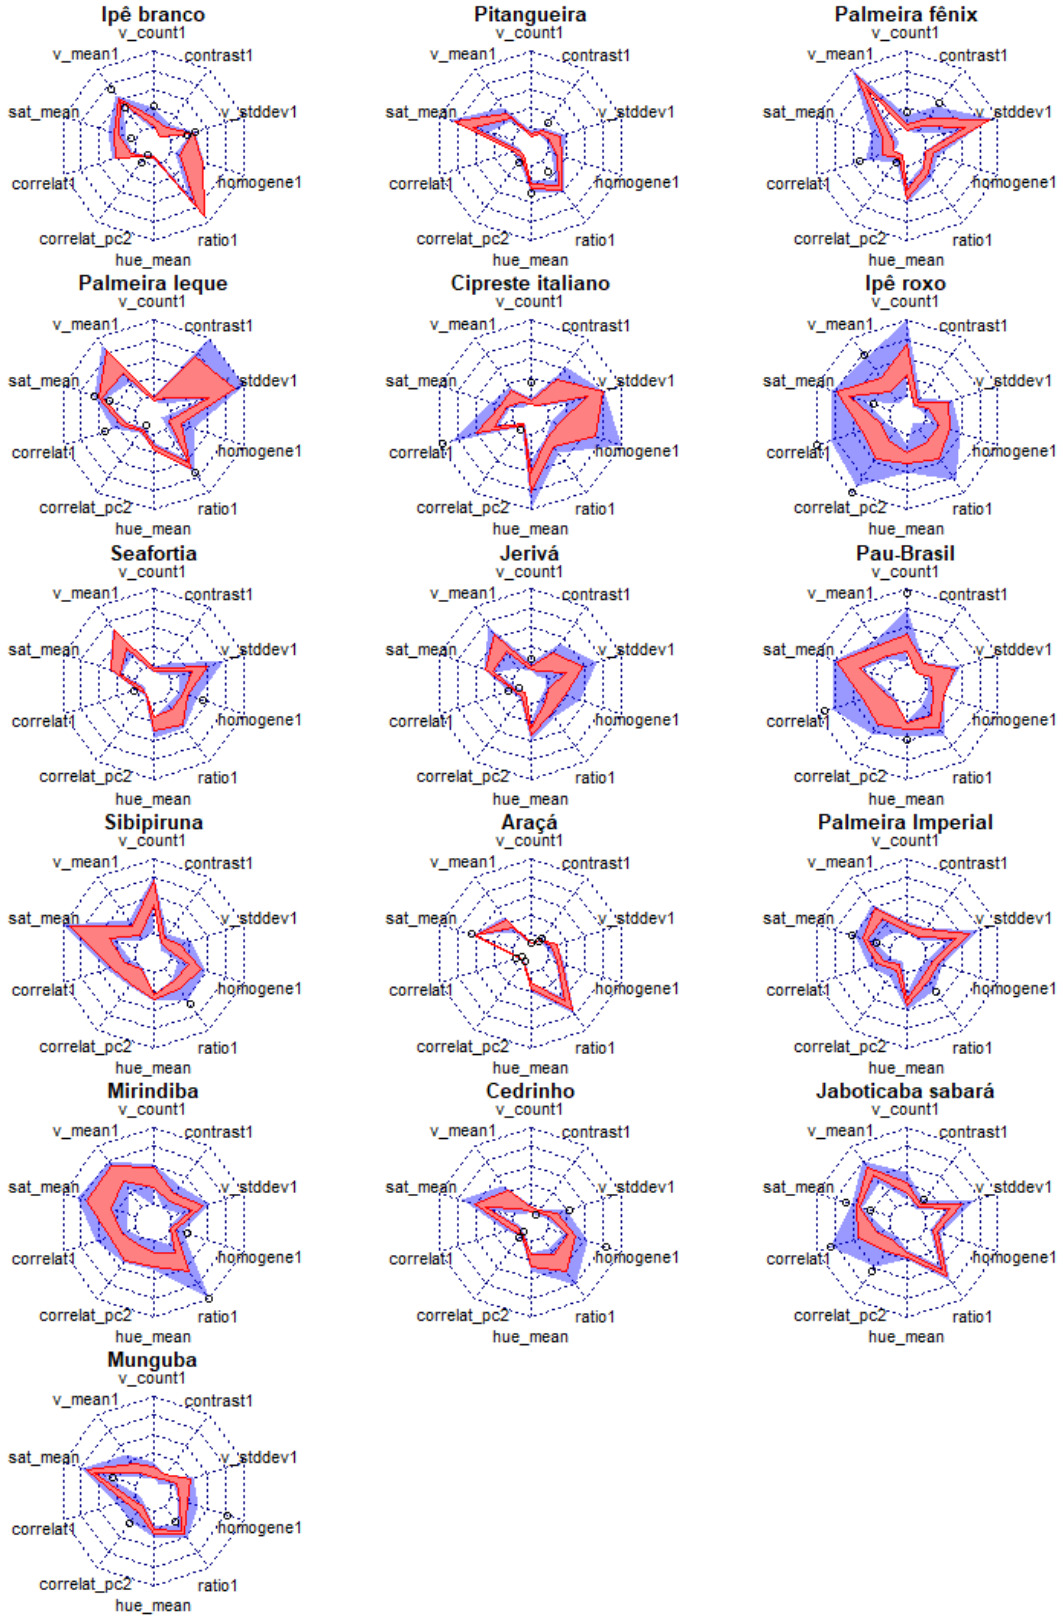

Tabela 2.2. Tabela de variáveis mais importantes escolhidas para gerar o classificador Random Forest

Sigla	Descrição
v_count1	área da copa
v_mean1	média da banda vermelho
sat_mean	média da saturação
correlat1	correlação da GLCM para a banda 1
correlat_pc2	correlação da GLCM para 2ª CP
hue_mean	média da tonalidade
ratio1	contribuição da banda 1 para o brilho
homogene1	homogeneidade da GLCM para a banda 1
v_stddev1	Desvio padrão para a banda 1
contrast1	constrate da GLCM para a banda 1

Tabela 2.3. Matriz de erros, as classes correspondem a: A - Araçá, Ce - Cedrinho, Ci - Cipreste italiano, Ib - Ipê-branco, Ir - Ipê-roxo, Ja - Jaboticaba-sabará, Je - Jerivá, Mi - Mirindiba, Mu - Mulunguba, Pf - Palmeira-fênix, Pi - Palmeira imperial, Pl - Palmeira-leque, Pb - Pau-brasil, Pt - Pitanga, Se - Seafortia, Si - Sibipiruna

	A	Ce	Ci	Ib	Ir	Ja	Je	Mi	Mu	Pf	Pi	Pl	Pb	Pt	Se	Si	AU
A	2	1	0	0	0	0	0	0	0	0	0	0	0	2	0	0	40%
Ce	0	5	0	0	0	0	1	0	1	0	0	1	0	0	0	0	63%
Ci	0	1	6	0	0	0	0	0	0	0	0	0	0	0	0	0	86%
Ib	0	0	0	5	0	0	0	0	0	0	0	0	0	0	0	0	100%
Ir	0	0	0	0	2	1	0	0	2	0	0	0	3	0	0	3	18%
Ja	0	0	0	0	1	4	0	1	0	0	0	0	1	0	0	0	57%
Je	0	0	0	0	0	0	11	0	0	0	2	0	0	0	1	0	79%
Mi	0	0	0	1	0	0	0	8	0	0	0	1	1	0	0	0	73%
Mu	0	1	0	0	2	0	0	0	4	0	0	0	1	1	0	0	44%
Pf	0	0	0	0	0	0	0	0	0	12	0	0	0	0	0	0	100%
Pi	0	0	0	0	0	0	2	0	1	0	13	0	0	0	0	0	81%
Pl	0	1	0	0	0	0	0	0	0	0	0	5	0	0	0	0	83%
Pb	0	0	0	0	4	0	0	2	1	0	1	0	1	0	0	0	11%
Pt	1	0	0	0	0	0	1	0	1	0	0	0	0	1	1	0	20%
Se	0	0	0	0	0	0	3	0	0	0	0	0	0	0	5	0	63%
Si	0	0	0	0	3	0	0	0	1	0	0	0	0	0	0	2	33%
AP	67%	56%	100%	83%	17%	80%	61%	73%	36%	100%	81%	71%	14%	25%	71%	40%	61,9%

antrópico, onde houve uma sistematização do plantio, as árvores de mesma espécie em sua maioria foram plantadas na mesma época e portanto apresentam-se com porte bastante semelhante gerando assim uma homogeneidade artificial para a mesma espécie.

Os atributos considerados como 4º e 5º mais importantes se referem à atributos texturais de correlação. Esse atributo de textura revela o quanto o valor dos pixels vizinhos estão correlacionados, i.e. demonstra a tendência de repetição de padrões. Esses atributos podem revelar os padrões de repetição e formato das folhas e a presença ou asuência de lacunas entre as mesmas, de forma que copas mais densas tenderão a ter maior correlação pois a probabilidade do vizinho representar o mesmo objeto (folhas) é maior.

O gráfico radar-boxplot (Figura 2.5) proposto, mostra-se bastante interessante para entender o comportamento das espécies quanto a múltiplas variáveis simultaneamente, permitindo compreender os resultados da classificação e da matriz de erros.

Podemos notar grande variabilidade em relação ao comportamento do Ipê-roxo e do Pau-brasil, por isso as duas espécies apresentaram baixa acurácia do usuário. Isso pode retratar o fato desses indivíduos terem sido encontrados distantes entre si, provavalmente plantados em épocas diferentes e com portes variados.

Podemos verificar também o comportamento de algumas variáveis mencionadas como, por exemplo, a alta variabilidade nos valores de saturação para a Mirindiba que reflete variabilidade do estado fisiológico da planta conforme podemos observar na figura 2.2, onde temos indivíduos com bastante vigor ao lado de indivíduos que apresentam característica de estresse. Ao mesmo tempo, a tonalidade da classe não apresenta grande variabilidade o que pode indicar que a composição de pigmentos não sofre grandes alterações.

Em relação à variável correlação calculada da textura, esta apresentaos maiores índices para o Cipreste italiano. Isso é esperado, pois se trata de uma conífera com copa bastante densa e homogênea, revelando a importância do atributo textural como representação da densidade e homogeneidade da copa.

A Pintagueira teve acurácia do usuário de apenas 20% e acurácia do produtor de 25%. Pelo gráfico é possível constatar que o seu comportamento em relação as variáveis apresentadas é muito semelhante ao do Araçá, o que pode ser justificado por dois motivos. Primeiramente, as duas espécies pertencem a família Myrtaceae, logo é esperado que ambas apresentem características semelhantes, tanto na composição de pigmentos quanto da estrutura da copa. Outro fator importante é que os indivíduos amostrados estavam dentro de um plantio de fruticultura plantados na mesma época e que ainda não apresentavam porte adulto.

Dessa forma, é possível compreender a necessidade de se estabelecerem outras variáveis capazes de diferenciar melhor a Pitangueira, que apesar de ter comportamento bem estabelecido, assemelha-se a outras espécies. Da mesma forma, seria interessante buscar alternativas para o Ipê-roxo e o Pau-brasil, que poderiam ser resolvidas pela obtenção de mais amostras para caracterizar melhor a distribuição de suas variáveis, além de buscar menor variação quanto ao estado fisiológico, utilizando-se imagens do final do período chuvoso, na qual as árvores não tenham passado por estresse hídrico.

Diferentemente do padrão estabelecido no trabalho de Zhang e Hu (ZHANG; HU, 2012), neste caso não foi possível verificar ganhos para a classificação utilizando a análise do perfil longitudinal das espécies arbóreas, este fato pode ter ocorrido pelo fato de a imagem utilizada não ter sido ortorretificada. Ademais o estudo foi realizado em Toronto, Canadá, que apresenta espécies coníferas e de climas temperados que costumam apresentar copas com formas que ressaltam mais as diferenças de reflectância entre a face voltada para o Sol e a face sombreada.

É importante salientar que o estudo foi realizado com fotografias RGB simples e, ainda assim, obteve resultados que indicam a possibilidade de aplicação essa metodologia, sobretudo se utilizar mais dados como dados multitemporais para analisar os diferentes estados da fenologia das espécies. Com planejamento mais cauteloso do plano de vôo com maior sobreposição entre as cenas também é possível extrair uma nuvem de pontos por meio de algoritmos de *structure from motion* (*SfM*) (WESTOBY et al., 2012), a partir do qual poderiam ser estabelecidos algoritmos para detecção e delineamento das copas de árvores, além da possibilidade de derivar novos atributos estruturais da copa que podem melhorar a qualidade dos resultados.

2.5 Conclusão

Os resultados indicaram que a classificação de espécies arbóreas pode ser viável por meio da abordagem orientada a objeto usando imagens RGB de altíssima resolução.

Os atributos mais importantes para a classificação das copas de árvores foram derivadas principalmente da banda vermelho, que corresponde ao segundo pico de absorbância da clorofila A, além da

tonalidade e saturação do espaço de cores HSV e a métrica de textural de correlação. Outro atributos importante foi a área da copa o que pode ser reflexo tanto da sistematização dos plantio, quanto ao crescimento e arquitetura da copa das diferentes espécies.

O gráfico de radar-boxplot, apresenta-se como uma ferramenta interessante para análise multivariada e pode ser aplicada em diferentes contextos para entender a variação e comportamento de variáveis simultaneamente dentre diversas classes, revelando padrões semelhantes.

Referências

AGRITEMPO. **Dados mensais da estação meteoreológica da ESALQ de 2017-2019**. [S.l.: s.n.], 2020. Disponível em: <http://www.agritempo.gov.br/>. Acesso em: 12 mai. 2020.

ALONZO, Michael; BOOKHAGEN, Bodo; ROBERTS, Dar A. Urban tree species mapping using hyperspectral and lidar data fusion. **Remote Sensing of Environment**, Elsevier, v. 148, p. 70–83, mai. 2014. ISSN 0034-4257. DOI: 10.1016/J.RSE.2014.03.018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425714001047?via%7B%5C%%7D3Dihub>.

BROADBENT, Eben North et al. The GatorEye Unmanned Flying Laboratory: sensor fusion for 4D ecological analysis through custom hardware and algorithm integration. Gainsville, FL, USA, 2020. Disponível em: <https://www.dropbox.com/sh/z663tc6trebdhbf/AACLJcRx9IYiAsWNjqwtwBnra?dl=0%7B%5C&%7Dpreview=Broadbent+et+al+GatorEye+Overview+050420+v15+webshare.docx>.

BUCKERIDGE, Marcos. Árvores urbanas em São Paulo: planejamento, economia e água. **estudos avançados**, SciELO Brasil, v. 29, n. 84, p. 85–101, 2015.

BURDEN, Dan. **Urban Street Trees 22 Benefits**. Orlando, USA, 2006. Disponível em: <http://www.walkable.org/download/22_benefits.pdf>.

DALPONTE, Michele; FRIZZERA, Lorenzo; GIANELLE, Damiano. Individual tree crown delineation and tree species classification with hyperspectral and LiDAR data. **PeerJ**, PeerJ Inc., San Diego, USA, v. 6, e6227, jan. 2019. ISSN 2167-8359. DOI: 10.7717/peerj.6227. Disponível em: <https://peerj.com/articles/6227>.

DORMANN, Carsten F. et al. Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. **Ecography**, Wiley-Blackwell, Wiley, v. 36, n. 1, p. 27–46, jan. 2013. ISSN 09067590. DOI: 10.1111/j.1600-0587.2012.07348.x. Disponível em: <http://doi.wiley.com/10.1111/j.1600-0587.2012.07348.x>.

FRANKLIN, Steven E.; AHMED, Oumer S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, Taylor & Francis, London, v. 39, n. 15-16, p. 5236–5245, 2018. ISSN 13665901. DOI: 10.1080/01431161.2017.1363442. Disponível em: <https://doi.org/10.1080/01431161.2017.1363442>.

GUIDI, Lucia; TATTINI, Massimiliano; LANDI, Marco. How Does Chloroplast Protect Chlorophyll Against Excessive Light? **Chlorophyll**, June, 2017. DOI: 10.5772/67887.

LEB - ESALQ - USP. **Série de Dados Climatológicos do Campus Luiz de Queiroz de Piracicaba, SP**. Piracicaba, SP: Universidade de São Paulo, 2018.

LISEIN, Jonathan et al. Discrimination of deciduous tree species from time series of unmanned aerial system imagery. **PLoS ONE**, San Francisco, CA, USA, v. 10, n. 11, p. 1–20, 2015. ISSN 19326203. DOI: 10.1371/journal.pone.0141006.

MENDES, Flávio Henrique et al. Diversidade Arbórea E Análise Estrutural Em Jardim Inglês Da Universidade De São Paulo. **Ciência e Natura**, v. 37, n. 3, 2015. ISSN 0100-8307. DOI: 10.5902/2179460x17304.

NATESAN, S.; ARMENAKIS, C.; VEPAKOMMA, U. Resnet-based tree species classification using uav images. In: 2/W13. INTERNATIONAL Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives. Enschede, The Netherlands: ISPRS, 2019. v. 42, p. 475–481. DOI: 10.5194/isprs-archives-XLII-2-W13-475-2019.

NEZAMI, Somayeh et al. Tree Species Classification of Drone Hyperspectral and RGB Imagery with Deep Learning Convolutional Neural Networks. **Remote Sensing**, Basel, Switzerland, v. 12, n. 7, p. 1070, 2020. ISSN 20724292. DOI: 10.3390/rs12071070.

WESTOBY, M. J. et al. 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. **Geomorphology**, Elsevier B.V., Amsterdam, v. 179, p. 300–314, 2012. ISSN 0169555X. DOI: 10.1016/j.geomorph.2012.08.021. Disponível em: <http://dx.doi.org/10.1016/j.geomorph.2012.08.021>.

ZHANG, Caiyun; QIU, Fang. Mapping Individual Tree Species in an Urban Forest Using Airborne Lidar Data and Hyperspectral Imagery. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 10, p. 1079–1087, out. 2012. ISSN 00991112. DOI: 10.14358/PERS.78.10.1079. Disponível em: <http://openurl.ingenta.com/content/xref?genre=article%7B%5C&%7Dissn=0099-1112%7B%5C&%7Dvolume=78%7B%5C&%7Dissue=10%7B%5C&%7Dspage=1079>.

ZHANG, Kongwen; HU, Baoxin. Individual Urban Tree Species Classification Using Very High Spatial Resolution Airborne Multi-Spectral Imagery Using Longitudinal Profiles. **REMOTE SENSING**, v. 4, n. 6, p. 1741–1757, jun. 2012. ISSN 2072-4292. DOI: 10.3390/rs4061741.

3 LIDAR MULTIESPECTRAL PARA CLASSIFICAÇÃO DE ESPÉCIES ARBÓREAS DE CLIMA TEMPERADO EM ARBORIZAÇÃO VIÁRIA

Resumo

A obtenção da informação taxonômica de árvores espacializada pode ser uma importante ferramenta para a gestão da floresta urbana. No entanto, tem sido comum a fusão de múltiplas fontes de dados o que torna a solução complexa. Visando reduzir a complexidade do problema, este trabalho se propõe a investigar o uso do LiDAR multiespectral como uma soluação de fonte de dados única. O estudo foi realizado em uma área urbana de Oshawa, Canadá. Foi possível obter classificadores com acurácia de até 90% utilizando todos os atributos extraídos tanto estruturais como espectrais. Analisando os resultados obtidos por diferentes conjuntos de variáveis extraídas foi possível concluir que os atributos espectrais são mais relevantes para a tarefa, sendo o canal 1 (1550 nm) o mais importante.

Palavras-chave: Imagens RGB, LiDAR multiespectral, Arborização urbana, Aprendizado de máquina

3.1 Introdução

A informação taxonômica espacializada das árvore no ambiente urbano pode representar uma ferramenta muito importante para a gestão da arborização urbana. Além da análise de diversidade, o mapeamento dos indivíduos por espécies pode fornecer indicativos para a sistematização da poda, análise de risco de pragas e doenças, risco de dano a infraestrutura e estimação dos potenciais benefícios dependentes da espécie como controle de poluição atmosférica (TAHA, 1996), captação de água da chuva (ZÖLCH et al., 2017) e valor ornamental (SMARDON, 1988; TYRVÄINEN; SILVENNOINEN; KOLEHMAINEN, 2003).

Para tanto, o sensoriamento remoto apresenta-se como uma solução prática em relação ao inventário florestal em campo, com diversos estudos demonstrando o seu potencial para extração de informações biométricas (SILVA et al., 2016; KUKKONEN et al., 2019) e na identificação de espécies (WEN et al., 2017; LAUNEAU et al., 2017).

