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

Uso de imagens hiperespectrais e da tecnologia LiDAR na identificação de espécies florestais em ambiente urbano na cidade de Belo Horizonte, Minas Gerais

Felipe Coelho de Souza Petean

Dissertação apresentada para obtenção do título de Mestre em Ciências, Programa: Recursos Florestais. Opção em: Conservação de Ecossistemas Florestais

Piracicaba
2015

Felipe Coelho de Souza Petean
Engenheiro Florestal

Uso de imagens hiperespectrais e da tecnologia LiDAR na identificação de espécies florestais em ambiente urbano na cidade de Belo Horizonte, Minas Gerais

versão revisada de acordo com a resolução CoPGr 6018 de 2011

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

Dissertação apresentada para obtenção do título de Mestre em Ciências, Programa: Recursos Florestais. Opção em: Conservação de Ecossistemas Florestais

Piracicaba
2015

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

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 / Felipe Coelho de Souza Petean. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2015.
132 p. : il.

Dissertação (Mestrado) - - Escola Superior de Agricultura "Luiz de Queiroz".

1. Planejamento urbano 2. Arborização urbana 3. Escaneamento a laser I. Título

CDD 631.46
B732m

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor"

Dedico este trabalho aos meus pais,

Vera e Paulo

por todo o apoio, por todo o amor

e por estarem ao meu lado sempre e incondicionalmente

AGRADECIMENTOS

À Deus, primeiramente, por ter me abençoado com paciência, alegrias e saúde, para que eu pudesse trilhar meu caminho em paz e segurança em Ti;

À minha eterna companheira, Mariana, por ter compartilhado todos os melhores momentos, encarado os desafios com sabedoria e por colher os mais doces frutos da vida comigo;

Aos meus pais, Vera e Paulo, por todo o apoio, carinho, dedicação e amor incondicionais, que sem eles, não conseguiria chegar aonde cheguei;

Aos meus queridos avós, Maria Odila, Maria Verbena, Gustavo e Paulo, por me ensinarem a amar e apreciar as coisas simples e belas da vida;

À minha família, Coelho de Souza e Petean, por estar sempre ao meu lado no meu caminho, me amando e apoiando ternamente;

Às famílias Gomes dos Santos e Pires Franco pelo eterno carinho, conselhos e bons momentos;

Ao meu orientador, Demóstenes Ferreira da Silva Filho, pelos ensinamentos e conhecimentos transmitidos ao longo desses anos;

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pela bolsa de mestrado e pelo financiamento do projeto 2013/21338-0;

À Escola Superior de Agricultura “Luiz de Queiroz” e à Universidade de São Paulo pela estrutura e condições para que executasse com sucesso meu trabalho;

Aos meus queridos amigos de toda hora Mateus Bergamin, Ivan Brunelli Filho, Paula Alves, Bianca Carlstron, Flavio Marcon, Taís Rosa, Daniel Oliveira, Danilo Costa, José de Deus Jr., por proporcionarem as melhores conversas, boas risadas e bate-papos regados a muito besteirol e papos-cabeça!

Aos meus amigos do CMQ Alex Bovo, André Peres da Silva, Andrea Bittencourt, Antônio Carlos Cella, Bruno Kanieski da Silva, Camila Costa, Danitiele Laranja, Eduardo Alexandrino, Eimi Arikawa, Eric Görgens, Esthevan Gasparoto, Flávio Mendes, Gustavo Oliva, Helena Zanlorenzi, Jefferson Polizel, Léa Dobbert, Luciana Cavalcante, Maísa Alves, Maria Carolina Garutti, Matheus Nunes, Michel Colmanetti, Rafaela Naves, Tito Castro, Vanessa de Oliveira, pelas conversas descontraídas, conselhos, bolos, doces de leite e muito café!;

Aos meus amigos do LAIM Alejandro Venegas, Aparecido Siqueira, Bénédicte Favreau, Claudio Anholetto, Fernanda Guedes, Gilles Chaix, Matheus Chagas, Ivanka Rosada, Maria Bermudez, Mario Tommasiello Filho, Nayara Marcon e Raphael de Araujo e Tassio Trevisor pela amizade, boas risadas, conversas, cafés e toalhas felpudas!;

À Giovana Oliveira, por todo o apoio, dicas, boas conversas e ajuda com as questões burocráticas e todos os trâmites legais do sistema;

Ao professor Dr. João Luís Ferreira Batista, pelas conversas e conselhos durante a elaboração de artigos;

Ao professor Dr. Edson José Vidal da Silva, pela orientação acadêmica no início do meu mestrado;

E finalmente, a todas as pessoas que contribuíram para que esse trabalho fosse possível, meu muito obrigado.

EPÍGRAFE

Gracias a la vida que me ha dado tanto
Me dio dos luceros que cuando los abro
Perfecto distingo lo negro del blanco
Y en el alto cielo su fondo estrellado
Y en las multitudes el hombre que yo amo

Gracias a la vida que me ha dado tanto
Me ha dado el oído que en todo su ancho
Graba noche y día grillos y canarios
Martirios, turbinas, ladridos, chubascos
Y la voz tan tierna de mi bien amado

Gracias a la vida que me ha dado tanto
Me ha dado el sonido y el abecedario
Con él, las palabras que pienso y declaro
Madre, amigo, hermano
Y luz alumbrando la ruta del alma del que estoy amando

Gracias a la Vida - Violeta Parra, por Mercedes Sosa

SUMÁRIO

RESUMO 13
ABSTRACT 15
LISTA DE FIGURAS 17
LISTA DE TABELAS 23
1 INTRODUÇÃO 25
2 OBJETIVOS 29
2.1 Objetivo Geral 29
2.2 Objetivos específicos 29
3 REVISÃO BIBLIOGRÁFICA 31
3.1 Os parques no contexto urbano 31
3.1.1 A urbanização no Brasil 31
3.1.2 Os parques urbanos no Brasil 34
3.2 A extração de informações de recursos digitais 36
3.2.1 A radiação eletromagnética 36
3.3 O espectro eletromagnético 38
3.4 Interação da vegetação com a energia eletromagnética 40
3.5 Formas de aquisição dos padrões espectrais 42
3.5.1 Sistemas sensores 42
3.5.1.1 Sensores não-imageadores 43
3.5.1.2 Sensores imageadores 45
3.5.2 Sensores multiespectrais 47
3.5.3 Sensores hiperespectrais 48
3.5.4 Aplicações de imagens hiperespectrais 51
3.5.4.1 Uso Florestal 51
3.5.4.2 Uso urbano 52
3.6 Classificação de imagens 53
3.6.1 Classificação não supervisionada 54
3.6.2 Classificação supervisionada 55
3.6.2.1 Segmentação 56

3.6.2.2 Classificação 57
3.7 Tecnologia LiDAR 58
3.7.1 Manejo e inventário florestal 60
3.7.2 Quantificação de biomassa e de cobertura foliar das árvores 61
3.7.3 Análise tridimensional do estrato florestal 62
4 MÉTODOS 65
4.1 Local de estudo 65
4.1.1 Belo Horizonte 65
4.1.2 Parque Municipal Américo Renné Giannetti 65
4.2 Base de Dados 68
4.2.1 Levantamento de campo 68
4.2.2 Imagem multispectral 70
4.2.3 Nuvem LiDAR 72
4.2.3.1 Processamento da nuvem e extração de informações básicas 73
4.3 Análise dos dados 75
4.3.1 Segmentação 76
4.3.1.1 Segmentação aplicada à imagem WV2 77
4.3.1.1.1 Segmentação com Idrisi 77
4.3.1.1.2 Segmentação com eCognition 79
4.3.1.1.3 Escolha da melhor segmentação para a classificação final 80
4.3.1.2 Segmentação aplicada ao MDE 83
4.3.1.2.1 ArcGis 84
4.3.2 Classificação 88
4.3.2.1 Classificação não-supervisionada 89
4.3.2.2 Classificação supervisionada 94
4.3.2.2.1 Comparação entre os classificadores 94
4.3.2.2.2 Classificação final 98
4.3.3 Análise estatística 100
5 RESULTADOS 101
5.1 Diversidade florística 101
5.2 Classificação final 103
6 CONCLUSÃO 109

REFERÊNCIAS.....111
ANEXOS 125

RESUMO

Uso de imagens hiperespectrais e da tecnologia LiDAR na identificação de espécies florestais em ambiente urbano na cidade de Belo Horizonte, Minas Gerais