Diversas soluções são estudadas para identificação de espécies ou grupos taxonômicos, desde utilizando imagens de satélite de alta resolução (LI et al., 2015; PU; LANDRY; ZHANG, 2015), à combinação de diversos sensores como LiDAR e sensores hiperespectrais (ALONZO; BOOKHAGEN; ROBERTS, 2014; ZHANG et al., 2016). Enquanto os primeiros apresentam limitações classificando poucos tipos de vegetação e fornecendo apenas mapas temáticos sem informações sobre indivíduos, a combinação de sensores traz dificuldades operacionais, tanto para aquisição quanto para compatibilização dos dados.

Visando reduzir a complexidade da fusão de dados de sensoriamento remoto, o LiDAR multiespectral vem sendo investigado como uma solução em um único sensor para diversas aplicações como mapeamento de uso do solo (HUO et al., 2018) e identificação de espécies (KUKKONEN et al., 2019).

O LiDAR possibilita a informação a nível de indivíduos arbóreos, após a etapa normalmente denominada delineamento individual de copas arbóreas, em inglês *Individual Tree Crown Delineation* (ITD). O ITD é uma etapa importante para a identificação de espécies e para a extração de informações biométricas, tendo sido objeto de diversos estudos recentes (DALPONTE et al., 2015; SILVA et al., 2016; DAI et al., 2018). Existem duas principais abordagens utilizadas para o ITD:

1. Derivado do modelo digital de dossel (CHM);

2. Com base na nuvem de pontos.

Os algoritmos derivados do uso do CHM necessitam de produtos intermediários para obter a individualização das copas, envolvendo outros algoritmos intermediários para isso. Nessa categoria, incluem-se a identificação dos máximos locais (POPESCU; WYNNE, 2004; FALKOWSKI et al., 2006), crescimento de regiões (HYYPPÄ et al., 2001; SOLBERG; NAESSET; BOLLANDSAS, 2006), polígonos de voronoi (SILVA et al., 2016), delineamento de vales (FALKOWSKI et al., 2006), escalada na árvore (PERSSON; HOLMGREN; SÖDERMAN, 2002), e *watershed* (CHEN et al., 2006; MONGUS; ŽALIK, 2015). Por outro lado, os algoritmos que utilizam o espaço tridimensional operam diretamente sobre a nuvem de pontos tridimensional (FERRAZ et al., 2012, 2016), envolve menos etapas e apresenta melhores resultados, sobretudo em locais com mais de uma camada de vegetação (XIAO et al., 2019).

Um método recente proposto por Dai et al. (2018) agrega a informação espectral do LiDAR multiespectral além da informação espacial tridimensional, permitindo a melhoria na individualização de árvores com copas sobrepostas. O método proposto pelos autores realiza a segmentação em duas etapas, primeiro segmentando utilizando o algoritmo de Ferraz et al. (2012), e posteriormente incorporando a informação espectral nos segmentos identificados como agregados arbóreos por um classificador SVM desenvolvido no trabalho.

Após a ITD, já é possível extrair informações importantes para o manejo da floresta urbana, como altura da árvore, largura e altura da copa, altura da base da copa, dentre outras métricas comumente extraídas em diversos estudos (ALONZO; BOOKHAGEN; ROBERTS, 2014; BUDEI et al., 2018; FERRAZ et al., 2016). Além disso, para extrair a informação taxonômica é necessário ajustar um modelo classificador com base em métricas extraídas dos segmentos.

Alguns estudos propõem a fusão dos dados LiDAR com imagens visando agregar a informação espectral ao LiDAR que normalmente está restrito à intensidade de retorno referente a apenas um comprimento de onda específico (VOSS; SUGUMARAN, 2008; VERLIC et al., 2014; LIU et al., 2017a), no entanto essa metodologia depende de dados provenientes de diferentes sensores o que pode levar a características diferentes como data de aquisição e resolução. Nesse contexto o LiDAR multiespectral foi desenvolvido permitindo o escaneamento simultâneo em diferentes comprimentos de onda possibilitando a extração de métricas espectrais que se mostraram bastante relevantes em outros estudos (BUDEI et al., 2018; HUO et al., 2018). No entanto ainda são poucos os estudos com esse tipo de sensor que só foi lançado comercialmente em 2014 (TELEDYNE OPTECH, 2014).

Apesar disso, não se encontram estudos utilizando-se de métricas relativas extraídas da fusão dos valores de intensidade para cada retorno, mas apenas valores agregados, por pixel ou por árvore.

Neste trabalho se propôs avaliar métricas espacias, espectrais e índices extraídos de nuvens de pontos de LiDAR multiespectral, em especial efetuando-se a fusão dos valores de intensidade das nuvens de um sensor LiDAR multiespectral, avaliando a importância das métricas para a classificação de espécies arbóreas.

3.2 Materiais e Métodos

3.2.1 Descrição da área de estudo

A área de estudo está localizada em Oshawa, Ontario, Canada, às margens do Lago Ontario. O município de Oshawa se situa no Sudeste de Ontario, a aproximadamente 60 quilômetros a oeste de Toronto. Oshawa é o maior município da região de Durham. O município representa uma típica área urbana com uma mistura de árvores isoladas e agregadas, possuindo indivíduos de diferentes portes e idades, distribuídos em áreas verdes, arborização viária e quintais privados, ver Figura 3.1. A cidade apresenta uma densidade populacional de 1.027,0 indivíduos/km^2, o clima da região é continental úmido

ou Dfb pela classificação de Köppen. Com elevação média de 106 metros, a cidade apresenta predomínio de terreno plano o que permitiu sua expansão leste a oeste ao longo do lago.

Figura 3.1. Área de estudo. a) Estado de Ontário, b) Município de Oshawa, c) Recorte da área de estudo em amarelo, com as amostras selecionadas para identificação e treinamento.

Para o treinamento e validação, foram escolhidas cinco parcelas de 200 m x 200 m na área de estudo alocadas aleatoriamente destacadas em amarelo na figura 3.1c.

3.2.2 Aquisição de dados do LiDAR multiespectral

Os dados foram obtidos por meio do sensor LiDAR *Multispectral Optech Titan*. O *Optech Titan* foi o primeiro sensor LiDAR multiespectral desenvolvido e disponibilizado comercialmente, seu lançamento foi realizado no ano de 2014. O sensor é composto de três canais independentes de imageamento ativo nos comprimentos de onda 1.550 nm (C1), 1.064 nm (C2) e 532 nm (C3) (Figura 3.2).

A aquisição na área de estudo foi realizada no dia 3 de Setembro de 2014 em uma única faixa de 3 km^2 (WICHMANN et al., 2015). A coleta foi realizada em um sobrevoo a altitude de 1075 metros, com aquisição na faixa angular de $\pm 20°$, frequência de repetição de pulsos de 200kHz/canal, e frequência de escaneamento de 40Hz (MORSY; SHAKER; EL-RABBANY, 2017). As nuvens de pontos foram registradas geometricamente e exportadas em formato LAS versão 1.2.

3.2.3 Processamento dos dados

Os dados foram pré-processados utilizando o LAStools (ISENBURG, 2018). Inicialmente utilizou-se o lasground para classificar os retornos referentes ao solo (step: 25m, bulge: 2.5, offset: 0.05). Em seguida, foi realizada a classificação dos pontos utilizando o lasclassify com os argumentos padrões.

Figura 3.2. Canais de aquisição do sensor *Optech Titan*.

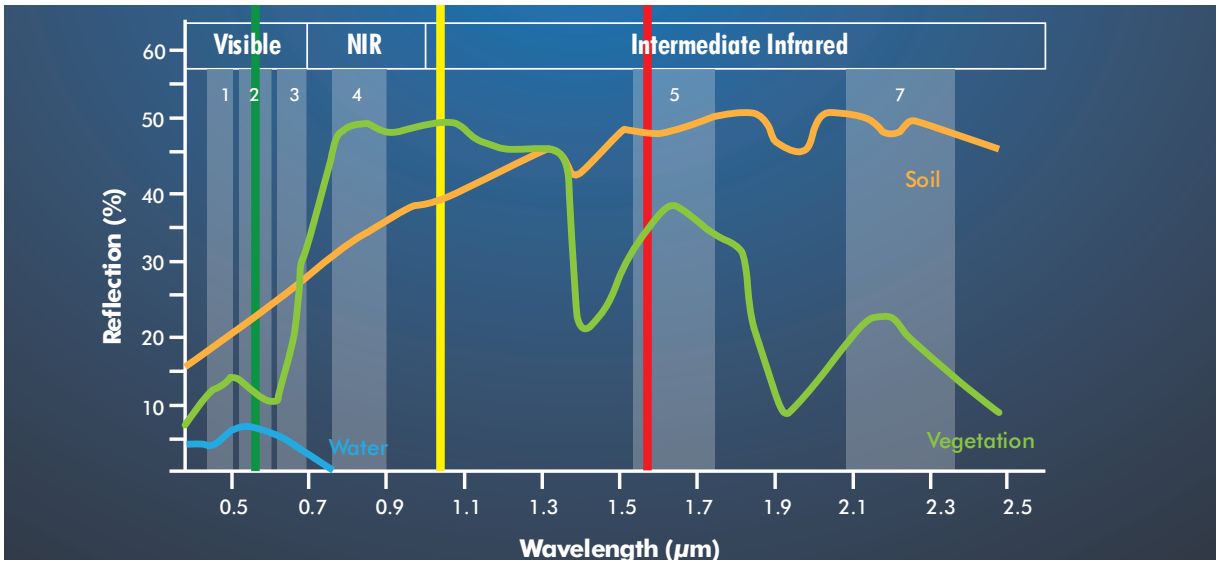

Fonte: Teledyne Optech (2014)

O restante do procesamento dos dados foi realizado utilizando o R (R CORE TEAM, 2020), incorporando os pacotes lidR (ROUSSEL; AUTY, 2020), rLiDAR (SILVA et al., 2017) e outros desenvolvidos ou adaptados pelo autor. As etapas estão resumidas na Figura 3.3.

Figura 3.3. Fluxograma de processamento dos dados

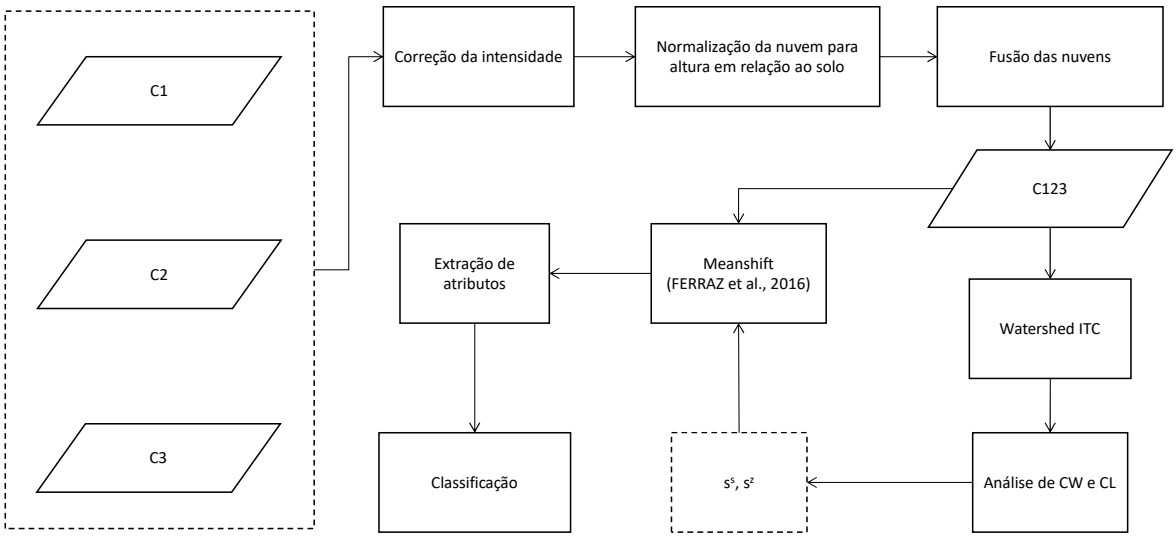

3.2.3.1 Correção da intensidade

Em estudos anteriores utilizando o *Multispectral Optech Titan* (TITAN), foi constatado que os valores de intensidade não são consistentes, mas variam conforme o ângulo de escaneamento (HUO et al., 2018; MATIKAINEN et al., 2017) com valores de intensidade consistentemente menores conforme se afasta do nadir, o que reflete a atenuação da energia decorrente do aumento da distância em relação ao sensor. Os trabalhos anteriores com o TITAN revelaram que a normalização apenas relativa ao aumento

da distância proposta por Luzum, Starek e Slatton (2004) foi o suficiente para a correção, definida pela equação 9.

$$\forall I_i \in I, N_i = I_i \frac{R_i}{R_f^2} \tag{9}$$

Para:

- I: vetor de intensidade dos pontos
- R_i: distância do ponto i em relação ao sensor
- R_f: distância de referência (altitude do voo)

Essa normalização corrige a intensidade baseada no quadrado da distância dos pontos (R_i) para o sensor, em relação à distância ao quadrado distância de referência (em nadir), ou apenas a altitude do voo. A distância dos pontos R_i em relação ao sensor é calculada pela equação 10.

$$R_i = \frac{|R_f - Z_i|}{\cos\theta} \tag{10}$$

Onde Z_i refere-se a altitude no ponto i e θ é igual ao valor do zênite do escaneamento, ou simplesmente ScanAngleRank do formato padrão LAS (THE AMERICAN SOCIETY FOR PHOTOGRAMMETRY & REMOTE SENSING, 2013).

Após esta etapa a nuvem de pontos foi normalizada para altura relativa ao solo, utilizando o algoritmo de triangulação dos retornos classificados como solo.

3.2.3.2 Fusão das nuvens

A aquisição dos canais do TITAN é independente, portanto, gera nuvens distintas, inclusive com características diferentes para o C3, pois neste canal a divergência do feixe do sensor é de $\approx 0,7$ mrad, enquanto C1 e C2 apresentam $\approx 0,35$ mrad (TELEDYNE OPTECH, 2014).

Em publicações anteriores utilizando o TITAN, o uso de métricas relativas entre os canais se revelou importante para o resultado final, como as métricas de diferença normalizada entre dois canais (HUO et al., 2018; KUKKONEN et al., 2019). Contudo, esses estudos utilizaram abordagem por pixels, sendo assim o cálculo foi realizado com base nas métricas de intensidade após a agregação por pixel. No entanto, para se trabalhar com a nuvem de pontos diretamente foi necessária a fusão da intensidade dos canais para cada ponto utilizando o algoritmo do vizinho mais próximo. Esse procedimento foi realizado por meio do pacote em R MultiSpecLiDAR (HAMAMURA, 2020a).

Para obter melhor desempenho, o algoritmo foi desenvolvido em C++ utilizando de indexação para busca, o que reduz a complexidade do algoritmo de $O(n^2)$ para $O(n \log n)$. O algoritmo foi baseado na implementação para o R (R CORE TEAM, 2020), desenvolvido por Gregory Jefferis e Mount (2020), o qual implementa a biblioteca *Approximate Neareast Neightbor Searching* (ANN) de Arya et al. (1998). O ANN consegue acelerar a busca de vizinhos por meio da decomposição hierárquica do espaço em uma árvore balanceada, portanto a busca é reduzida pela metade a cada nó da árvore em vez de buscar em todos os pontos da nuvem (ARYA et al., 1998). O código está disponível na plataforma colaborativa github em código aberto, sob licença GPL-3 (HAMAMURA et al., 2020).

Quanto à fusão por pontos, Morsy, Shaker e El-Rabbany (2017) alegam a existência de dificuldades devido à possibilidade de ocorrer mais de um ponto equidistante em relação ao alvo. Entretanto, a ocorrência desse fenômeno é muito pouco provável em um espaço tridimensional contínuo, sobretudo em copas de árvore (alvo de interesse neste trabalho), onde a superfície é irregular. Por conseguinte, o algoritmo simplesmente utiliza o primeiro vizinho mais próximo, embora possua um parâmetro k para

determinar o número de vizinhos e outro parâmetro $func$ para determinar a função de agregação dos vizinhos, caso se opte por $k > 1$.

3.2.3.3 Delineamento Individual das Copas de Árvore

As copas de árvores foram segmentadas em duas etapas, primeiro utilizando o algoritmo *Watershed*, que consegue separar bem as copas que estão na mesma camada de altura. Inicialmente foram filtrados os pontos até 2 m de altura, depois derivado o CHM de resolução 1 m usando o valor máximo de altura dos pontos. A seguir, a partir do CHM, foi utilizado o algoritmo de busca de topos das árvores por meio da função de máxima local, com raio de busca adaptativo, assim como em Xiao et al. (2019).

Os resultados do *Watershed* foram analisados visualmente dentro das amostras. As árvores bem isoladas com melhor segmentação foram utilizadas para manualmente se estabelecer as relações alométricas entre altura da base da copa (CBH, *crown base height*), altura da copa (CL, *crown length*), largura da copa (CW, *crown width*) e altura da árvore para encontrar o melhor modelo para derivar o CBH e derivar os parâmetros s^s e s^z do Mean Shift adaptativo (FERRAZ et al., 2016) (MS). Essas métricas das árvores foram esquematizadas na figura 3.4.

Figura 3.4. Esquema das métricas utilizadas para as árvores.

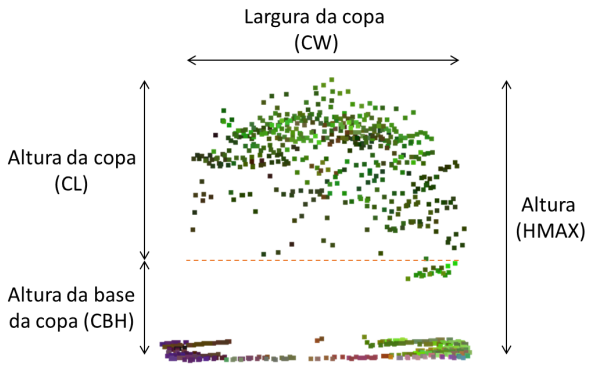

Com os parâmetros s^s e s^z derivados do modelo alométrico linear foi aplicado o MS sobre os dados para obter a segmentação das copas das árvores.

O MS gerou pequenos fragmentos da copa que ficam desconectados do restante, além de retornos classificados erroneamente como vegetação e que precisam de filtragem. Por isso foi necessário realizar uma série de análises iterativas para eliminar esses fragmentos com base em limiares de diferentes métricas da árvore para obter um resultado mais limpo que contenha, em maior parte, apenas segmentos de copas arbóreas.

3.2.3.4 Extração de atributos

Com os segmentos das copas de árvores foi possível prosseguir para a extração de atributos. Os atributos foram divididos em:

1. Estruturais (3D)
2. Espectrais (SPEC)
3. Índices multicanais (MULT)

Esses atributos foram divididos em quatro conjuntos para testar a relevância e simular alguns cenários, são eles:

1. V_3D: apenas atributos 3D
2. V_SPEC: apenas atributos SPEC + MULT
3. V_COMB: atributos 3D + SPEC + MULT
4. V_UNI: atributos 3D + SPEC (apenas canal 2)

O grupo V_UNI foi estabelecido para simular como seria a classificação de espécies usando um LiDAR uniespectraç. Enquanto V_3D, V_SPEC e V_COMB para analisar a relevância dos atributos estruturais e espectrais isoladamente e em conjunto.

Os atributos foram organizados conforme a tabela 3.1.

Tabela 3.1. Tabela de atributos extraídos da nuvem de pontos do LiDAR multiespectral.