A silvicultura urbana é um dos elementos essenciais à manutenção da qualidade de vida nos grandes centros urbanos. A existência de uma ampla rede de arvores distribuída ao longo das vias e dos espaços públicos atua promovendo a qualidade do ar, a conservação de água, o conforto térmico, acústico e psicológico dos cidadãos. Florestas urbanas são capazes de amenizar as emissões dos Gases do Efeito Estufa (GEE), tais como o CO_2, atuando como sumidouros. Visto sua importância, novas aplicações de ferramentas de sensoriamento remoto têm surgido para auxiliar no planejamento e implantação da silvicultura urbana. O sistema de escaneamento a laser aerotransportado LiDAR (*Light Detection And Ranging* em inglês), gera uma representação em três dimensões do objeto alvo por meio de uma nuvem de pontos georreferenciados. O cruzamento com sensores de altíssima resolução espectral proporciona analises mais aprofundadas do objeto, podendo-se extrair diversas métricas florestais tais como altura, área basal, e até mesmo espécie. O trabalho teve como objetivo verificar a contribuição do uso de informações derivadas da nuvem de pontos LiDAR, na identificação e classificação das seis espécies florestais mais frequentes do Parque Municipal Américo Renné Giannetti em Belo Horizonte, Minas Gerais, Brasil, a fim de auxiliar no planejamento e manejo da silvicultura urbana. Para tanto, por meio de classificação supervisionada, cruzou-se informações de levantamento de campo, segmentação de copas, pontos de topo de copa de árvore extraídos da nuvem LiDAR, e uma imagem multiespectral WordlView-2. A acurácia da classificação foi medida por análise da exatidão global do processo e por meio do índice Kappa. Os pontos de topo de copa de árvore derivados da nuvem LiDAR contribuíram para a localização e classificação das classes referentes às espécies florestais, quando comparados ao mesmo processo sem estes pontos. A segmentação das copas executada pelo programa eCognition facilitou o lançamento das amostras treinamento e teste. O classificador *ECHO* conseguiu melhores valores de acurácia e índice Kappa, frente aos outros classificadores do programa Multispec. O uso de informações provenientes da nuvem de pontos LiDAR se mostrou promissor em imagens multiespectrais de ambiente florestal urbano, aumentando a acurácia geral da classificação supervisionada.

Palavras-chave: Planejamento urbano; Arborização urbana; Escaneamento a laser

ABSTRACT

Use of hyperspectral imagery and LiDAR technology to identify tree species in an urban environment in the city of Belo Horizonte, Minas Gerais

Urban forestry is a key element to maintaining the quality of life in urban centers. The existence of a broad network of trees distributed along roads and public spaces acts to promote air quality, water conservation, thermal comfort, acoustic and psychological citizens. Urban forests are able to mitigate the emissions of Greenhouse Gases (GHG) such as CO2, acting as sinks. Since its importance, new applications of remote sensing tools have emerged to assist in planning and implementation of urban forestry. The laser scanning system airborne LiDAR (*Light Detection And Ranging*), generates a three-dimensional representation of the target object through a cloud of points georeferenced. The crossing with very high resolution sensors provides more in-depth analysis of the object and can be extracted several forest metrics such as height, basal area, and even species. The study aimed to verify the contribution of LiDAR derived points in the identification and classification of six most common tree species in Parque Municipal Americo Renne Giannetti, Belo Horizonte, Minas Gerais, Brazil, in order to assist urban forestry planning and management. Through supervised classification, field survey information, segmented areas, LiDAR treetop points, and a multispectral WordlView-2 image were crossed together. The classification accuracy was measured by analyzing overall accuracy and Kappa index. The LiDAR treetop points contributed to location and classification of tree species' classes, when compared to the same process without these points. The segmentation of crowns performed by eCognition program facilitated the launch of training and test samples. ECHO classifier showed the best accuracy and Kappa index in comparison to other Multispec program classifiers. The aggregation of LiDAR data showed promise in urban forest multispectral images, increasing supervised classification overall accuracy.

Keywords: Urban planning; Urban arboriculture; Laser scanning

LISTA DE FIGURAS

Figura 1 - Desenho básico característico de cidades espanholas e portuguesas durante os anos de colonização. À esquerda, grade de ruas da Cidade do México respeitando um plano ortogonal; à direita, grade de ruas de Ouro Preto, MG, seguindo a topografia montanhosa da cidade. 32

Figura 2 – Propagação de característica ondulatória da energia eletromagnética. Fonte: Adaptado de Novo (1992). 36

Figura 3 – Espectro eletromagnético. Fonte: Adaptado de ARMSTRONG, M. **The Schema Frequency**. 2015. Disponível em: <http://www.armstrongeconomics.com/archives/tag/third-dimension-of-the-ecm>. Acesso em: 05 out. 2015. 38

Figura 4 – A imagem da esquerda exemplifica as diferentes formas de interação da radiação eletromagnética incidente (I) na folha: Absorção (A), Transmissão (T) e Reflexão (R). A imagem da direita mostra a relação entre a Radiação Fotossintéticamente Ativa – RFA à taxa fotossintética das plantas. Nota-se que os picos de absorção de energia dos pigmentos fotossintéticos estão estritamente relacionados aos picos de atividade fotossintética. Fonte: Adaptado de imagens disponíveis na internet. 41

Figura 5 – Exemplo de uma nuvem de pontos LiDAR do parque municipal Américo Renné Giannetti, em Belo Horizonte, MG. 58

Figura 6 – Principais movimentos de rotação de uma aeronave medidos pelo IMU: A) ângulo de arfada, B) ângulo de guinada, e C) ângulo de rolamento (à esquerda). Esquema de aquisição de dados LiDAR por meio da emissão de feixes de laser interceptando um alvo (varredura) (à direita). 59

Figura 7 – Área de estudo: Parque Municipal Américo Renné Giannetti, cidade de Belo Horizonte, Minas Gerais, Brasil. Fonte: Arquivo pessoal. 66

Figura 8 – Plano urbano desenhado por Aarão Reis para Belo Horizonte, em 1895. O parque municipal Américo Renné Gianetti aparece na região central do mapa, ainda com sua configuração e desenho originais. Imagem de domínio público. 66

Figura 9 – Configuração atual do parque municipal Américo Renné Giannetti. Ao longo das décadas parte do parque foi cedido para a construção do

complexo de saúde, para a construção do campo do América Futebol Clube – AFC, e para zoneamento urbano..... 67
Figura 10 – Informações referentes a cada árvore (pontos georreferenciados) do levantamento de campo: Localização geográfica, espécie, número de identificação exclusivo (FID), hábito e nome popular. 69
Figura 11 – Seis espécies arbóreas mais frequentes no Parque Municipal Américo Renné Giannetti: *Spathodea campanulata* P. Beauv.; *Ficus benjamina* L.; *Syzygium cumini* (L.) Skeels; *Ceiba speciosa* (A. St.-Hil.) Ravenna; *Handroanthus impetiginosus* (Mart. ex DC.) Mattos; e *Eucalyptus sp.* As espécies *Murraya paniculata* e *Ligustrum lucidum* não foram utilizadas por pertencerem a um estrato intermediário, que não se sobressai na imagem WorldView-2..... 69
Figura 12 – Gráfico de alcance dos comprimento de onda de cada banda da imagem WorldView - 2. Satellite Sensor. 2013. Disponível em: <http://www.spot-7.com/satellite-sensors/worldview-2.html>. Acesso em: 01 abr. 2015... 70
Figura 13 – Imagem hiperespectral recortada do Parque Municipal Renné Giannetti em Belo Horizonte, MG, Brasil..... 72
Figura 14 – Esquema simplificado do processamento da nuvem LiDAR. Etapas compreendem da conversão do formato original da nuvem em .LAS até a extração dos pontos de máxima, pelo comando *CanopyMaxima*..... 74
Figura 15 – Esquema resumido para a obtenção da imagem classificada final. 76
Figura 16 – Esquema de segmentação realizado pelos programas Idrisi e eCognition na imagem WV2. 77
Figura 17 – Interface da ferramenta Segmentation do programa Idrisi. É possível alterar os critérios de análise da imagem. 77
Figura 18 – Interface do comando Multiresolution Segmentation do programa eCognition. É possível modificar diversos critérios de análise da imagem. 79
Figura 19 – Escolha da melhor segmentação para ser utilizada na classificação final. Por meio de uma análise visual dentre todas as combinações possíveis de segmentação dos programas Idrisi e eCognition, chegou-se a uma segmentação cada. Em seguida, por meio de análise estatística das áreas dos polígonos formados, escolheu-se a segmentação gerada pelo programa eCognition. 81