Origem	Métrica	Estatísticas	Descrição
I - Estruturais			
3D	H	max, min, mean, sd, ske, kur, range, percentiles (25, 50, 75, 90, 95, 99), IQR	Estatísticas descritivas de altura da copa
3D	CBH	-	Altura da base da copa (m)
3D	CL	-	altura da copa (HMAX – CBH) (m)
3D	CRATIO	-	Razão de altura da copa ($CL/HMAX$)
3D	CAREA	-	Área da copa ($\pi \times CRAD^2$) (m^2)
3D	CW	-	Largura da copa (m) calculada pelo raio médio do polígono convexo (descrição no texto)
3D	CV	-	Volume da copa calculado pelo polígono convexo (m^3)
3D	CSA	-	Superfície da copa calculado pelo polígono convexo (m^2)
3D	CV_H	-	$CV/HMAX^3$ (BUDEI et al., 2018)
3D	C_DENS	-	Densidade da copa em % (razão entre número de retornos $\geq$ CBH e o total de retornos)
3D	BEST_SHAPE	-	Algoritmo para identificação do melhor modelo ajustado para a copa (descrição no texto)
3D	BEST_SHAPE_RMSE	-	Raíz do erro médio quadrático do modelo de forma (descrição no texto)
3D	PAI	-	Índice de área de planta > CBH (*plant area index*) (STARK et al., 2012)
II - Espectrais			

SPEC	C1, C2, C3	max, min, mean, sd, ske, kur, range, percentiles (25, 50, 75, 90, 95, 99), IQR	Estatísticas descritivas da intensidade dos canais
III - Índices Multicanais			
MULT	NDG1	max, min, mean, sd, ske, kur, range, percentiles (25, 50, 75, 90, 95, 99), IQR	Estatísticas descritivas do $NDG1 = ((mean(C_2 - C_3)/(C_2 + C_3))$ adaptado de (BUDEI et al., 2018)
MULT	NDG2	max, min, mean, sd, ske, kur, range, percentiles (25, 50, 75, 90, 95, 99), IQR	Estatísticas descritivas do $NDG2 = ((mean(C_1 - C_3)/(C_1 + C_3))$ adaptado de (BUDEI et al., 2018)
MULT	NDIR	max, min, mean, sd, ske, kur, range, percentiles (25, 50, 75, 90, 95, 99), IQR	Estatísticas descritivas do $NDIR = ((mean(C_1 - C_2)/(C_1 + C_2))$ adaptado de (BUDEI et al., 2018)

A largura da copa (CW) teórica seria equivalente ao diâmetro médio da copa. Dessa forma, para derivar o cálculo do diâmetro da copa utilizou-se um método geométrico levando em consideração apenas a distribuição (x, y) da copa sem a dimensão da altura (figura 3.5).

Figura 3.5. Polígono de exemplo de pontos da copa em cinza, extraindo o polígono convexo, seus vértices P, medianas M e centroide G.

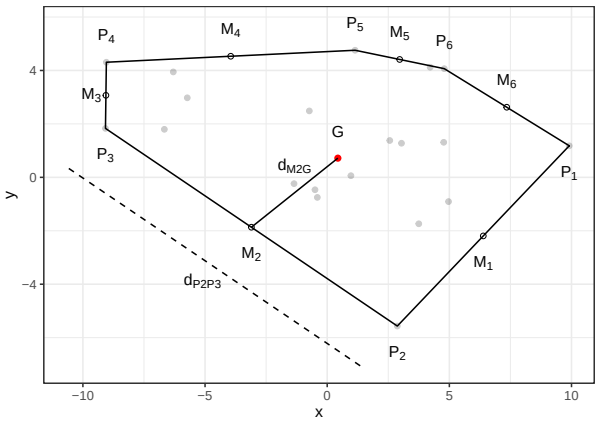

Utilizando os retornos da copa foi derivado o polígono convexo (EDDY, 1977), a partir do qual se mediu o raio médio. Para obter o raio médio do polígono convexo, calculou-se o centroide G pelo método de divisão em triângulos. Por fim, o raio médio $\bar{r}$ pode ser calculado com base no centroide G, utilizando a equação:

$$\bar{r} = \frac{\sum_{i=0}^{n-1} d_{M_iG}\ d_{P_iP_{i+1}}}{\sum_{i=0}^{n-1} d_{P_iP_{i+1}}} \tag{11}$$

Onde,

- d: distância entre dois pontos;

- M_i: mediana entre os pontos P_i e P_{i+1};
- P_i: vértice i do polígono convexo
- G: centroide do polígono convexo

Por fim, a métrica CW pode ser considerada como $2\bar{r}$.

A métrica BEST_SHAPE foi desenvolvida utilizando com base nos formatos de copa apresentados no pacote de (SILVA et al., 2017). A figura 3.6 demonstra um exemplo do resultado do algoritmo desenvolvido.

Figura 3.6. Nuvem de pontos com a métrica BEST_SHAPE extraída utilizando o algoritmo desenvolvido na tese.

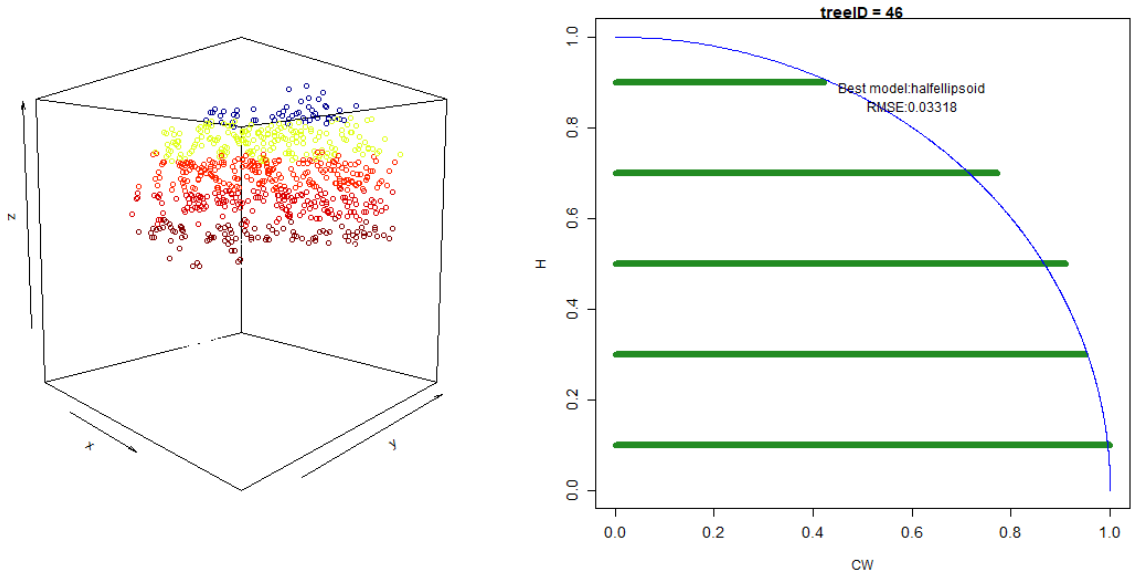

O algoritmo de escolha do melhor modelo subdivide a copa do CBH ao topo em n fatias de altura, o presente estudo considerou $n = 5$. Para cada fatia, utiliza-se do algoritmo anteriormente descrito para o cálculo do CW. Os CW de referência são derivados matematicamente para cada um dos modelos de formato de copa: elipsoidal, meio-elipsoidal, cônico e cilíndrico. Assim é possível calcular também o RMSE (raíz do erro quadrático médio) de desvio em relação ao modelo geométrico.

Todas as métricas que utilizam a intensidade foram baseadas apenas em retornos únicos para evitar valores de intensidade referentes à energia fracionada, conforme discutido posteriormente nos resultados.

3.2.3.5 Seleção de Atributos e Classificação

Para a seleção de atributos utilizou-se o seletor *wrapper* de estratégia gulosa e seleção iterativa para frente, i.e. para cada classificador utilizado seleciona-se o atributo que apresenta o melhor resultado, em seguida o atributo é fixado no modelo e seleciona-se o próximo iterativamente, até que não exista um incremento quantitativo na acurácia do resultado final ou que atinja o melhor resultado possível (HAN, 2019).

A acurácia dos resultados foi calculada pelo método de validação cruzada *K-fold* estratificado com K=6 (tamanho da menor classe) e 10 repetições de reamostragem. O *K-fold* repetido tem sido

considerado mais estável, apresentando menor viés em relação ao bootstrapping (KIM et al., 2009). A acurácia geral foi utilizada como função de mensuração da qualidade do resultado:

$$AG = \frac{n_{corretos}}{n_{total}} \tag{12}$$

O principal problema da acurácia geral é que ela mede apenas o número total de acertos do modelo sem levar em consideração a possível baixa especificidade do classificador para determinadas classes. Isso é especialmente verdadeiro se houver predomínio de alguma classe na amostra analisada, pois um modelo classificador que sempre rotule um objeto para a classe mais comum vai ter alta acurácia geral, mesmo sem poder algum de discriminar outras classes. Para contornarmos este problema foi utilizada a métrica denominada escore F1-macro baseado no escore F1 (WU; ZHOU, 2017).

Tradicionalmente o escore F1 é usado para problemas binários, no entanto é possível adaptá-lo para problemas multiclasse. Basicamente, o escore F1 seria uma média harmônica entre acurácia do usuário, chamado de precisão em problemas de classificação binária e a acurácia do produtor, denominada revocação.

A acurácia do usuário (precisão) pode ser entendida como: dado um objeto aleatório classificado como L, qual a probabilidade de ele realmente pertencer a L? Por outro lado, a acurácia do produtor (revocação), pode ser interpretada como: dado um objeto conhecido que pertence a classe L, qual probabilidade do classificador realmente classificá-lo como L?

Consequentemente o escore F1 para problemas de classificação multiclasse gera uma avaliação harmônica do quão confiável é a classificação de uma determinada classe. Assim, cada classe possui um escore e o escore F1-macro sintetiza os escores F1 de cada classe pela média aritmética. Isso faz com que o escore não seja sensível ao desbalanceamento, mas atribua um peso igual para a confiabilidade da classificação de cada classe (WU; ZHOU, 2017). Outra vantagem do escore F1 para problemas multiclasse é a possibilidade de analisar sua dispersão entre as classes utilizando, por exemplo, o desvio padrão que retrata o quão estável é o classificador entre as diferentes classes. Devido ao uso da média harmônica, quando a precisão ou revocação são iguais a 0, teremos um erro na operação, por isso sempre que isso ocorria foi considerado o F1 da classe como sendo 0.

Outras métricas de mensuração da qualidade também foram analisadas como o Kappa de Cohen (kappa) (COHEN, 1960) e o Índice de Correlação de Matthews (MCC, *Matthews Correlation Coefficient*) (MATTHEWS, 1975). Embora o MCC tenha surgido no contexto de classificação binária, a métrica foi adaptada para problemas multiclasse (GORODKIN, 2004).

O índice kappa vem sendo utilizado praticamente como padrão na área de sensoriamento remoto, sobretudo em classificação de uso do solo (HUO et al., 2018; VERMA et al., 2020), mesmo depois de Pontius e Millones (2011) terem feito uma severa crítica principalmente pela subjetividade na interpretação do valor, mas também por usar como base para comparação a concordância aleatória, o que pode não ser a melhor referência em todos os casos. Os autores do referido estudo sugerem o uso do erro de alocação e quantidade, mas no contexto de classifição orientada a objetos o erro de quantidade tem pouco sentido, uma vez que apenas analisa as proporções resultantes das classes, portanto seria possível atingir erro de quantidade 0 mesmo com todos os objetos classificados incorretamente, o que não tem sentido prático.

O MCC tem sido altamente estudado e recomendado para problemas binários (BOUGHORBEL; JARRAY; EL-ANBARI, 2017; CHICCO; JURMAN, 2020), já para problemas multiclasse essa métrica foi pouco estudada (SILVA; ZANCHETTIN, 2017; SIGDEL; AYGÜN, 2013) e na área de sensoriamento remoto não foi encontrada qualquer publicação fazendo uso dela.

Os classificadores testados para os dados foram:

- Classificador de máxima verossimilhança (MLC)

- *Support vector machine* (SVM): Meyer et al. (2019)
- *Random Forest* (RF): Liaw e Wiener (2002)
- Análise de discriminante linear (LDA): Venables e Ripley (2002)
- k-vizinhos mais próximos (kNN): Crookston e Finley (2007)

Todos os algoritmos têm pacotes diponíveis no R, conforme referências mencionadas, com exceção do classificador por máxima verossimilhança, pois ele não possui implementação para tipo de dados tabulares, ainda que seja considerado praticamente o padrão em aplicações de classificação por pixel em imagens multiespectrais, inclusive com pacotes disponíveis para aplicar diretamente em raster. Consequentemente, foi necessário o desenvolvimento de um pacote para este trabalho. O pacote desenvolvido utiliza a biblioteca de álgebra linear Armadillo por meio do RcppArmadillo (EDDELBUETTEL; SANDERSON, 2014). A biblioteca Armadillo (SANDERSON, 2016), apresenta implementação altamente eficiente de algortimos de álgebra linear, fazendo com que o algoritmo de máxima verossimilhança tenha sido adaptado para executar de forma vetorizada.

Segundo Mather (1985), a verossimilhança ou probabilidade de determinado objeto x pertencer a classe k é de:

$$P_k(x) = \frac{1}{2\pi^{n/2}\sqrt{|S_k|}} e^{-0,5\left[(x-\bar{x}_k)^T S_k^{-1}(x-\bar{x}_k)\right]} \tag{13}$$

Em que,

- x: vetor a ser predito
- n: número de classes
- S_k: matriz de covariância dentro da classe k
- $\bar{x}_k$: vetor de médias de cada variável para a classe k

Ao invés de maximizar a equação 13, Mather (1985) simplifica o problema retirando o logaritmo natural de $P_k(x)$, e minimizando a função $F(lnP_k(x))$, definida como:

$$F(lnP_k(x)) = \ln|S_k| + (x-\bar{x}_k)^T S_k^{-1}(x-\bar{x}_k) \tag{14}$$

No algoritmo proposto $\ln|S_k|$, $\bar{x}_k$ e S_k^{-1} são guardados na memória ao se treinar o modelo. Enquanto a equação 14 é vetorizada para calcular a verossimilhança de apenas um objeto por vez foi possível se valer de programação linear para calcular $F(lnP_k(x))$ para todos os objetos de interesse utilizando a equação 15. Considerando $\vec{X}$ o vetor de todos os objetos x a serem preditos e $\vec{F}(lnP_k(\vec{X}))$ o vetor de todos os valores $F(lnP_k(x))$ para o vetor $\vec{X}$, temos:

$$\vec{F}(lnP_k(\vec{X})) = \ln|S_k| + \left\{\left[(\vec{X}-\bar{x}_k)S_k^{-1}\right] \circ (\vec{X}-\bar{x}_k)\right\}\vec{1}_v \tag{15}$$

Onde,

- $\circ$: multiplicação por elemento ou Produto de Hadamard
- $\vec{1}_v$: vetor de 1, com v elementos (a multiplicação sobre esse vetor resulta em uma soma por linha)
- v: número de variáveis

O algoritmo está disponível em código aberto (HAMAMURA, 2020b).

Para o treinamento e validação dos classificadores, as árvores foram identificadas por meio de fotografias disponíveis na plataforma Google Street View (GOOGLE, 2018).

Por fim o resultado final foi analisado com base em amostras de teste obtidas em 100 indivíduos resultantes da segmentação.

3.3 Resultados e Discussão

3.3.1 Normalização da intensidade com base no ângulo de escaneamento

A análise dos resultados obtidos pela normalização da intensidade foi realizada pela observação da distribuição dos valores de intensidade em classes de ângulos de escaneamento distintas.

Considerando que os valores de intensidade deveriam estar igualmente distribuídas entre as classes de ângulos de escaneamento, seria possível verificar o desvio ocasionado pela atenuação sistemática da energia. Dessa forma, na Figura 3.7 é possível notar a redução da diferença das distribuições das classes de ângulos de escanemaento, entre os dados brutos e normalizados, em que verifica que é possível verificar que os dados normalizados possuem curvas mais próximas entre as classes de ângulo [0,5) e [15,20].

Figura 3.7. Efeito da normalização da intensidade por classe de intensidade.

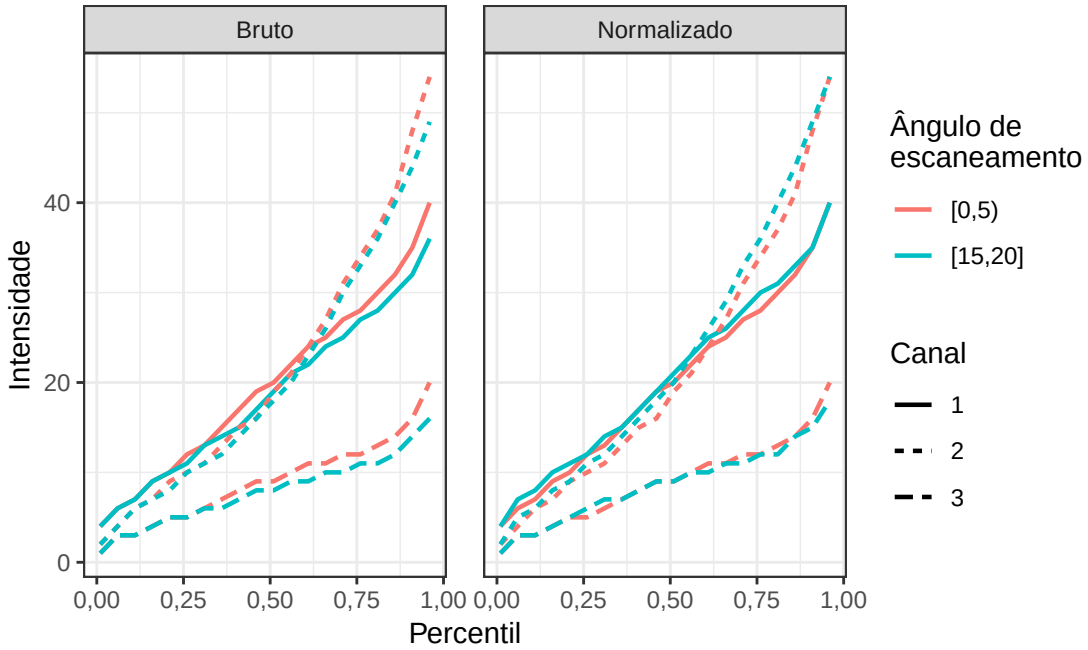

3.3.2 Fusão das Nuvens

O resultado da fusão das nuvens pode ser visualizado na figura 3.8, no lado esquerdo (a), utilizando todos os retornos, e no lado direito (b) apenas os retornos únicos. Nota-se que o padrão de cores é consistente conforme o material do objeto refletido, o que demonstra que a fusão pelo vizinho apresenta o resultado esperado.

Na figura 3.8a, alguns retornos possuem coloração mais vibrante principalmente nas bordas de telhados e outros objetos elevados, em corpos d'água e objetos com alta reflectância como carros.

O efeito nas bordas pode ser explicado pelo fato de o pulso laser atingir o alvo apenas parcialmente, portanto obtendo valores de intensidade distorcidos. Este fenômeno pode ser mitigado utilizando-se apenas os pulsos de retorno único (figura 3.8b). Contudo, isso não impede completamente o efeito

Figura 3.8. Nuvem de pontos em falsa cor, vermelho=C1, Verde=C2 e Azul=C3, após fusão das nuvens independentes. a) Todos os retornos da nuvem. b) Apenas retornos únicos.

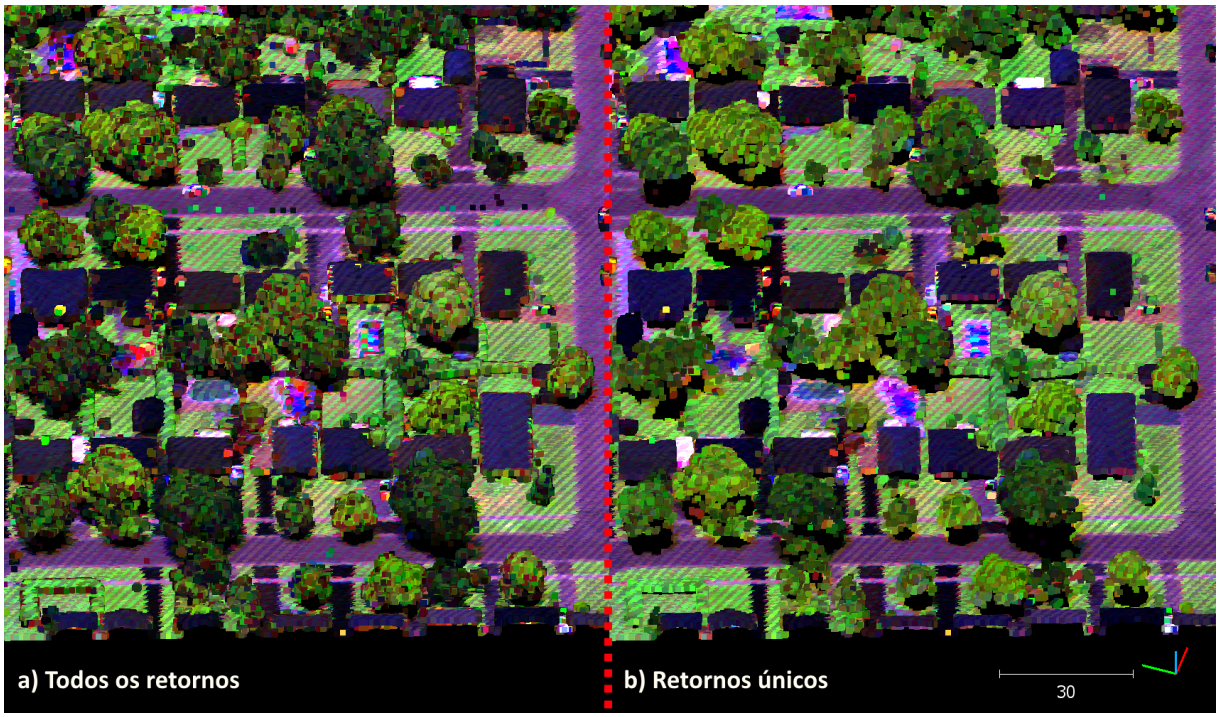

dado que a fração restante do feixe laser pode não produzir outro retorno, o que faz com que esses pontos sejam mantidos como retornos únicos. Conforme podemos ver na figura com retornos únicos apenas, as copas de árvore também ficam com cores mais suaves com menos efeito de retornos de pulsos parciais.

Ao se utilizar apenas retornos únicos removemos grande parte dos retornos de vegetação, uma vez que muitos pulsos atravessam as primeiras folhas da copa e apresentam múltiplos retornos. Assim, para se utilizar métricas referentes à intensidade é importante utilizar apenas retornos únicos, mas para preservar o máximo da informação espacial os múltiplos retornos são importantes, ou seja, é interessante manter a nuvem completa.

Em corpos d'água, a distorção nos retornos se deve às suas propriedades espectrais, o que faz com que os canais C1 e C2 (figura 3.9b) não gerem retornos, pois a água apresenta absorção quase total da energia nesse espectro, logo, o algoritmo não encontra vizinhos correspondente a água e sim pontos das bordas que representam outros materiais. Como o objeto de interesse neste estudo é apenas a vegetação, não há a necessidade de corrigir este problema.

3.3.3 Delineamento Individual das Copas de Árvore

A partir do resultado do *Watershed* as árvores foram analisadas visualmente pelas nuvens de pontos. Os indivíduos bem delineados foram usados para ajustar o modelo alométrico para o Mean Shift e determinar a melhor forma de calcular a altura da base da copa (CBH, *crown base height*), determinando manualmente nas árvores por meio interativo delimitando um plano de corte na nuvem de pontos na altura selecionada.

Nas cinco parcelas foram escolhidas 137 árvores que foram bem delineadas. Com a definição manual do CBH, foi possível comparar o CBH manualmente delimitado com diferentes formas de calcular a métrica a partir da nuvem, conforme a figura 3.10

Diferentemente de florestas naturais, que possuem mais de uma camada de vegetação, a ar-

Figura 3.9. Detalhe de corpo d'água colorido por: a) falsa cor; b) por canal, vermelho C1, verde C2 e azul C3.

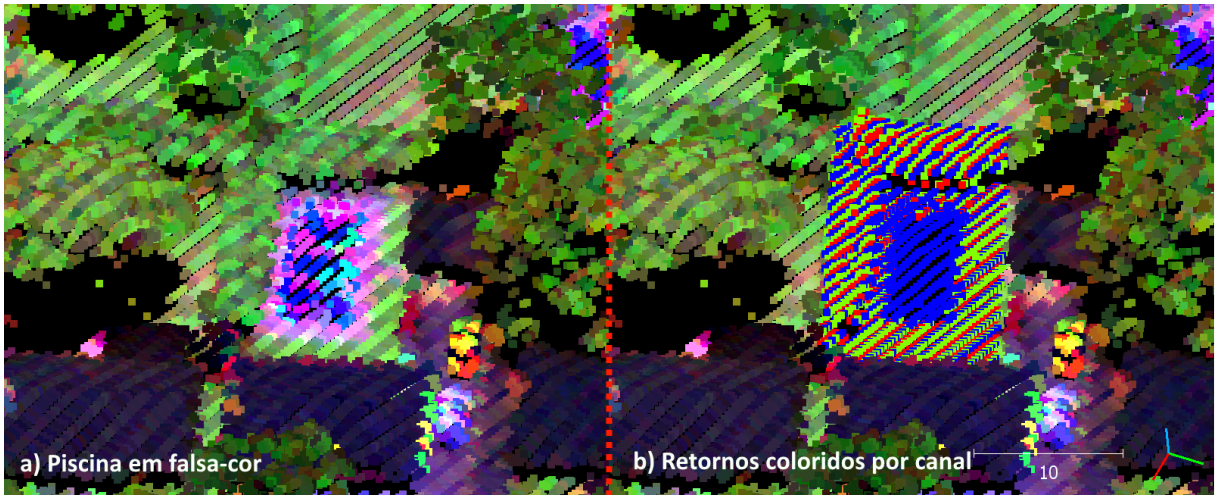

Figura 3.10. Relação entre altura da base da copa (CBH) e outras métricas extraídas da nuvem de pontos.

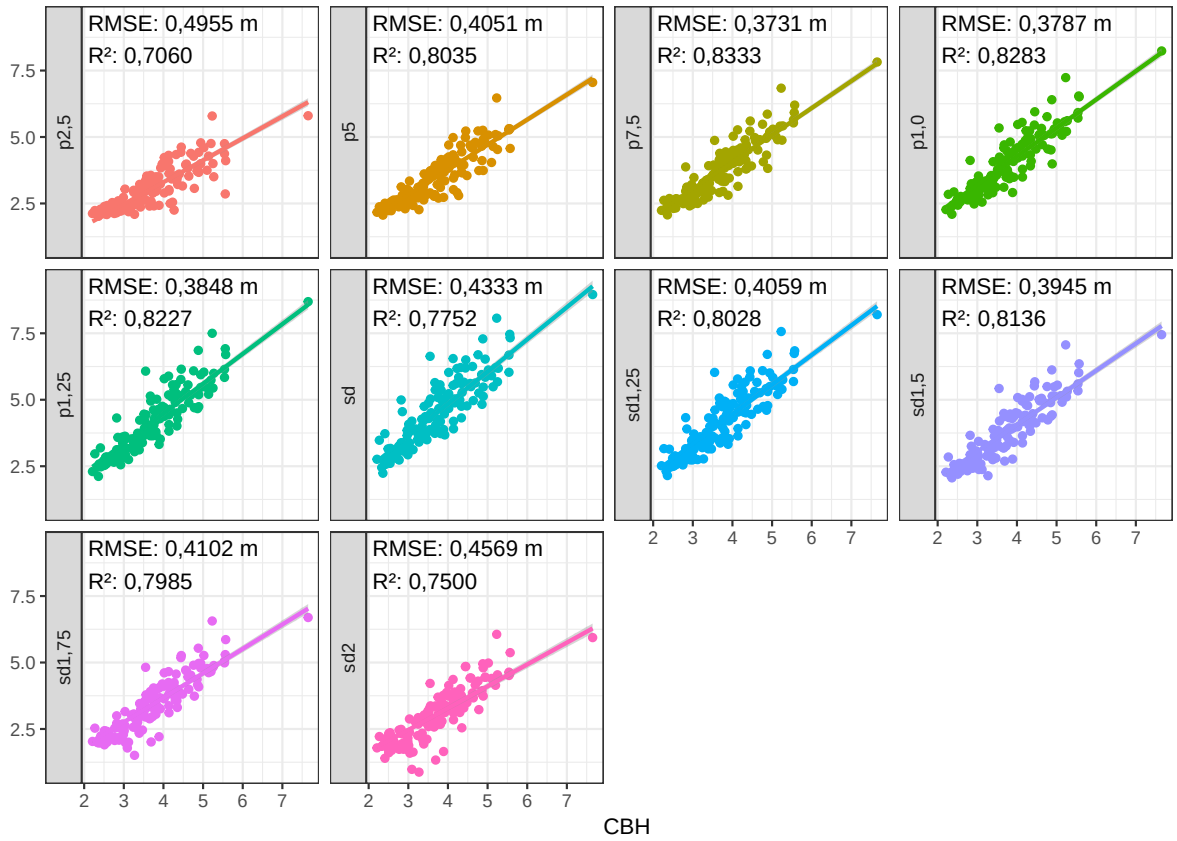

borização urbana normalmente é livre de sub-bosque, apenas apresentando estrato herbáceo em alguns casos. Por isso, ao contrário do que foi constatado por Ferraz et al. (2016), o desvio padrão da primeira gaussiana não apresentou os melhores resultados. A melhor métrica foi obtida pelo pencentil 7,5 que foi escolhido como preditor do CBH.

O CBH delimitado manualmente também foi utilizado para estabelecer a relação alométrica entre altura da copa (CL), calculado como $H_{max} - CBH$ e a altura da árvore (HMAX). A largura da copa (CW) foi derivada pelo algoritmo descrito na seção 3.2.3.4 utilizando o raio médio do polígono convexo. A relação CW x H e CL x H podem ser visualizadas na figura 3.11.

Figura 3.11. Relações alométricas entre altura (m) x altura da copa (m) e altura (m) x largura da copa (m).

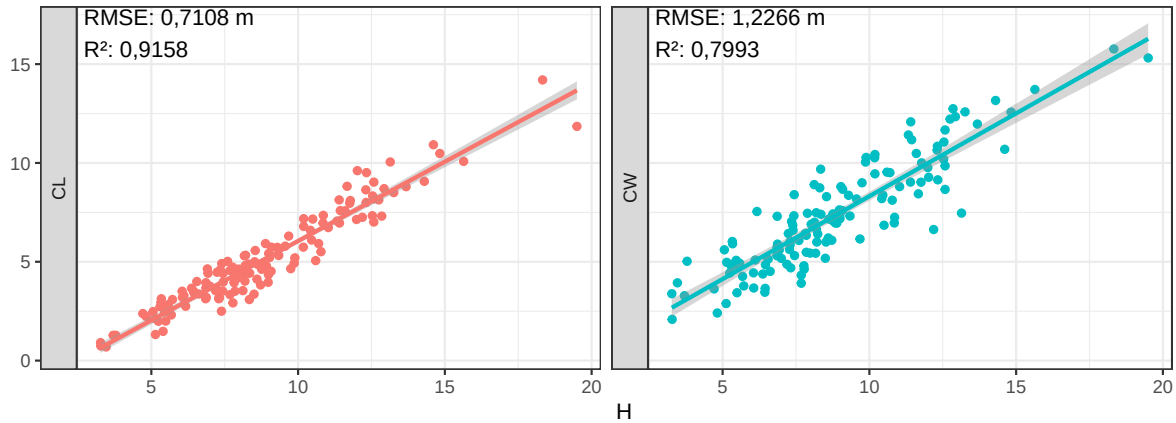

A métrica CL apresentou melhor ajuste em relação à CW tanto com R^2 maior quanto com menor erro quadrático médio. Isso pode ser explicado pela existência de coníferas e latifoliadas que apresentam relação bem distinta, principalmente para a largura da copa. Dado este fato, é de se esperar que o ajuste não seja tão acurado, mas ainda assim o erro quadrático médio para CW ficou abaixo dos 1,3 metros.

A partir dos modelos alométricos ajustados é possível se obter os parâmetros do algoritmo de segmentação Mean Shift adaptativo (FERRAZ et al., 2016) s_s e s_z pelo coeficiente angular das retas, que apresentaram valor de 0,83891 e 0,598476 respectivamente. Os fatores são multiplicados pela altura do ponto para obter a largura (s_s) e a altura (s_z) do cilindro de busca.

O resultado do processo de segmentação pode ser visualizado na figura 3.12. A segmentação apresenta resultados visulmente satisfatórios, separando com sucesso a vegetação rasteira sob a copa da árvore. Entretanto, o resultado da classificação *High Vegetation* do LiDAR utilizando o LAStools não é suficiente para remover a vegetação rasteira, por isso um pós-processamento para limpeza foi necessário.

O processo de limpeza neste caso não pode ser realizado de forma ingênua utilizando apenas um limiar de altura, dado que existem coníferas cuja copa se extende até muito próximo do solo. Em vez disso, foi possível usar os próprios segmentos identificados pelo MeanShift e remover essas estruturas baseadas em limiares de métricas, excluindo valores que não correpondem ao esperado para copas de árvore. Por exemplo, com número muito baixo de retornos, ou ainda com razão entre largura da copa e altura da copa distorcidos. Assim essas feições foram iterativamente removidas ordenando as métricas de interesse e analisando cada segmento quanto a representar ou não copas de árvores até encontrar um limiar adequado.

O resultado do processo de filtragem pode ser visualizado na figura 3.13. Em azul estão representadas as árvores que permaneceram após o processo de filtragem; em vermelho foi realizada uma

Figura 3.12. Resultado da individualização das copas de árvores pelo algoritmo Mean Shift adaptativo de Ferraz et al. (2016). As árvores estão coloridas aleatoriamente, cores contíguas representam um segmento.

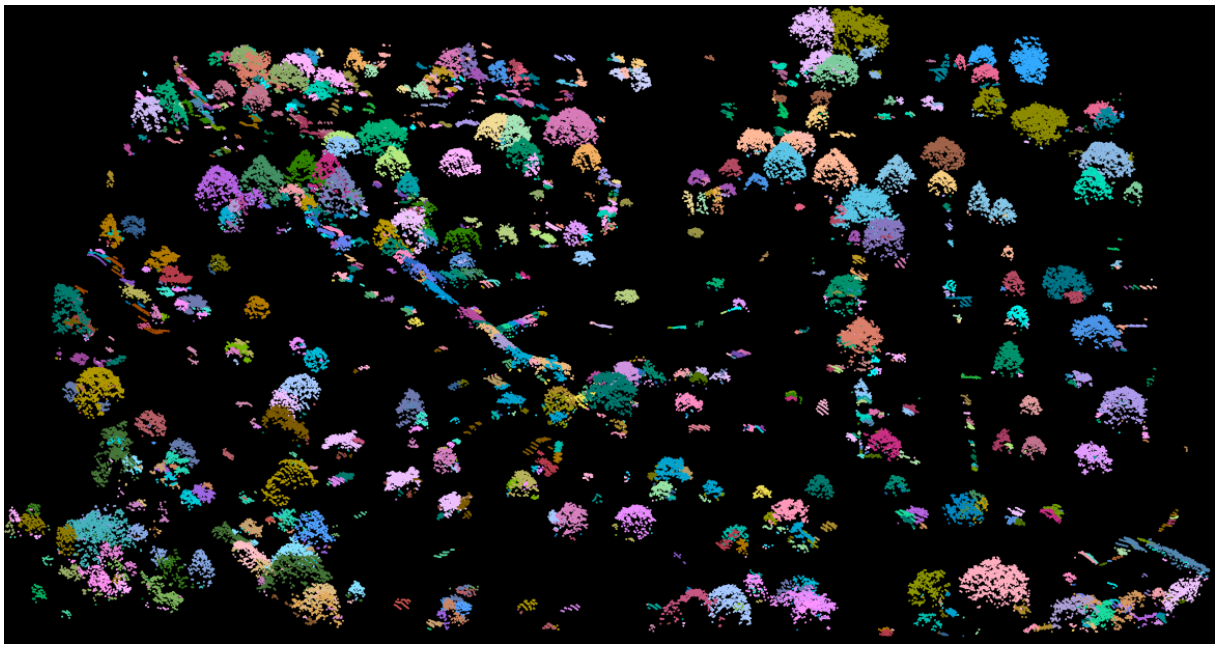

Figura 3.13. Remoção dos segmentos que não possuem características de copa de árvores utilizando limiares de métricas espaciais extraídas da nuvem. Azul: árvores mantidas; vermelho: remoção baseada na divisão em fatias de altura e número mínimo de retornos não colineares; amarelo: CV/CSA <= 0,33 (objetos chatos, muita superfície pouco volume); verde: diâmetro máximo/diâmetro mínimo > 2,5

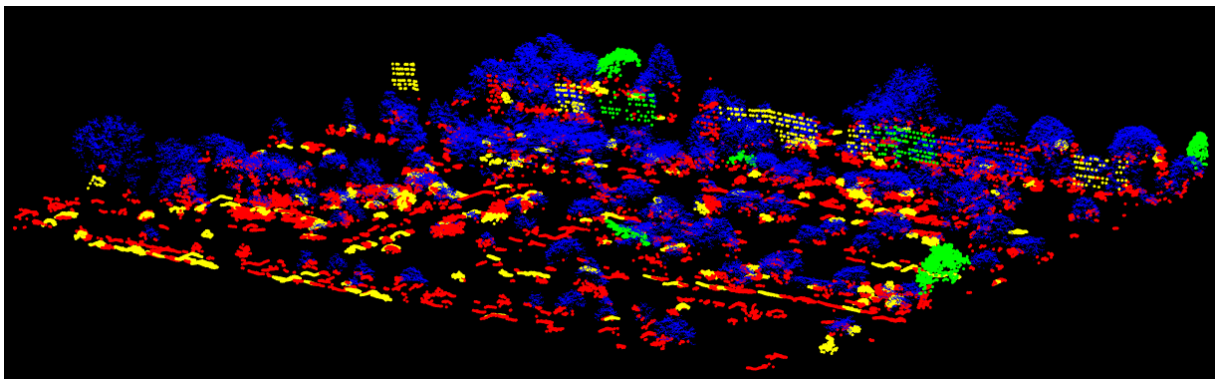

filtragem baseada no algoritmo de detecção de melhor forma, onde a divisão em cinco fatias de altura precisavam conter pelo menos 3 pontos não colineares para poder derivar o polígono convexo; em amarelo foram filtrados os segmentos com $CV/CSA <= 0,33$, i.e. segmentos cujo prisma convexo possua alta relação de área de superfície em relação ao seu volume, caracterizando objetos mais delgados; em verde estão os segmentos cuja relação entre diâmetro maior e diâmetro menor seja maior do que 2,5, sendo que o cálculo do diâmetro maior e menor foi realizado por meio do algoritmo rotação de pinças (*rotating calipers*) sobre o polígono convexo (SHAMOS, 1978).

Esse processo de filtragem removeu grande parte dos segmentos que não consistem em copas de árvores e presevou as copas baixas das coníferas, diferentemente de um filtro simples por altura, como utilizado em outros estudos (FERRAZ et al., 2012; XIAO et al., 2019). Algumas árvores das bordas também foram removidas.

Em outros estudos pouca atenção é dada ao processo de filtragem. Dado que a maioria dos estudos em área urbana utiliza agregação baseada rasterização em vez de individualizar as copas de árvore (ALONZO; BOOKHAGEN; ROBERTS, 2014; VOSS; SUGUMARAN, 2008; SUGUMARAN; VOSS, 2007), provavelmente esses problemas ficam menos evidentes uma vez que não usam o espaço trimensional completo.

3.3.4 Seleção de atributos e classificação

No total foram identificadas para treinamento 159 árvores de 9 espécies diferentes nos cinco blocos amostrais. Dentre elas, 146 indivíduos estavam no conjunto de dados divididas em 8 espécies. As espécies com menos de 5 indivíduos foram agrupadas na classe "outras", permitindo assim que fosse criado um modelo que identificasse árvores que não pertençam às classes alvo. Os indivíduos identificados estão distribuídos segundo a tabela 3.3.4

Tabela 3.2. Árvores identificadas nas cinco amostras de 200 x 200 metros.

Espécie	Quantidade
Acer saccharum (Bordo)	70
Picea spp. (Abeto)	24
Tilia americana (Tília)	14
Populus tremuloides (Álamo)	10
Fraxinus sp. (Freixo)	6
Quercus sp. (Carvalho)	15
Outras	6

Entre as 13 árvores não encontradas 5 apresetavam erro de segmentação, duas delas não foi possível estabelecer a localização exata e 6 eram de porte pequeno e foram filtradas.

Algumas copas não apresentaram qualquer retorno no C3. A hipótese é que isso se deva a dois fatores: 1) a alta absorbância da energia visível pela vegetação; 2) o C3 possui divergência do pulso laser $\approx 0,7$ mrad, o que faz com que a 1075 m de altitude o pulso tenha um feixe de largura $\approx$ 70 cm ao atingir o solo, contra $\approx$ 30 cm dos demais canais, o que pode fazer com que o árvores com baixo índice de área foliar não gere retornos.

Em decorrência disso, as variáveis baseadas apenas no C3 precisaram ser preenchidas com valor 0, pois a ausência de dados nesse canal consiste em informação podendo refletir tanto a baixa reflectância da árvore quanto o baixo índice de área foliar.

O processo de seleção das variáveis utilizando o seletor *wrapper* de estratégia gulosa e seleção iterativa para frente demonstram maior importância para os atributos espectrais, conforme a tabela 3.3, onde os dois primeiros atributos foram espectrais para todos os algoritmos.

Tabela 3.3. Atributos estruturais e espectrais (V_COMB) selecionados por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold.