Figura 20 – Comparação visual do padrão de segmentação executado pelos programas eCognition e Idrisi. Em A, a segmentação escolhida do Idrisi: ST = 30, WW = 5, WMF = 0.25 e WVF = 0.75; e em B, a segmentação escolhida do eCognition: SP = 20, S = 0.25 e C = 0.75. 82
Figura 21 – Esquema de segmentação realizado pelos programas ArcGis, Idrisi, eCognition e Fusion no MDE derivado da nuvem LiDAR. 83
Figura 22 – Padrões de segmentação gerados pelos programas: A) ArcGis; B) Idrisi; e C) eCognition. 84
Figura 23 – Fluxograma dos passos realizados no programa ArcGis para a segmentação das copas, por meio da ferramenta *Watershed*. 85
Figura 24 – Mapa categorizado de pontos provenientes da nuvem LiDAR.....87
Figura 25 – Esquema ilustrando as classificações realizadas na imagem WV2, por meio do programa livre Multispec versão 3.4. 89
Figura 26 – Imagem WV classificada pelos classificadores: A) Maximum Likelihood, B) Fisher Linear Likelihood, C) Minimum Euclidean Distance, D) ECHO Spectral-spatial, E) Correlation (SAM), F) Matched Filter (CEM), e G) Parallel Piped. 91
Figura 28 – Região do coreto do parque aproximada para ilustrar as diferenças no padrão de classificação não-supervisionada realizada pelos classificadores: A) *Maximum Likelihood*, B) *Fisher Linear Likelihood*, C) *Minimum Euclidean Distance*, D) *ECHO Spectral-spatial*, E) *Correlation (SAM)*, F) *Matched Filter (CEM)*, e G) *Parallel Piped*. 92
Figura 28 – Comparação gráfica do desempenho dos sete classificadores utilizados na definição, em porcentagem do total, das áreas das classes de uso e ocupação de solo estabelecidas. Legenda: MAXLIKE = *Maximum Likelihood*; FISHER = *Fisher Linear Likelihood*; MED = *Minimum Euclidean Distance*; ECHO = *ECHO Spectral-spatial*; SAM = *Correlation (SAM)*; CEM = *Matched Filter (CEM)*; e PP = *Parallel Piped*. 93
Figura 29 – Padrões de classificação supervisionada gerados pelos classificadores: aproximada para ilustrar as diferenças no padrão de classificação realizada pelos classificadores: A) *Maximum Likelihood*, B) *Fisher Linear Likelihood*, C) *Minimum Euclidean Distance*, D) *ECHO Spectral-spatial*, E) *Correlation (SAM)*, F) *Matched Filter (CEM)*, e G) *Parallel Piped*.....95

Figura 30 – Região do coreto do parque aproximada para ilustrar as diferenças no padrão de classificação supervisionada realizada pelos classificadores: A) *Maximum Likelihood*, B) *Fisher Linear Likelihood*, C) *Minimum Euclidean Distance*, D) *ECHO Spectral-spatial*, E) *Correlation (SAM)*, F) *Matched Filter (CEM)*, e G) *Parallel Piped*. 96

Figura 31 – Esquemas que ilustram os procedimentos adotados para auxiliar o lançamento de amostras de treinamento e teste da classificação final da imagem WV2. 98

Figura 32 – Comparação do lançamento de amostras de treinamento e teste nas classificações com os pontos de topo de copa derivados da nuvem LiDAR (A) e sem os pontos LiDAR (B). 100

Figura 33 – Total de indivíduos nativos e exóticos do Brasil encontrados no parque municipal Américo Renné Giannetti em Belo Horizonte, MG. Dos 2904 indivíduos levantados, 54% (1557) são exóticos e 46% (1315) são nativos. 101