LDA	MLC	RF	SVM
SPEC_75_C1	SPEC_MEAN_C1	SPEC_75_C1	MULT_MEAN_NDIR
(67,0 ± 0,3)	(56,9 ± 0,9)	(63,9 ± 1,5)	(66,2 ± 0,5)
SPEC_MEAN_C2	SPEC_MEAN_C2	SPEC_MEAN_C2	SPEC_95_C2
(76,7 ± 1,1)	(78,8 ± 0,8)	(77,8 ± 1,5)	(76,1 ± 1,2)
3D_CAREA	SPEC_25_C3	3D_CV_H	3D_HMAX
(82,1 ± 0,8)	(83,0 ± 1,3)	(84,3 ± 2,0)	(81,1 ± 0,7)
MULT_95_RAT2	3D_HKUR	SPEC_99_C3	SPEC_95_C1
(84,8 ± 0,7)	(84,0 ± 0,8)	(87,9 ± 1,5)	(84,7 ± 0,4)
3D_CL	SPEC_SD_C2	MULT_MEAN_NDIR	MULT_95_RAT3
(85,9 ± 0,7)	(84,1 ± 0,6)	(87,8 ± 1,0)	(86,1 ± 0,4)
SPEC_90_C3	SPEC_25_C1	MULT_RANGE_NDG2	3D_CV_H
(87,4 ± 0,7)	(84,5 ± 0,7)	(90,3 ± 1,3)	(87,0 ± 0,8)
3D_CV	SPEC_SKE_C3	MULT_99_NDG1	3D_H50
(88,5 ± 0,9)	(84,5 ± 0,5)	(91,4 ± 1,5)	(88,1 ± 0,6)
MULT_75_RAT1	SPEC_KUR_C1	SPEC_50_C3	
(89,1 ± 0,7)	(85,4 ± 0,9)	(91,9 ± 1,4)	
3D_HSD	3D_HSD		
(89,7 ± 0,5)	(86,1 ± 0,6)		
3D_PAI	SPEC_SD_C1		
(90,5 ± 0,8)	(86,5 ± 0,5)		
3D_HKUR	SPEC_KUR_C2		
(90,6 ± 0,4)	(86,8 ± 0,3)		
SPEC_MAX_C1			
(91,3 ± 0,7)			
3D_HRANGE			
(91,7 ± 0,8)			
MULT_KUR_NDG1			
(92,0 ± 0,6)			
MULT_SKE_RAT2			
(92,1 ± 0,5)			
SPEC_RANGE_C2			
(92,4 ± 0,5)			
SPEC_KUR_C1			
(92,8 ± 0,7)			
MULT_50_RAT3			
(92,8 ± 0,6)			
		Melhor acurácia	
92,8 ± 0,6	86,8 ± 0,3	91,9 ± 1,4	88,1 ± 0,6

Somente com os atributos SPEC e MULT (V_SPEC) já se atinge praticamente a mesma acurácia do uso combinado com atributos estruturais para todos os classificadores, conforme tabela 3.4, o

que demonstra a importância da utilização dos canais multiespectrais para a tarefa de classificação. Esse resultado é consistente com outros estudos utilizando LiDAR multiespectral que demonstram o mesmo padrão (BUDEI et al., 2018; KUKKONEN et al., 2019).

Tabela 3.4. Atributos espectrais selecionados (V_SPEC) por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold.

LDA	MLC	**RF**	SVM
SPEC_75_C1	SPEC_MEAN_C1	SPEC_75_C1	MULT_MEAN_NDIR
(67,0 ± 0,3)	(56,9 ± 0,9)	(63,4 ± 1,5)	(66,2 ± 0,5)
SPEC_MEAN_C2	SPEC_MEAN_C2	SPEC_MEAN_C2	SPEC_95_C2
(76,7 ± 1,1)	(78,8 ± 0,8)	(77,9 ± 1,1)	(76,1 ± 1,2)
SPEC_90_C3	SPEC_25_C3	SPEC_MAX_C3	SPEC_MEAN_C3
(81,1 ± 0,8)	(83,0 ± 1,3)	(83,2 ± 1,0)	(80,6 ± 0,8)
MULT_90_RAT1	SPEC_SD_C1	MULT_MEAN_NDIR	SPEC_25_C1
(83,0 ± 0,5)	(83,6 ± 0,8)	(85,4 ± 1,6)	(83,5 ± 1,1)
SPEC_99_C2	SPEC_SD_C2	SPEC_SKE_C3	MULT_95_NDIR
(85,1 ± 1,0)	(84,1 ± 0,6)	(87,1 ± 1,5)	(83,5 ± 0,6)
SPEC_50_C3	SPEC_SKE_C1	MULT_RANGE_NDG2	MULT_99_RAT3
(87,0 ± 1,1)	(84,1 ± 0,6)	(89,2 ± 1,1)	(83,7 ± 0,8)
SPEC_SD_C1		MULT_MAX_NDG1	MULT_RANGE_RAT3
(87,9 ± 1,3)		(90,1 ± 1,1)	(85,2 ± 1,1)
MULT_KUR_RAT1		MULT_SKE_NDG1	SPEC_99_C2
(87,9 ± 0,9)		(90,2 ± 1,1)	(85,9 ± 0,7)
MULT_SKE_NDG1			SPEC_90_C1
(88,1 ± 0,8)			(86,6 ± 0,7)
			MULT_MEAN_NDG1
			(86,8 ± 0,7)
			SPEC_MAX_C2
			(87,0 ± 0,8)
		Melhor acurácia	
88,1 ± 0,8	84,1 ± 0,6	**90,2 ± 1,1**	87,0 ± 0,8

Dentre os canais espectrais é possível notar que os atributos relacionados ao C1 foram os mais importantes, atingindo acurácia acima de 55% somente com um atributo, em seguida temos C2 seguido pelo C3. Outro fato interessante é que dentre os três primeiros atributos selecionados sempre há a presença dos três canais, diretamente no caso de MLC, LDA e RF, ou indiretamente por índice relativo para o SVM, o que demonstra a complementaridade dos canais para gerar informação ao modelo.

Por outro lado, com o uso apenas dos atributos estruturais (V_3D), há uma redução de mais de 10% de acurácia, chegando a reduzir 44% para o classificador MLC (tabela 3.5). O RF é o que apresenta melhor acurácia geral atingindo 69,2%.

Tabela 3.5. Atributos estruturais (V_3D) selecionados por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold.

LDA	MLC	**RF**	SVM
3D_CRATIO	3D_BESTMODEL	3D_BESTMODEL	3D_CV_H
(54,1 ± 0,6)	(43,2 ± 0,9)	(46,8 ± 2,1)	(54,8 ± 0,7)
3D_CV_H	3D_RMSE	3D_CV_H	3D_CRATIO
(59,2 ± 0,6)	(43,2 ± 0,9)	(63,5 ± 2,3)	(60,8 ± 0,5)
3D_BESTMODEL		3D_HSD	3D_BESTMODEL
(62,8 ± 1,1)		(65,6 ± 0,9)	(63,7 ± 1,4)
3D_CW		3D_CDENS	3D_H50
(65,5 ± 1,1)		(66,6 ± 1,3)	(64,0 ± 1,3)
3D_PAI		3D_H25	3D_PAI
(67,0 ± 1,4)		(69,2 ± 1,5)	(65,2 ± 1,7)
3D_CDENS			3D_HKUR
(67,7 ± 1,8)			(65,5 ± 1,4)
3D_N			3D_CW
(68,9 ± 1,3)			(66,5 ± 0,9)
	Melhor acurácia		
68,9 ± 1,3	43,2 ± 0,9	**69,2 ± 1,5**	66,5 ± 0,9

O LiDAR uniespectral foi simulado restringindo os atributos aos estruturais e aos espectrais derivados exclusivamente do C2 (tabela 3.6), assim como em Kukkonen et al. (2019).

Tabela 3.6. Atributos selecionados para simulação de LiDAR uniespectral (V_UNI) por algoritmo, melhor modelo destacado em negrito. Em cada linha temos o atributo selecionado para o classificador e na linha imediatamente abaixo, entre parênteses a tabela demonstra o valor médio ± desvio padrão entre as 10 repetições da validação cruzada 6-fold.

LDA	MLC	**RF**	SVM
SPEC_MAX_C2	SPEC_MEAN_C2	SPEC_25_C2	SPEC_MAX_C2
(61,2 ± 0,8)	(54,1 ± 0,9)	(59,3 ± 1,8)	(61,4 ± 0,6)
3D_CV_H	3D_H25	3D_CV_H	3D_CV_H
(67,7 ± 0,7)	(64,7 ± 1,2)	(67,2 ± 1,0)	(69,4 ± 1,0)
3D_CRATIO	3D_HRANGE	SPEC_95_C2	3D_CL
(74,5 ± 1,3)	(72,1 ± 0,7)	(73,9 ± 1,3)	(75,0 ± 0,8)
3D_CW	3D_CW	3D_H25	3D_CRATIO
(76,3 ± 1,0)	(75,2 ± 1,0)	(76,1 ± 1,5)	(76,5 ± 0,9)
3D_PAI	3D_HMAX	3D_HSKEW	SPEC_MEAN_C2
(77,9 ± 1,1)	(77,2 ± 1,1)	(79,0 ± 1,0)	(78,6 ± 1,3)
SPEC_SKE_C2	SPEC_RANGE_C2	3D_H99	3D_H25
(78,3 ± 0,7)	(78,8 ± 0,9)	(80,4 ± 1,1)	(80,4 ± 1,2)
3D_CBH	SPEC_KUR_C2	3D_CDENS	3D_CAREA
(79,3 ± 1,3)	(79,0 ± 0,7)	(81,4 ± 1,4)	(80,2 ± 0,7)
SPEC_95_C2	3D_H50	3D_RMSE	

(79,9 ± 0,9)	(79,7 ± 0,9)	(82,3 ± 1,2)	
3D_CDENS	3D_H90	3D_CRATIO	
(80,8 ± 1,6)	(80,0 ± 1,2)	(81,7 ± 0,6)	
3D_N	SPEC_SKE_C2	SPEC_99_C2	
(81,7 ± 1,4)	(80,0 ± 1,1)	(82,8 ± 1,2)	
3D_RMSE	3D_BESTMODEL	SPEC_KUR_C2	
(82,6 ± 1,5)	(79,9 ± 0,9)	(83,4 ± 1,4)	
SPEC_SD_C2	3D_HSKEW		
(82,8 ± 1,6)	(80,2 ± 1,0)		
3D_H25	3D_HMEAN		
(82,8 ± 1,3)	(80,2 ± 0,8)		
	3D_PAI		
	(80,3 ± 0,8)		
	3D_HSD		
	(80,3 ± 0,9)		
	3D_CDENS		
	(80,4 ± 0,8)		
	Melhor acurácia		
82,8 ± 1,3	80,4 ± 0,8	**83,4 ± 1,4**	80,4 ± 1,2

Os resultados apresentaram valores de acurácia variando entre 1,7 a 4,7% menor em relação a se usar todos os atributos, o que indica que um LiDAR uniespectral poderia alcançar resultados muito próximos ao LiDAR multiespectral para esse conjunto de dados. De fato, Kukkonen et al. (2019) chega a mesma conclusão, sobretudo para poucas classes interesse. Nota-se que o atributo mais importante neste caso também foi o espectral, contudo cumpre salientar que após o primeiro atributo espectral todos os modelos selecionam um ou mais atributos estruturais na sequência, o que aponta que os atributos estruturais, neste caso, são complementares para o modelo.

As matrizes de erros estão anexas ao trabalho (anexo1 a anexo16). De forma resumida podemos visualizar os resultados dos diferentes classificadores pela figura 3.14 no gráfico de acurácia do usuário x acurácia do produtor.

O gráfico de acurácia do usuário x acurácia do produtor é bastante útil, pois representa visualmente a qualidade da classificação de cada classe, sendo possível identificar o tipo de erro predominante (inclusão ou omissão). O gráfico está dividido em quatro seções por duas linhas pontilhadas sobre o valor de 0,5 em cada eixo, assim temos uma referência visual da acurácia de cada classe baseado no quadrante em que o ponto está localizado. Classes no 1º quadrante (superior direito) podem ser consideradas como bem classificadas, no 2º quadrante (inferior direito) temos baixa acurácia do produtor, ou seja indivíduos que pertencem à classe estão sendo alocadas em outras classes, falso negativo, ou erro de omissão; no 3º quadrante (inferior esquerdo) estão classes que apresentam as menores acurácias; por fim, no 4º quadrante (superior esquerdo) representam classes com baixa acurácia do usuário, i.e. alta taxa de falso positivos ou erros de inclusão.

Por meio do gráfico apresentado pela figura 3.14 podemos notar que, usando apenas as variáveis espaciais (V_3D, em azul), somente o Abeto (quadrado) permanece com acurácia elevada, exceto para MLC que teve baixa acurácia geral, o que é esperado, já que o Abeto é uma conífera, ou seja, com arquitetura da copa bastante distinta em relação às demais espécies.

Comparando a simulação do LiDAR uniespectral (V_UNI, roxo) ao uso de todas variáveis (V_COMB, vermelho) podemos verificar algumas espécies que praticamente não perdem acurácia como

Figura 3.14. Gráfico de acurácia do usuário x acurácia do produtor para os quatro algoritmos testados: random forest (RF), MLC (máxima verossimilhança), LDA (análise discriminante linear) e SVM (máquina de suporte a vetores). Os conjuntos de variáveis (V_SPEC: variáveis espectrais apenas; V_3D: variáveis estruturais apenas; V_COMB: combinação de espectrais e estruturais; V_UNI: simulação de LiDAR uniespectral com uso de atributos estruturais e espectrais do canal 1064 nm) estão em cores diferentes e as espécies com tipos de ponto diferente conforme a legenda. No limite esquerdo e superior de cada painel temos a acurácia geral média para cada conjunto de atributos com a mesma cor utilizada para a representação dos pontos.

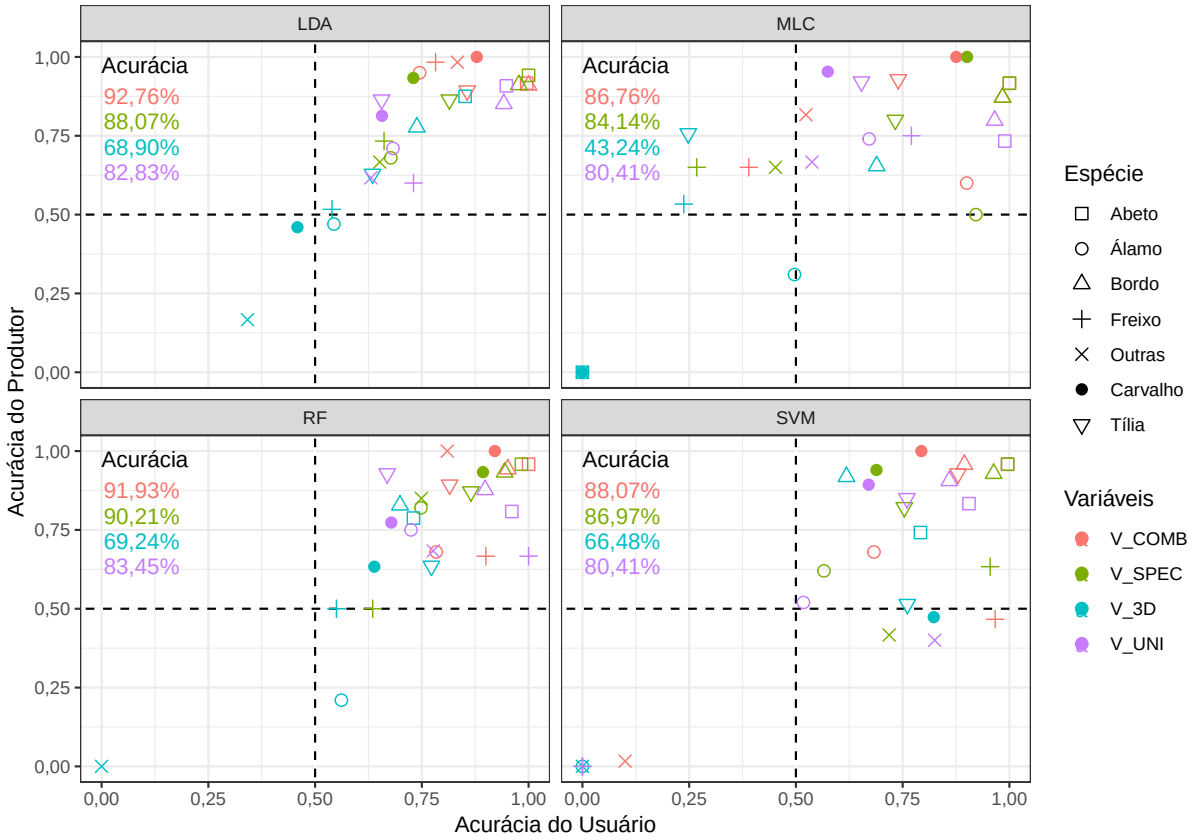

o Abeto, o Bordo e a Tília, enquanto que a classe Carvalho apresenta redução da acurácia para todos os algoritmos. Por outro lado, agregar o C2 aos atributos estruturais (V_3D) claramente melhorou os resultados da classificação elevando a separabilidade de todas as classes.

Outro fato interessante é que o MLC apresenta acurácia especialmente baixa ao usar apenas V_3D, isso porque sendo um classificador paramétrico, que assume distribuição gaussiana para as variáveis e usa apenas as medidas de centralidade e de dispersão e não obtém resultados satisfatórios com diversas variáveis pouco relevantes. Apesar de o LDA (análise discriminante linear) também ser paramétrico e apresentar as mesmas premissas quanto à distribuição dos dados, esse classificador consegue lidar com diversas variáveis fracas atribuindo um peso para cada variável, diferentemente do MLC que não atribui pesos para as variáveis além das medidas de dispersão da matriz de covariâncias.

Notou-se ainda que os classificadores lineares ajustam o modelo de forma a levar em conta todas as classes, mesmo que tenham poucas amostras e apresentam modelos capazes de maior generalização nesses casos, o que pode ser notado principalmente para a classe Outras, em que tanto SVM quanto RF, mesmo com acurácia elevada apresentam resultados piores para as classes Outras, Freixo e Álamo. Isso também pode ter ocorrido devido à escolha a forma como o algoritmo de seleção foi programado, utilizando apenas a acurácia geral como critério de seleção.

Devido a este fator é importante utilizar outras métricas que levem em conta o desbalancea-

mento dos dados, para tanto a tabela 3.7 demonstra a acurácia calculada para diferentes métricas.

Tabela 3.7. Resultado da validação cruzada *leave-on-out* dos classificadores testados com diversas métricas de qualidade: acurácia geral, F1-macro ± desvio padrão do escore F1, Coeficiente de Correlação de Matthew (MCC) e Kappa de Cohen.

Classificador	Variáveis	Acurácia	F1-macro	MCC	Kappa
LDA	V_COMB	0,93	0,90 ± 0,05	0,90	0,90
MLC	V_COMB	0,87	0,78 ± 0,18	0,82	0,82
RF	V_COMB	0,92	0,87 ± 0,11	0,89	0,89
SVM	V_COMB	0,88	0,72 ± 0,33	0,83	0,83
LDA	V_SPEC	0,88	0,80 ± 0,13	0,84	0,84
MLC	V_SPEC	0,84	0,74 ± 0,23	0,79	0,78
RF	V_SPEC	0,90	0,83 ± 0,15	0,86	0,86
SVM	V_SPEC	0,87	0,77 ± 0,17	0,82	0,82
LDA	V_3D	0,69	0,57 ± 0,21	0,56	0,56
MLC	V_3D	0,43	0,25 ± 0,26	0,25	0,23
RF	V_3D	0,69	0,52 ± 0,28	0,55	0,54
SVM	V_3D	0,66	0,39 ± 0,37	0,49	0,46
LDA	V_UNI	0,83	0,75 ± 0,13	0,77	0,76
MLC	V_UNI	0,80	0,75 ± 0,10	0,75	0,74
RF	V_UNI	0,83	0,79 ± 0,08	0,77	0,77
SVM	V_UNI	0,80	0,63 ± 0,32	0,72	0,72

Comparando a acurácia geral com o escore F1-macro e o desvio padrão do escore F1 (F1-sd) podemos perceber que o SVM apresenta valores para F1-macro bem menores em relação à acurácia geral. Como o algoritmo de seleção foi programado com base na acurácia geral, o SVM deve ter sido sobreajustado para elevar a acurácia geral em detrimento da separabilidade de classes com menos indivíduos como o Freixo e Outras. O fato de o SVM ser propenso a sobreajuste já é conhecido e reportado na literatura (CAWLEY; TALBOT, 2010). Por outro lado os demais algoritmos apresentam valores de F1-macro mais próximos da acurácia geral, bem como desvio padrão mais baixo. O desvio padrão baixo indica que existe pouca variabilidade do escore F1 para cada classe, ou seja, pode demonstrar a precisão do classificador, i.e. a sua consistência para os resultados da classificação das diferentes classes.

O F1-macro e desvio padrão do escore F1 parecem ser bastante apropriados para analisar a qualidade da classificação multivariada, pois são de fácil interpretação e capazes de demonstrar, não apenas a acurácia do algoritmo atribuindo peso igual para todas as classes, mas ainda revelando sua precisão, i.e. a consistência da sua acurácia para as diferentes classes. A acurácia geral ainda é relevante, uma vez que para o produto final, o usuário precisa ter confiabilidade que a classificação está representando o cenário real. Se analisarmos apenas o escore F1-macro e desconsiderarmos a acurácia geral em dados muito desbalanceados, podemos obter um classificador que não é tão acurado para determinar a classe predominante, assim um mapa final gerado com base no classificador pode ficar muito subestimado para a classe predominante, que representaria a maior área do mapa, e seria atribuída incorretamente a outras classes.

As métricas Kappa e MCC representam a acurácia levando em conta o desbalanceamento dos dados, conforme podemos ver na tabela 3.7. Essas métricas por si só deixam a análise um pouco subjetiva, além de assumirem a linha de base como sendo a concordância aleatória, confome discutido por Pontius e Millones (2011), no entanto, poucos análises foram realizadas sobre o MCC para problemas multiclasse. Conforme podemos verificar na figura 3.15. As métricas foram calculadas durante a seleção de atributos considerando todos os algoritmos e conjunto de atributos.

Pelos gráficos, podemos notar que MCC e Kappa possuem correlação elevada, portanto parece não haver grande diferença entre adotar uma ou outra métrica.

Figura 3.15. Correlação entre as diferentes métricas de acurácia: acurácia geral (OA), F1-macro, F1-sd, MCC e Kappa.

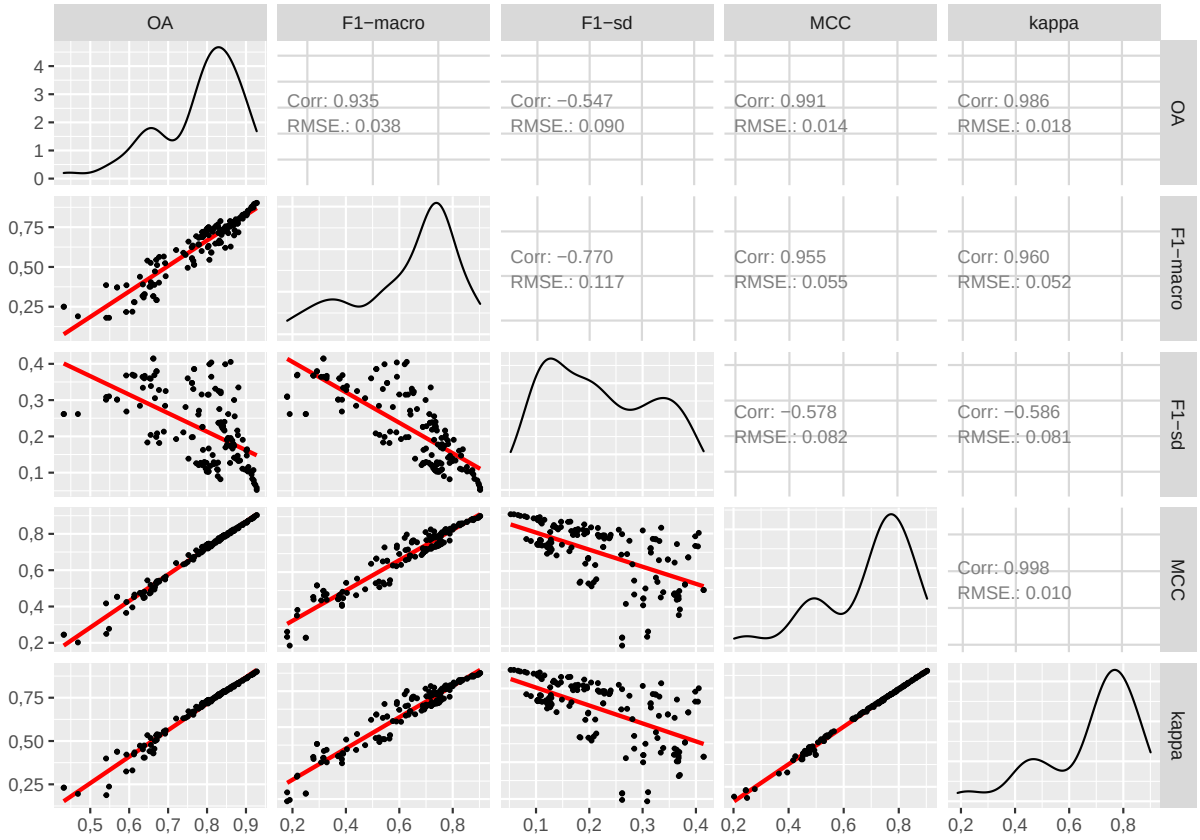

Para esse conjunto de dados, Kappa e MCC também estiveram altamente correlacionados com a acurácia geral, no entanto, isso não significa que não agregam informação em relação a acurácia geral, mas pode significar que não há um desbalanceamento significativo na acurácia entre as classes para a maioria modelos gerados.

Já as métrica F1-macro e F1-sd possuem correlação menor tanto com acurácia geral quanto com kappa e MCC, agregando mais informação. Outra grande vantagem das métricas F1-macro e F1-sd é a interpretação clara, a primeira atribuindo o mesmo peso para a acurácia das diferentes classes, e a segunda demonstrando a consistentência das acurácias entre as diferentes classes.

Sendo assim ao utilizar F1-macro, F1-sd e acurácia geral, o pesquisador pode estabelecer objetivamente o que seria considerado um bom classificador segundo o contexto, diferentemente do Kappa e MCC, que agregam o resultado em uma única métrica comparando o resultado final à linha de base aleatória. Dessa maneira, ao usar Kappa ou MCC não é necessariamente correto constatar que um classificador é melhor que outro por ter valor da métrica maior ou menor.

Todavia é possível definir objetivamente que um bom classificador consegue discriminar bem todas as classes e estabelecer a F1-macro e F1-sd como métricas importantes. Ou ainda, com base na metodologia adotada e distribuição dos dados, adotar a acurácia geral como métrica representativa, desde que as proporções das classes obtidas pela amostragem representem a população e o interesse seja obter uma estimativa não enviesada das proporções de cada classe no resultado final da classificação.

Contudo, em muitos problemas as proporções obtidas pela amostra não refletem as proporções da população, isso porque as amostras de uma classe podem ocorrer de forma agregada, assim uma amostragem aleatória ou sistemática não conseguiria capturar todas as classes. Nesses casos é comum o pesquisador buscar ativamente a variabilidade para amostrar todas as classes, descartando então a

premissa de que as amostras refletem a distribuição da população. Nesses casos, a F1-macro e F1-sd podem ser mais apropriadas ao considerar o cenário ingênuo, atribuindo o mesmo peso para todas as classes, dado que não se conhece a distribuição real da população.

Ainda assim, as métricas Kappa e MCC podem ser importantes, sobretudo na etapa de seleção do modelo, uma vez que levam em consideração o desbalanceamento das classes, podem representar melhor a qualidade do classificador em relação à acurácia geral, conforme constatam Boughorbel, Jarray e El-Anbari (2017).

Ao aplicar os classificadores treinados sobre a área de estudo inteira, escolhendo o melhor resultado de cada algoritmo para a combinação de todos os atributos (V_COMB), obtemos distribuições bem diferentes para cada espécie (tabela 3.8). Isso indica que houve sobreajuste na amostra, caso contrário os diferentes classificadores deveriam calcular quantidades próximas para cada espécie, dado que a acurácia geral atingida foi maior que 85%.

Tabela 3.8. Classificação da área de estudo completa, demonstrando a quantidade de indivíduos em cada espécie por classificador.

Algoritmo	Freixo	Carvalho	Bordo	Outras	Álamo	Abeto	Tília
LDA	1286	640	3143	3856	399	942	3167
MLC	947	876	6883	1896	413	867	1551
RF	98	868	7852	176	1685	1123	1631
SVM	53	464	11139	6	915	389	467

A concordância entre os diferentes classificadores ficou baixa (figura 3.16), sendo que apenas o MLC e RF apresentaram Kappa $> 41\%$, considerado por Landis e Koch (1977) como concordância moderada.

Novamente, demonstra-se a propensão do SVM em sobreajustar na amostra, enquanto o LDA pode ter sobreajustado devido ao número excessivo de atributos selecionados (18), indicando que mesmo um algoritmo paramétrico pode sobreajustar na amostra em decorrência da dimensionalidade excessiva. MLC por outro lado, mesmo com 11 atributos selecionados, maior que os 7 atributos selecionados pelo SVM, demontra ter sofrido menor sobreajuste. O RF também é robusto ao sobreajuste, conforme Breiman (2001), devido à Lei Forte dos Grandes Números.

Verificando os números obtidos pelo SVM, fica evidente que o algoritmo não apresentou capacidade de discriminar entre as espécies, mas em vez disso apenas classificou a maior parte dos indivíduos como Bordo, enquanto os demais algoritmos apresentaram cerca de 30% menos indivíduos.

Pela inspeção manual de 100 indivíduos selecionados aleatoriamente como amostra teste, foi possível constatar que o MLC apresentou o melhor resultado classificando corretamente principalmente o Abeto, Bordo e Tília, enquanto os demais apenas Abeto e Bordo.

Devido à característica do MLC de assumir distribuição normal, a class ”Outras”ficou superestimada. Contudo, os valores kappa de LDA MLC e RF estão dentro do mesmo intervalo de confiança de 95%, e apenas LDA e MLC diferem de SVM que apresenta o Kappa mais baixo (ver figura 3.17).

Com maior número de amostras para as classes menores, provavelmente o RF apresentaria melhores resultados, especialmente para a classe Outras, pois consegue lidar com a natureza não paramétrica dela, enquanto o MLC provavelmente ainda apresentaria baixa acurácia devido à classe não possuir a distribuição gaussiana esperada de um grupo homogêneo.

Analisando com mais detalhes o resultado do MLC (3.18), podemos notar que a maior confusão ocorre dentro das classes Outras, Freixo e Álamo. A classe Outras e Álamo apresentam grande erro de omissão, sendo confundidas com Freixo, Carvalho e Bordo, justamente as espécies que apresentaram menos amostras.

Figura 3.16. Matriz de concordância entre os diferentes classificadores, demonstrando o Kappa ± intervalo de confiança de 95%.

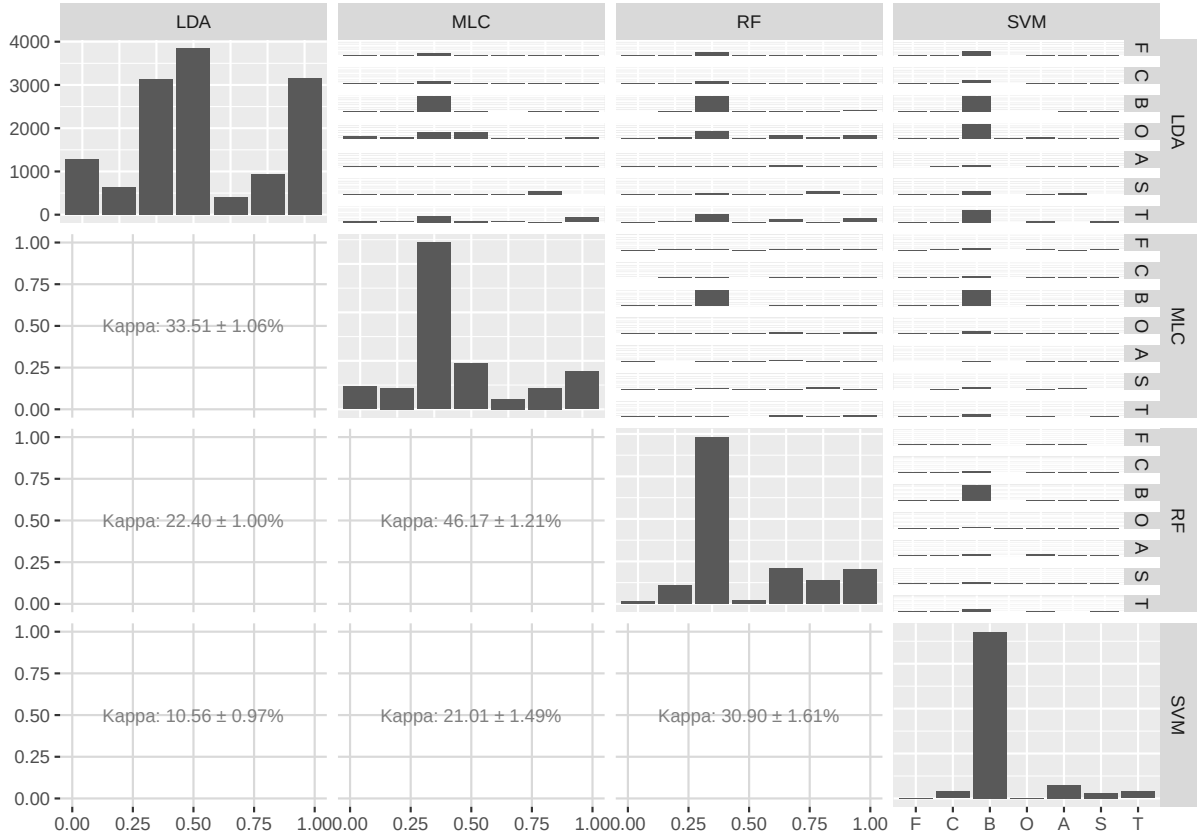

Figura 3.17. Gráfico de acurácia do usuário x acurácia do produtor para os quatro algoritmos diferenciados pela cor e espécies com tipos de ponto diferente, conforme legenda. No limite esquerdo e superior de cada painel estão retratados o Kappa ± intervalo de confiança de 95% representados com a mesma cor utilizada para os pontos.

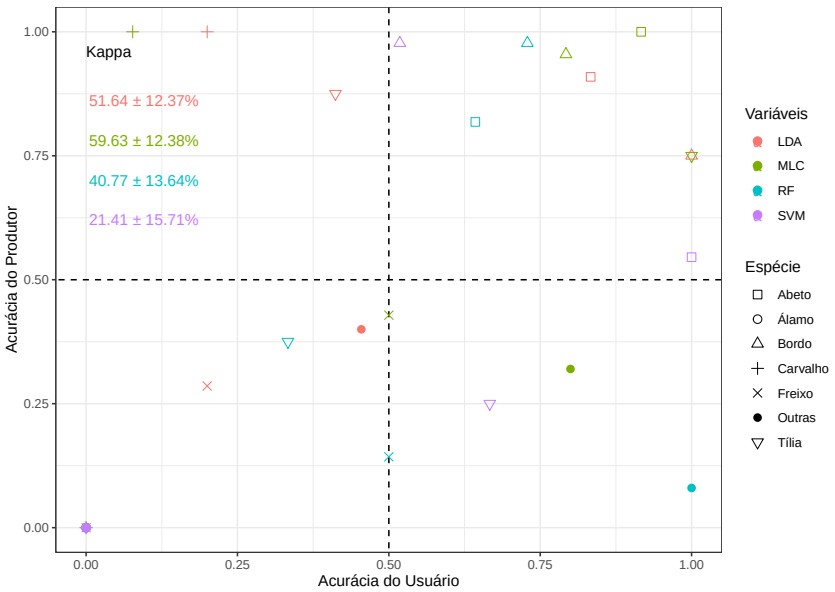

Figura 3.18. Gráfico aluvial da classificação gerada por MLC. Do lado esquerdo estão as classes reais e a direita o predito. Em verde, demonstra o que foi corretamente classificado e vermelho incorretamente classificado.

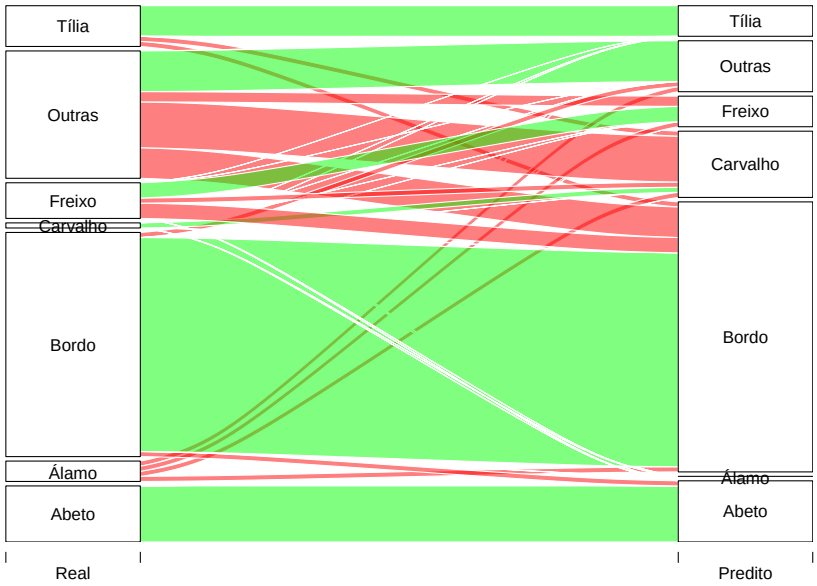

O carvalho consistiu apenas de indivíduos jovens e que apresentavam características das folhas bem diferentes do esperado para indivíduos adultos. O Freixo, por outro lado foi uma espécie que apresentou bastante interferência de podas com copas não naturais, o que também pode explicar a dificuldade na classificação.

O resultado final pode ser visualizado na figura 3.19, no qual verificou-se o predomínio da classe bordo (o que reflete a realidade), no entanto com excessivo erro de inclusão para o algoritmo SVM. Isso evidencia a importância de ser realizado o teste depois do ajuste do classificador usando validação cruzada. A validação sobre o conjunto teste é frequentemente ignorada nos estudos, relatando em métricas de qualidade que provavelmente não se sustentariam no resultado final, sobretudo para os algoritmos com alta tendência de sobreajuste (ZHANG; FENG; JIANG, 2010; SHEEREN et al., 2016; YAN et al., 2018), portanto seria inviável realizar uma comparação direta dos valores de acurácia obtidos.

3.4 Conclusão

Demonstrou-se a viabilidade do uso de LiDAR multiespectral como fonte única para realizar o delineamento individual das árvores e a classificação das árvores, obtendo Kappa de até 90% sobre a amostra de validação. Os atributos estruturais extraídos neste estudo, baseado em outros estudos recentes (BUDEI et al., 2018; LIU et al., 2017b), por si só não foram suficientes para gerar um modelo acurado.

Por outro lado, o uso apenas dos atributos espectrais apresentou alta acurácia, de forma que os classificadores que utilizaram apenas dados multiespectrais obtiveram resultados com qualidade próximas a da utilização de todos os atributos, sendo que o canal 1 (1.550 nm) foi o que apresentou maior relevância. Foi possível constatar que, simulando os atributos que poderiam ser extraídos de um LiDAR uniespectral (apenas C2 - 1.064 nm), seria possível atingir resultado próximo ao de se usar o LiDAR multiespectral. Outros estudos que discriminem mais espécies podem revelar se esse fato ainda se sustenta, permitindo o uso de sensores mais simples.

O espectro normalmente utilizado para LiDAR, próximo ao C2 1064 nm, não foi o que apresentou maior relevância para a tarefa, mas sim o C1 1.550 nm, sugerindo que esse comprimento de onda poderia ser mais relevante para a análise da vegetação.

Figura 3.19. Mapa do resultado da classificação sobre toda a área de estudo.

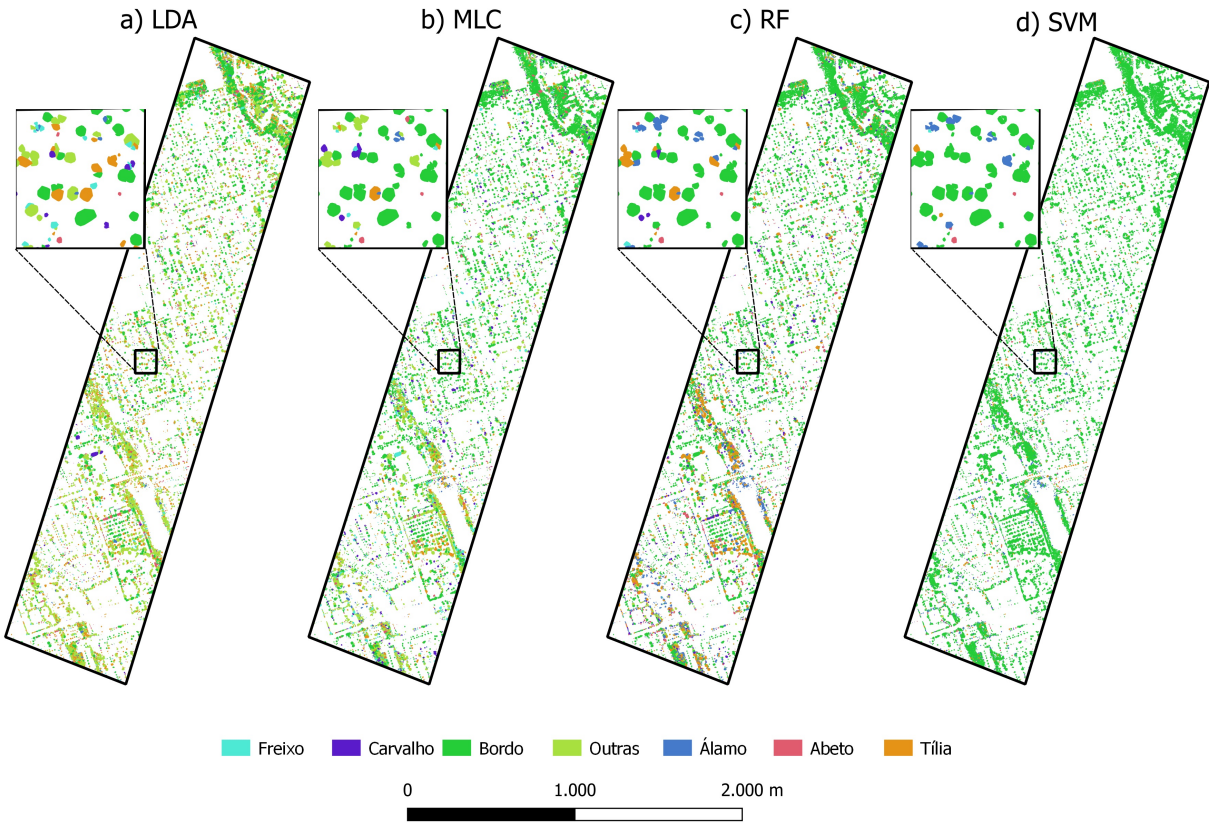

Referências

ALONZO, Michael; BOOKHAGEN, Bodo; ROBERTS, Dar A. Urban tree species mapping using hyperspectral and lidar data fusion. **Remote Sensing of Environment**, Elsevier, v. 148, p. 70–83, mai. 2014. ISSN 0034-4257. DOI: 10.1016/J.RSE.2014.03.018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425714001047?via%7B%5C%%7D3Dihub>.

ARYA, Sunil et al. An optimal algorithm for approximate nearest neighbor searching in fixed dimensions. **Journal of the ACM**, v. 45, n. 6, p. 891–923, 1998. ISSN 00045411. DOI: 10.1145/293347.293348.

BOUGHORBEL, Sabri; JARRAY, Fethi; EL-ANBARI, Mohammed. Optimal classifier for imbalanced data using Matthews Correlation Coefficient metric. **PLoS ONE**, v. 12, n. 6, p. 1–17, 2017. ISSN 19326203. DOI: 10.1371/journal.pone.0177678.

BREIMAN, L. Random Forests. **Machine Learning**, Basel, Switzerland, v. 45, n. 1, p. 5–32, 2001. ISSN 1098-6596. DOI: 10.1017/CBO9781107415324.004. arXiv: arXiv:1011.1669v3.

BUDEI, Brindusa Cristina et al. Identifying the genus or species of individual trees using a three-wavelength airborne lidar system. **Remote Sensing of Environment**, Elsevier, v. 204, March 2016, p. 632–647, 2018. ISSN 00344257. DOI: 10.1016/j.rse.2017.09.037. Disponível em: <https://doi.org/10.1016/j.rse.2017.09.037>.

CAWLEY, Gavin C.; TALBOT, Nicola L.C. On over-fitting in model selection and subsequent selection bias in performance evaluation. **Journal of Machine Learning Research**, v. 11, p. 2079–2107, 2010. ISSN 15324435.

CHEN, Qi et al. Isolating individual trees in a savanna woodland using small footprint lidar data. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 8, p. 923–932, 2006. ISSN 00991112. DOI: 10.14358/PERS.72.8.923.

CHICCO, Davide; JURMAN, Giuseppe. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. **BMC Genomics**, BMC Genomics, v. 21, n. 1, p. 1–13, 2020. ISSN 14712164. DOI: 10.1186/s12864-019-6413-7.

COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. XX, n. 1, p. 37–46, 1960. Disponível em: <http://web.njit.edu/%7B~%7Dmendonca/statcomp/papers/Cohen%7B%5C_%7Dnominal%7B%5C_%7Dscales%7B%5C_%7D1960.pdf>.

CROOKSTON, Nicholas L.; FINLEY, Andrew O. yaImpute: An R Package for kNN Imputation. **Journal of Statistical Software**, v. 23, n. 10, out. 2007. ISSN 1548-7660. Disponível em: <http://www.jstatsoft.org/v23/i10>.

DAI, Wenxia et al. A new method for 3D individual tree extraction using multispectral airborne LiDAR point clouds. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 144, July, p. 400–411, 2018. ISSN 09242716. DOI: 10.1016/j.isprsjprs.2018.08.010. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2018.08.010>.

DALPONTE, Michele et al. Delineation of Individual Tree Crowns from ALS and Hyperspectral data: a comparison among four methods. **European Journal of Remote Sensing**, Informa UK Limited, v. 48, n. 1, p. 365–382, jan. 2015. DOI: 10.5721/eujrs20154821. Disponível em: <https://doi.org/10.5721/eujrs20154821>.

EDDELBUETTEL, Dirk; SANDERSON, Conrad. RcppArmadillo: Accelerating R with high-performance C++ linear algebra. **Computational Statistics and Data Analysis**, v. 71, p. 1054–1063, mar. 2014. Disponível em: <http://dx.doi.org/10.1016/j.csda.2013.02.005>.

EDDY, William F. A New Convex Hull Algorithm for Planar Sets. **ACM Transactions on Mathematical Software (TOMS)**, Association for Computing Machinery (ACM), v. 3, n. 4, p. 398–403, dez. 1977. DOI: 10.1145/355759.355766. Disponível em: <https://doi.org/10.1145/355759.355766>.

FALKOWSKI, Michael J. et al. Automated estimation of individual conifer tree height and crown diameter via two-dimensional spatial wavelet analysis of lidar data. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 153–161, 2006. ISSN 17127971. DOI: 10.5589/m06-005.

FERRAZ, António et al. 3-D mapping of a multi-layered Mediterranean forest using ALS data. **Remote Sensing of Environment**, v. 121, p. 210–223, 2012. ISSN 0034-4257. DOI: https://doi.org/10.1016/j.rse.2012.01.020. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0034425712000570>.

FERRAZ, António et al. Lidar detection of individual tree size in tropical forests. **Remote Sensing of Environment**, Elsevier Inc., v. 183, p. 318–333, set. 2016. ISSN 00344257. DOI: 10.1016/j.rse.2016.05.028. Disponível em: <http://dx.doi.org/10.1016/j.rse.2016.05.028%20https://linkinghub.elsevier.com/retrieve/pii/S0034425716302292>.

GOOGLE. **Street view images for Oshawa, Canadá**. [S.l.: s.n.], 2018. Disponível em: <https://www.google.com/maps>. Acesso em: 13 abr. 2020.

GORODKIN, J. Comparing two K-category assignments by a K-category correlation coefficient. **Computational Biology and Chemistry**, v. 28, n. 5, p. 367–374, 2004. ISSN 1476-9271. DOI: https://doi.org/10.1016/j.compbiolchem.2004.09.006. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1476927104000799>.

GREGORY JEFFERIS, Sunil Arya; MOUNT, David. **RANN2: Fast Nearest Neighbour Search ('Rcpp' Wrapper of 'Arya' and Mount's 'libANN')**. [S.l.], 2020. R package version 0.1.0.9001. Disponível em: <https://github.com/jefferis/RANN2>.

HAMAMURA, Caio. **MultiSpecLiDAR: a package for analyzing and fusing multipectral LiDAR data**. [S.l.], 2020. R package version 0.0.1. Disponível em: <https://github.com/caiohamamura/MultiSpecLiDAR-R>.

_____. **tabularMLC: Tabular Maximum Likelihood Classifier**. [S.l.], 2020. R package version 0.0.1. Disponível em: <https://github.com/caiohamamura/tabularMLC>.

HAMAMURA, Caio et al. **lasRANN: Fast Nearest Neighbour Search ('Rcpp' Wrapper of 'Arya' and Mount's 'libANN')**. [S.l.], 2020. R package version 0.0.1. Disponível em: <https://github.com/caiohamamura/RANN2/tree/lasRANN>.

HAN, Jiawei. **Data Mining: Concepts and Techniques**. 3. ed. Walthan, MA, US: Elsevier, jun. 2019. P. 703. ISBN 9380931913. Disponível em: <https://www.xarg.org/ref/a/B00A2KLX0Y/>.

HUO, Lian-Zhi et al. Supervised spatial classification of multispectral LiDAR data in urban areas. Edição: Tayyab Ikram Shah. **PLOS ONE**, Public Library of Science, v. 13, n. 10, e0206185, out. 2018. ISSN 1932-6203. DOI: 10.1371/journal.pone.0206185. Disponível em: <http://dx.plos.org/10.1371/journal.pone.0206185>.

HYYPPÄ, Juha et al. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 5, p. 969–975, 2001. ISSN 01962892. DOI: 10.1109/36.921414.

ISENBURG, M. **LAStools—Efficient Tools for Lidar Processing**. [S.l.: s.n.], 2018.

KIM, Sooyoung et al. Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. **Remote Sensing of Environment**, Elsevier Inc., v. 113, n. 8, p. 1575–1586, 2009. ISSN 00344257. DOI: 10.1016/j.rse.2009.03.017. Disponível em: <http://dx.doi.org/10.1016/j.rse.2009.03.017>.

KUKKONEN, Mikko et al. Multispectral Airborne LiDAR Data in the Prediction of Boreal Tree Species Composition. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 57, n. 6, p. 1–10, 2019. ISSN 0196-2892. DOI: 10.1109/tgrs.2018.2885057.

LANDIS, J Richard; KOCH, Gary G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159, 1977. ISSN 0006341X. DOI: 10.2307/2529310.

LAUNEAU, Patrick et al. Airborne hyperspectral mapping of trees in an urban area. **International Journal of Remote Sensing**, v. 38, n. 5, p. 1277–1311, 2017. ISSN 13665901. DOI: 10.1080/01431161.2017.1285080.

LI, Dan et al. Object-Based Urban Tree Species Classification Using Bi-Temporal WorldView-2 and WorldView-3 Images. **Remote Sensing**, v. 7, n. 12, p. 16917–16937, dez. 2015. ISSN 2072-4292. DOI: 10.3390/rs71215861. Disponível em: <http://www.mdpi.com/2072-4292/7/12/15861/htm%20http://www.mdpi.com/2072-4292/7/12/15861>.

LIAW, Andy; WIENER, Matthew. Classification and Regression by randomForest. **R News**, v. 2, n. 3, p. 18–22, 2002. Disponível em: <https://CRAN.R-project.org/doc/Rnews/>.

LIU, Luxia et al. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. **Remote Sensing of Environment**, Elsevier, v. 200, p. 170–182, out. 2017. ISSN 0034-4257. DOI: 10.1016/J.RSE.2017.08.010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717303620?via%7B%5C%%7D3Dihub>.

_____._____. **Remote Sensing of Environment**, Elsevier, v. 200, p. 170–182, out. 2017. ISSN 0034-4257. DOI: 10.1016/J.RSE.2017.08.010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717303620?via%7B%5C%%7D3Dihub>.

LUZUM, B J; STAREK, M; SLATTON, K C. **Normalizing ALSM intensities**. University of Florida, US, 2004. P. 8.

MATHER, P. M. A computationally-efficient maximum-likelihood classifier employing prior probabilities for remotely-sensed data. **International Journal of Remote Sensing**, Informa UK Limited, v. 6, n. 2, p. 369–376, fev. 1985. DOI: 10.1080/01431168508948456. Disponível em: <https://doi.org/10.1080/01431168508948456>.

MATIKAINEN, Leena et al. Object-based analysis of multispectral airborne laser scanner data for land cover classification and map updating. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, p. 298–313, 2017. ISSN 0924-2716. DOI: https://doi.org/10.1016/j.isprsjprs.2017.04.005. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0924271616305305>.

MATTHEWS, B.W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. **Biochimica et Biophysica Acta (BBA) - Protein Structure**, Elsevier BV, v. 405, n. 2, p. 442–451, out. 1975. DOI: 10.1016/0005-2795(75)90109-9. Disponível em: <https://doi.org/10.1016/0005-2795(75)90109-9>.

MEYER, David et al. **e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien**. [S.l.], 2019. R package version 1.7-3. Disponível em: <https://CRAN.R-project.org/package=e1071>.

MONGUS, Domen; ŽALIK, Borut. An efficient approach to 3D single tree-crown delineation in LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 219–233, 2015. ISSN 09242716. DOI: 10.1016/j.isprsjprs.2015.08.004.

MORSY, Salem; SHAKER, Ahmed; EL-RABBANY, Ahmed. Multispectral LiDAR Data for Land Cover Classification of Urban Areas. **Sensors (Basel, Switzerland)**, Multidisciplinary Digital Publishing Institute (MDPI), v. 17, n. 5, abr. 2017. ISSN 1424-8220. DOI: 10.3390/s17050958. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/28445432%20http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC5461082>.

PERSSON, Åsa; HOLMGREN, Johan; SÖDERMAN, Ulf. Detecting and measuring individual trees using an airborne laser scanner. **Photogrammetric Engineering and Remote Sensing**, v. 68, n. 9, p. 925–932, 2002. ISSN 00991112.

PONTIUS, Robert Gilmore; MILLONES, Marco. Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 2011. ISSN 13665901. DOI: 10.1080/01431161.2011.552923.

POPESCU, Sorin C; WYNNE, Randolph H. Seeing the Trees in the Forest. **Photogrammetric Engineering & Remote Sensing**, American Society for Photogrammetry e Remote Sensing, v. 70, n. 5, p. 589–604, 2004. DOI: 10.14358/pers.70.5.589. Disponível em: <https://doi.org/10.14358/pers.70.5.589>.

PU, Ruiliang; LANDRY, Shawn; ZHANG, Jingcheng. Evaluation of Atmospheric Correction Methods in Identifying Urban Tree Species With WorldView-2 Imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 5, p. 1886–1897, mai. 2015. ISSN 1939-1404. DOI: 10.1109/JSTARS.2014.2363441. Disponível em: <http://ieeexplore.ieee.org/document/6971089/>.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2020. Disponível em: <https://www.R-project.org/>.

ROUSSEL, Jean-Romain; AUTY, David. **lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications**. [S.l.], 2020. R package version 2.2.3. Disponível em: <https://CRAN.R-project.org/package=lidR>.

SANDERSON, Conrad. **Armadillo C++ Linear Algebra Library**. [S.l.]: Zenodo, jun. 2016. DOI: 10.5281/zenodo.55251. Disponível em: <https://doi.org/10.5281/zenodo.55251>.

SHAMOS, Michael Ian. **Computational Geometry.** 1978. Tese (Doutorado) – USA. AAI7819047.

SHEEREN, David et al. Tree Species Classification in Temperate Forests Using Formosat-2 Satellite Image Time Series. **Remote Sensing**, v. 8, n. 9, p. 734, 2016. ISSN 2072-4292. DOI: 10.3390/rs8090734. Disponível em: <http://www.mdpi.com/2072-4292/8/9/734>.

SIGDEL, Madhav; AYGÜN, Ramazan Savas. Pacc - A discriminative and accuracy correlated measure for assessment of classification results. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, 7988 LNAI, p. 281–295, 2013. ISSN 03029743. DOI: 10.1007/978-3-642-39712-7_22.

SILVA, Carlos A. et al. Imputation of Individual Longleaf Pine (Pinus palustris Mill.) Tree Attributes from Field and LiDAR Data. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 554–573, 2016. ISSN 17127971. DOI: 10.1080/07038992.2016.1196582.

SILVA, Carlos A. et al. **rLiDAR: LiDAR Data Processing and Visualization**. [S.l.], 2017. R package version 0.1.1. Disponível em: <https://CRAN.R-project.org/package=rLiDAR>.

SILVA, Evandro J.R.; ZANCHETTIN, Cleber. On Validation Setup for Multiclass Imbalanced Data Sets. **Proceedings - 2016 5th Brazilian Conference on Intelligent Systems, BRACIS 2016**, p. 468–473, 2017. DOI: 10.1109/BRACIS.2016.090.

SMARDON, Richard C. Perception and aesthetics of the urban environment: Review of the role of vegetation. **Landscape and Urban Planning**, Elsevier, v. 15, n. 1-2, p. 85–106, jun. 1988. ISSN 0169-2046. DOI: 10.1016/0169-2046(88)90018-7. Disponível em: <https://www.sciencedirect.com/science/article/pii/0169204688900187>.

SOLBERG, Svein; NAESSET, Erik; BOLLANDSAS, Ole Martin. Single_Tree_Segment_Hetero_Spruce_Forest. v. 72, n. 12, p. 1369–1378, 2006.

STARK, Scott C. et al. Amazon forest carbon dynamics predicted by profiles of canopy leaf area and light environment. **Ecology Letters**, v. 15, n. 12, p. 1406–1414, 2012. ISSN 14610248. DOI: 10.1111/j.1461-0248.2012.01864.x.

SUGUMARAN, Ramanathan; VOSS, Matthew. Object-oriented classification of LIDAR-fused hyperspectral imagery for tree species identification in an Urban environment. **2007 Urban Remote Sensing Joint Event, URS**, 2007. DOI: 10.1109/URS.2007.371845.

TAHA, Haider. Modeling impacts of increased urban vegetation on ozone air quality in the South Coast Air Basin. **Atmospheric Environment**, Pergamon, v. 30, n. 20, p. 3423–3430, out. 1996. ISSN 1352-2310. DOI: 10.1016/1352-2310(96)00035-0. Disponível em: <https://www.sciencedirect.com/science/article/pii/1352231096000350>.

TELEDYNE OPTECH. **Optech Titan Multispectral Lidar System: High Precision Environmental Mapping**. Canada: [s.n.], 2014. P. 8. Disponível em: <https://geo3d.hr/sites/default/files/2018-06/Titan-Specsheet-150515-WEB.pdf>.

THE AMERICAN SOCIETY FOR PHOTOGRAMMETRY & REMOTE SENSING. **LAS SPECIFICATION VERSION 1.4 - R13**. Maryland, US, 2013. P. 45–47. DOI: 10.1179/sre.1989.30.231.45.

TYRVÄINEN, Liisa; SILVENNOINEN, Harri; KOLEHMAINEN, Osmo. Ecological and aesthetic values in urban forest management. **Urban Forestry & Urban Greening**, Urban & Fischer, v. 1, n. 3, p. 135–149, jan. 2003. ISSN 1618-8667. DOI: 10.1078/1618-8667-00014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S161886670470014X>.

VENABLES, W. N.; RIPLEY, B. D. **Modern Applied Statistics with S**. Fourth. New York: Springer, 2002. ISBN 0-387-95457-0. Disponível em: <http://www.stats.ox.ac.uk/pub/MASS4>.

VERLIC, Andrej et al. TREE SPECIES CLASSIFICATION USING WORLDVIEW-2 SATELLITE IMAGES AND LASER SCANNING DATA IN A NATURAL URBAN FOREST. **SUMARSKI LIST**, v. 138, n. 9-10, p. 477–488, 2014. ISSN 0373-1332.

VERMA, Pramit et al. Appraisal of kappa-based metrics and disagreement indices of accuracy assessment for parametric and nonparametric techniques used in LULC classification and change detection. **Modeling Earth Systems and Environment**, Springer Science e Business Media LLC, v. 6, n. 2, p. 1045–1059, mar. 2020. DOI: 10.1007/s40808-020-00740-x. Disponível em: <https://doi.org/10.1007/s40808-020-00740-x>.

VOSS, Matthew; SUGUMARAN, Ramanathan. Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach. **Sensors**, Molecular Diversity Preservation International, Basel, Switzerland, v. 8, n. 5, p. 3020–3036, mai. 2008. ISSN 1424-8220. DOI: 10.3390/s8053020. Disponível em: <http://www.mdpi.com/1424-8220/8/5/3020>.

WEN, Dawei et al. Semantic Classification of Urban Trees Using Very High Resolution Satellite Imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 4, p. 1413–1424, abr. 2017. ISSN 1939-1404. DOI: 10.1109/JSTARS.2016.2645798. Disponível em: <http://ieeexplore.ieee.org/document/7828096/>.

WICHMANN, V. et al. EVALUATING THE POTENTIAL OF MULTISPECTRAL AIRBORNE LIDAR FOR TOPOGRAPHIC MAPPING AND LAND COVER CLASSIFICATION. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, Copernicus GmbH, II-3/W5, p. 113–119, ago. 2015. DOI: 10.5194/isprsannals-ii-3-w5-113-2015. Disponível em: <https://doi.org/10.5194/isprsannals-ii-3-w5-113-2015>.

WU, Xi Zhu; ZHOU, Zhi Hua. A unified view of multi-label performance measures. In: 34TH International Conference on Machine Learning, ICML 2017. [S.l.: s.n.], 2017. v. 8, p. 5778–5791. ISBN 9781510855144.

XIAO, Wen et al. Mean shift segmentation assessment for individual forest tree delineation from airborne lidar data. **Remote Sensing**, v. 11, n. 11, p. 1–19, 2019. ISSN 20724292. DOI: 10.3390/rs11111263.

YAN, Jingli et al. Mapping vegetation functional types in urban areas with WorldView-2 imagery: Integrating object-based classification with phenology. **Urban Forestry & Urban Greening**, v. 31, p. 230–240, abr. 2018. ISSN 16188667. DOI: 10.1016/j.ufug.2018.01.021. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S1618866717300729>.

ZHANG, Xiuying; FENG, Xuezhi; JIANG, Hong. Object-oriented method for urban vegetation mapping using IKONOS imagery. **International Journal of Remote Sensing**, Taylor & Francis, v. 31, n. 1, p. 177–196, jan. 2010. ISSN 0143-1161. DOI: 10.1080/01431160902882603. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/01431160902882603>.

ZHANG, Zhongya et al. Object-Based Tree Species Classification in Urban Ecosystems Using LiDAR and Hyperspectral Data. **Forests**, Multidisciplinary Digital Publishing Institute, v. 7, n. 12, p. 122, jun. 2016. ISSN 1999-4907. DOI: 10.3390/f7060122. Disponível em: <http://www.mdpi.com/1999-4907/7/6/122>.

ZÖLCH, Teresa et al. Regulating urban surface runoff through nature-based solutions – An assessment at the micro-scale. **Environmental Research**, Elsevier Inc., Amsterdam, NL, v. 157, n. 5, p. 135–144, 2017. ISSN 0013-9351. DOI: 10.1016/j.envres.2017.05.023. Disponível em: <http://dx.doi.org/10.1016/j.envres.2017.05.023>.

CONSIDERAÇÕES FINAIS

O levantamento inicial desenvolvido por meio da revisão demonstrou como a temática é ainda recente e está em pleno desenvolvimento, no entanto ainda com deficiência de dados e experimentos realizados em área urbana de clima tropical. Também foi possível notar a maior relevância da fonte de dados utilizada e dos atributos extraídos em relação ao algoritmo classificador para estabelecer o modelo de classificação, dentro desse contexto os capítulos seguintes focaram na comparação entre diferentes formas de extrair os atributos de fontes distintas, analisando a importância dos atributos. Assim foram apresentadas duas abordagens distintas para a classificação espécies arbóreas em ambiente urbano.

A primeira abordagem, utilizando imagens RGB obtidas por drone demonstra a possibilidade de obtenção de um mapa de espécies por um método de baixo custo, no entanto com algumas limitações. Os resultados obtidos demonstram que os dados RGB podem fornecer informações suficientes para discriminar um número razoável de espécies, aqui 16 espécies. Entretanto, ainda existe potencial para aprimoramento por meio de mais estudos que explorem: 1) o uso de técnicas de *structure from motion* (SFM) para derivar dados de elevação agregando informação estrutural e possibilitando o uso de algoritmos de individualização das árvores; 2) dados multitemporais em diferentes períodos do ano que possam revelar os diferentes estados fenológicos das árvores, como floração e flutificação, facilitando a discriminação das espécies.

A segunda abordagem, consiste em um método com uso LiDAR multiespectral, um sensor mais sofisticado e lançado no mercado apenas em 2014 e que ainda precisa ser estudado com mais detalhes. No entanto, demonstrou-se o seu alto potencial para discriminar as diferentes espécies, valendo-se dos três canais de escaneamento e do desenvolvimento de um novo mecanismo de fusão das nuvens, permitindo extrair atributos relativos entre os canais, bem como analisar a sua distribuição nas copas. O estudo detalhou o comportamento espectral dos múltiplos retornos, demonstrando que os dados de intensidade devem considerar apenas os retornos únicos para reduzir os ruídos decorrentes de retornos que refletem apenas parcialmente o feixe laser, no entanto o uso da nuvem completa para capturar a estrutura da árvore e a densidade da copa.

Além de demonstrar o potencial do sensoriamento remoto para o mapeamento de espécies de árvore no meio urbano, a tese demonstrou métodos inovadores de análise visual de dados multivariados como o radar-boxplot e o gráfico de acurácia do produtor x acurácia do usuário, não encontrados na literatura até então. Outro produto oriundo da tese foi o pacote MultispecLiDAR do R para analisar os dados multiespectrais, primeiro pacote dedicado a analisar esse tipo de produto disponível na linguagem R . Este estudo, também aprofundou-se em questões como a validação os dados e a mensuração da qualidade do resultados, que até então vêm sendo pouco detalhados e desenvolvidos nos trabalhos aqui analisados, levando à interpretação subjetiva e de difícil comparação com os demais estudos. Aqui, foi proposta a adoção da validação cruzada como essencial para evitar superestimar os modelos com sobreajuste, além do uso de amostras teste no caso de utilizar otimização na seleção dos atributos (*wrapper*) e/ou no ajuste hiperparâmetros dos classificadores. Por fim, para aferir a qualidade do resultado, o uso parcimonioso do índice kappa, em favor do escore F1-sd e F1-macro, além do acurácia geral que possuem interpretação mais clara e objetiva, ficando a critério do pesquisador definir as propriedades de um bom classificador de acordo com o contexto do estudo.

APÊNDICES

APÊNDICE A. radarBoxplot: pacote em R que implementa o radar-boxplot.

Hamamura, C. radarBoxplot: Implementation of the Radar-Boxplot, versão 1.0.0, acesso em 12 de Mai 2020, <https://cran.r-project.org/package=radarBoxplot>

O radarBoxplot é um pacote R em código aberto para gerar o gráfico radar-boxplot criado pelo autor para análise de dados multivariados. Desenvolvido em 2019 como parte da tese de doutorado e disponibilizada no repositório oficial CRAN.

O radar-boxplot une os conceitos do gráfico de radar e do boxplot (TUKEY, 1977), permitindo a comparação de dados multivariados para múltiplas classes/*clusters* ao mesmo tempo. O gráfico permite um entendimento intuitivo dos dados ao criar polígonos em um radar que podem ser comparados visualmente pelo formato e espessura, fornecendo informações para identificar rapidamente classes semelhantes e/ou com alta variabilidade interna. Pela interpretação do radar-boxplot é possível predizer os problemas de confusão dos classificados e entender o porquê e o que poderia ser feito para atingir melhores resultados.

O gráfico é desenhado utilizando eixos polares de raio 1. A circunferência é dividida por n eixos, onde n é o número de atributos que serão representados. Os atributos são normalizados para o interlado de 0.1-1.0 para evitar sobreposição entre valores que baixos que residiriam no centro do gráfico. A normalização é feito por $normalizado = (X - min)/(max - min)$, e então transformado para o intervalo de 0.1 - 1.0 por $norm_e scala = (normalizado \cdot 0,9) + 0,1$.

O radar-boxplot é desenhado utilizando dois polígonos de cores diferentes, assim como em um boxplot, no entanto para diversos atributos simultaneamente, juntando-os em polígonos anelar. O polígono interno representa os percentis 25-75% de cada atributo, enquanto que o azul representa a amplitude total, excluindo os *outliers*, definidos como:

$$outlier_{superior} = Q_3 + \alpha \cdot IQR$$

$$outlier_{inferior} = Q_1 - \alpha \cdot IQR$$

Onde Q_1 e Q_3 correpondem aos quartis 1 e 3 respectivamente, α é um fator de multiplicação (padrão é 1,5) e IQR a amplitude interquartil (*interquartile range*), definida como $IQR = Q_3 - Q_1$. Os *outliers* são representados como pontos no gráfico.

Referências

CORTEZ, P. et al. Modeling wine preferences by data mining from physicochemical properties. **Decision Support Systems**, Amsterdam, v. 47, n. 4, p. 547–553, 2009.

TUKEY, John W. (John Wilder). **Exploratory data analysis**. [S.l.]: Addison-Wesley Pub. Co, 1977. P. 688. ISBN 0201076160.

Figura A.1. Exemplo de radar-boxplot para o conjunto de dados de vinho tinto de Cortez et al. (2009). Cada radar-boxplot representa uma nota de 3 a 8 atribuída por enólogos e nos eixos as propriedades físico-químicas dos vinhos.

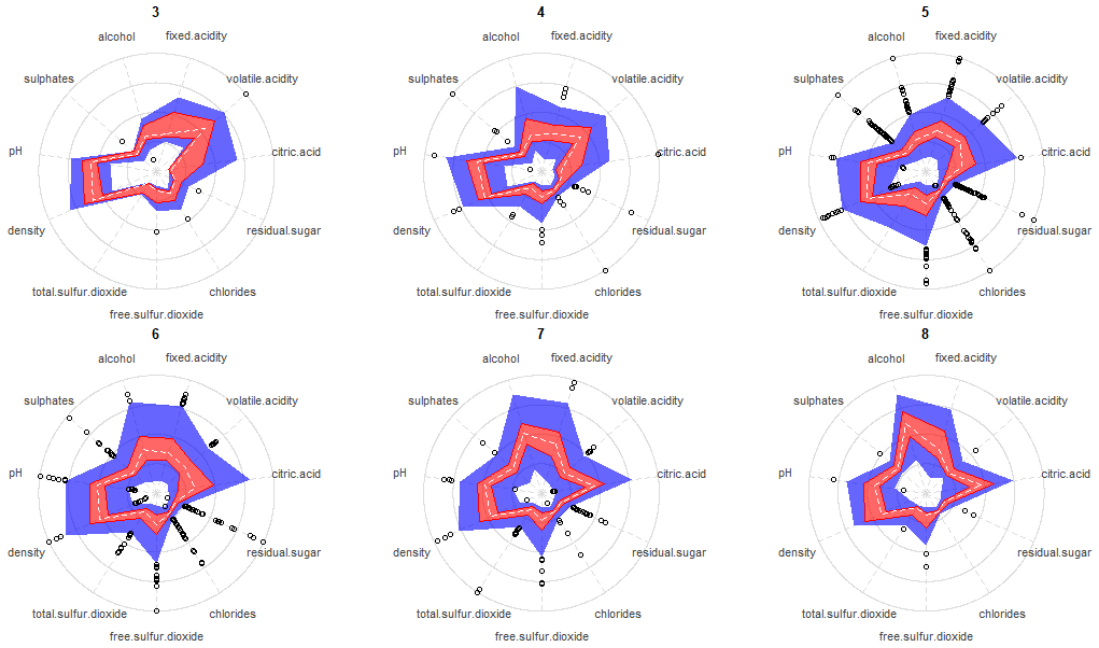

APÊNDICE B. MultiSpecLiDAR: pacote em R para análise de dados LiDAR multiespectrais

Hamamura, C., Silva, C.A. MultiSpecLiDAR: pacote em R para análise de dados LiDAR multiespectrais, versão 0.1, acesso em 12 de Mai 2020, <https://www.github.com/caiohamamura/MultiSpecLiDAR-R>

O MultiSpecLiDAR é um pacote R em código aberto para analisar dados LiDAR multiespectrais. Desenvolvido em 2020 como parte da tese de doutorado e disponibilizada na plataforma para código aberto GitHub. O pacote contém funções para realizar o pré-processamento dos dados, com destaque para a função de fusão de diferentes nuvens espectrais utilizando o algoritmo de vizinho mais próximo, agregando o dado de intensidade de cada uma no campo RGB do formato LAS. Além disso, o pacote possui funções para: a) Normalização dos valores de intensidade com base em Luzum, Starek e Slatton (2004); b) Recortar as nuvens; c) Obtenção de métricas da nuvem; d) Obtenção de métricas da árvore; e) Extração de métricas por grid; f) Segmentação individual das copas de árvore, implementando um algoritmo Mean Shift desenvolvido que utiliza os dados espectrais com cilindro de busca adaptável, agregando as melhorias propostas por Ferraz et al. (2016) e Dai et al. (2018) ; g) Visualização da nuvem em falsa cor; h) Classificação; i) Seleção de atributos. O pacote foi desenvolvido para servir de base para as análises realizadas no capítulo 3 da tese.

Referências

DAI, Wenxia et al. A new method for 3D individual tree extraction using multispectral airborne LiDAR point clouds. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 144, July, p. 400–411, 2018. ISSN 09242716. DOI: `10.1016/j.isprsjprs.2018.08.010`. Disponível em: <`https://doi.org/10.1016/j.isprsjprs.2018.08.010`>.

FERRAZ, António et al. Lidar detection of individual tree size in tropical forests. **Remote Sensing of Environment**, Elsevier Inc., v. 183, p. 318–333, set. 2016. ISSN 00344257. DOI: `10.1016/j.rse.2016.05.028`. Disponível em: <`http://dx.doi.org/10.1016/j.rse.2016.05.028%20https://linkinghub.elsevier.com/retrieve/pii/S0034425716302292`>.

LUZUM, B J; STAREK, M; SLATTON, K C. **Normalizing ALSM intensities**. University of Florida, US, 2004. P. 8.

ANEXOS

ANEXO A. Matrizes de erros

Tabela anexo1. Matriz de erros para o algoritmo LDA variáveis espectrais e espaciais (V_COMB).

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	4	0	1	1	0	1	0
Rosaceae	0	13	2	1	0	0	0
Bordo	0	2	60	0	0	0	2
Outros	0	0	2	4	0	0	0
Álamo	2	0	2	0	7	1	1
Abeto	0	0	1	0	0	22	0
Tília	0	0	2	0	3	0	11

Tabela anexo2. Matriz de erros para o algoritmo LDA e conjunto de variáveis V_SPEC.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	1	0	1	0	0	0	0
Rosaceae	4	8	1	1	0	1	0
Bordo	0	6	61	0	0	0	4
Outros	0	0	1	4	1	0	0
Álamo	1	0	4	1	8	0	1
Abeto	0	0	0	0	0	23	0
Tília	0	1	2	0	1	0	9

Tabela anexo3. Matriz de erros para o algoritmo LDA e conjunto de variáveis V_3D.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	2	0	1	0	1	0	0
Rosaceae	0	7	11	0	0	2	0
Bordo	0	7	52	3	3	1	7
Outros	0	0	2	3	0	0	0
Álamo	3	1	1	0	6	0	0
Abeto	1	0	1	0	0	20	0
Tília	0	0	2	0	0	1	7

Tabela anexo4. Matriz de erros para o algoritmo LDA e conjunto de variáveis V_UNI.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	2	0	1	0	1	0	0
Rosaceae	0	11	4	0	0	4	2
Bordo	0	4	61	0	0	1	1
Outros	0	0	0	4	2	0	0
Álamo	2	0	3	2	6	0	0
Abeto	2	0	0	0	0	19	0
Tília	0	0	1	0	1	0	11

Tabela anexo5. Matriz de erros para o algoritmo MLC variáveis espectrais e espaciais (V_COMB).

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	6	0	0	0	0	0	0
Rosaceae	0	15	1	0	0	1	1
Bordo	0	0	64	0	0	0	1
Outros	0	0	3	4	3	0	0
Álamo	0	0	2	2	7	0	0
Abeto	0	0	0	0	0	23	0
Tília	0	0	0	0	0	0	12

Tabela anexo6. Matriz de erros para o algoritmo MLC e conjunto de variáveis V_SPEC.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	5	0	1	1	4	1	1
Rosaceae	0	15	0	0	0	0	1
Bordo	0	0	64	0	0	0	1
Outros	1	0	2	5	1	0	0
Álamo	0	0	0	0	5	1	0
Abeto	0	0	1	0	0	22	0
Tília	0	0	2	0	0	0	11

Tabela anexo7. Matriz de erros para o algoritmo MLC e conjunto de variáveis V_3D.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	0	0	1	0	0	1	0
Rosaceae	3	15	15	0	3	7	2
Bordo	0	0	18	1	1	0	0
Outros	0	0	8	2	1	0	0
Álamo	0	0	7	2	0	0	0
Abeto	1	0	1	0	1	16	0
Tília	2	0	20	1	4	0	12

Tabela anexo8. Matriz de erros para o algoritmo MLC e conjunto de variáveis V_UNI.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	5	0	1	0	1	1	0
Rosaceae	0	15	6	0	0	4	2
Bordo	0	0	56	0	0	1	0
Outros	0	0	3	4	2	0	0
Álamo	1	0	1	0	6	0	0
Abeto	0	0	1	0	0	16	0
Tília	0	0	2	2	1	2	12

Tabela anexo9. Matriz de erros para o algoritmo RF variáveis espectrais e espaciais (V_COMB).

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	2	0	0	2	1	0	0
Rosaceae	0	14	1	0	1	1	0
Bordo	1	1	65	0	1	0	1
Outros	0	0	0	3	0	0	0
Álamo	2	0	1	0	7	0	0
Abeto	0	0	1	0	0	23	0
Tília	1	0	2	1	0	0	13

Tabela anexo10. Matriz de erros para o algoritmo RF e conjunto de variáveis V_SPEC.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	4	1	0	1	2	0	0
Rosaceae	1	14	2	0	0	0	1
Bordo	0	0	65	0	0	0	2
Outros	0	0	0	5	0	0	0
Álamo	1	0	2	0	7	1	0
Abeto	0	0	0	0	0	23	0
Tília	0	0	1	0	1	0	11

Tabela anexo11. Matriz de erros para o algoritmo RF e conjunto de variáveis V_3D.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	3	0	1	0	3	0	0
Rosaceae	0	11	4	0	0	1	1
Bordo	0	4	57	6	3	4	5
Outros	0	0	0	0	1	0	0
Álamo	2	0	0	0	2	0	0
Abeto	1	0	5	0	1	19	0
Tília	0	0	3	0	0	0	8

Tabela anexo12. Matriz de erros para o algoritmo RF e conjunto de variáveis V_UNI.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	1	0	1	0	0	0	0
Rosaceae	0	13	4	0	0	2	1
Bordo	1	2	61	2	1	3	0
Outros	0	0	0	3	2	0	0
Álamo	2	0	1	0	6	0	0
Abeto	2	0	1	0	0	19	0
Tília	0	0	2	1	1	0	13

Tabela anexo13. Matriz de erros para o algoritmo SVM variáveis espectrais e espaciais (V_COMB).

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	0	0	0	1	0	0	0
Rosaceae	0	15	0	0	2	1	1
Bordo	2	0	69	2	1	0	0
Outros	0	0	0	0	0	0	0
Álamo	2	0	1	1	7	0	0
Abeto	1	0	0	1	0	23	0
Tília	1	0	0	1	0	0	13

Tabela anexo14. Matriz de erros para o algoritmo SVM e conjunto de variáveis V_SPEC.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	0	0	0	0	1	1	0
Rosaceae	1	15	1	0	1	0	1
Bordo	1	0	64	0	1	0	1
Outros	0	0	0	5	0	0	0
Álamo	4	0	1	1	7	1	0
Abeto	0	0	0	0	0	22	0
Tília	0	0	4	0	0	0	12

Tabela anexo15. Matriz de erros para o algoritmo SVM e conjunto de variáveis V_3D.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	0	0	0	0	0	0	0
Rosaceae	0	0	1	0	0	0	0
Bordo	5	15	68	6	9	5	10
Outros	0	0	0	0	0	0	0
Álamo	0	0	0	0	0	0	0
Abeto	1	0	1	0	1	19	0
Tília	0	0	0	0	0	0	4

Tabela anexo16. Matriz de erros para o algoritmo SVM e conjunto de variáveis V_UNI.

	Freixo	Rosaceae	Bordo	Outros	Álamo	Abeto	Tília
Freixo	0	0	0	0	0	0	0
Rosaceae	0	12	4	0	0	5	2
Bordo	1	3	65	1	3	1	0
Outros	0	0	0	2	0	0	0
Álamo	5	0	1	1	7	0	0
Abeto	0	0	0	0	0	18	0
Tília	0	0	0	2	0	0	12