Figura 34 – O gráfico da esquerda traz o total de espécies nativas e exóticas do Brasil encontradas no parque municipal Américo Renné Giannetti em Belo Horizonte, MG. Das 164 espécies encontradas, 46% (73) são exóticas e 54% (85) são nativas. O gráfico da direita traz a proporção de espécies nativas brasileiras de ocorrência local (nativas locais (52), que não ocorrem na região de BH (exóticas locais (27) e de origem desconhecida (6). 101

Figura 35 – Comparação das do tamanho das áreas (em porcentagem do total) definidas para cada classe, pelo classificador ECHO, na classificação com os pontos de topo de copa derivados da nuvem LiDAR (azul) e sem os pontos (laranja). 104

Figura 36 – Classificação supervisionada executada com o auxílio dos pontos de topo de copa derivado da nuvem LiDAR na definição das amostras de treinamento e teste (A), e sem o auxílio dos pontos do LiDAR (B). Detalhe das classificações com e sem os pontos de topo de copa do LiDAR (C e D respectivamente) tomando como referência a região do coreto do parque. 105

Figura 37 – Detalhes do efeito sal-e-pimenta na classificação. Em A, nota-se o predomínio da classe Ceiba speciosa (azul claro) na classe *Spathodea*

campanulata; em B, pixels de diversas classes (ruído) erroneamente classificados como *Ficus benjamina* (rósea); em C, ruído na classe *Eucalyptus sp.* (verde); em D, classe *Eucalyptus sp.* erroneamente associada a indivíduos de *Spathodea campanulata* (acima) e *Ficus benjamina* (abaixo). 107

LISTA DE TABELAS

Tabela 1 – Principais grandezas radiométricas utilizadas no sensoriamento remoto. 40
Tabela 2 – Principais sensores multiespectrais instalados por satélite LANDSAT....46
Tabela 3 – Principais sensores hiperespectrais sub-orbitais em operação comercial. 50
Tabela 4 – Principais sensores hiperespectrais orbitais em operação.....51
Tabela 5 – Especificações técnicas dos satélites da série WorldView: Órbita, sensores e resolução espacial. 71
Tabela 6 – Dados gerais do sobrevoo e especificações do sensor LiDAR utilizado na aquisição da nuvem de pontos do parque municipal Américo Renné Giannetti. 73
Tabela 7 – Relação das combinações possíveis para os comandos de segmentação dos programas Idrisi e eCognition. 79
Tabela 8 – Estatística básica exploratória aplicada às segmentações escolhidas realizadas pelos programas Idrisi e eCognition, na imagem WV2. A menor média (m²) e desvio padrão (m²) foram encontrados para a segmentação do programa eCognition. 82
Tabela 9 – Estatística básica exploratória aplicada às segmentações escolhidas realizadas pelos programas ArcGis, Idrisi, eCognition e Fusion, no MDE. A menor média (m²) e desvio padrão (m²) foram encontrados para a segmentação do programa eCognition. 87
Tabela 10 – Classes de uso e ocupação do solo definidas tanto para a classificação não-supervisionada quanto para a supervisionada da imagem WV2.....90
Tabela 11 – Acurácia do usuário (UA), exatidão global (EG) e índice Kappa (Kappa) obtidos para os sete classificadores disponíveis no programa Multispect. 97
Tabela 12 – Tabela de interpretação dos valores do índice Kappa, elaborado por Landis e Koch (1977). 97
Tabela 13 – Matrizes de erro para as classificações com os pontos de topo de copa derivados da nuvem LiDAR (acima), e sem os pontos de topo de copa derivados da nuvem LiDAR (abaixo). 103

1 INTRODUÇÃO

As populações urbanas têm crescido vertiginosamente nas últimas décadas. Por volta do ano de 2011, metade da população do planeta passou a viver em centros urbanos, o que representa cerca de 3,6 bilhões de pessoas (ORGANIZAÇÃO DAS NAÇÕES UNIDAS - ONU, 2012), enquanto que nos anos 1950 esse número não passava dos 750 milhões de habitantes. Projeções feitas pela ONU indicam um aumento nesse valor para 5 bilhões de pessoas por volta do ano de 2030 (THE UNITED NATIONS POPULATION FOUND - UNFPA, 2007). O agravamento desse fenômeno mundial acarreta em uma pressão ambiental cada vez maior nos ecossistemas naturais que abastecem de recursos as cidades. A fragmentação das florestas representa a redução do habitat de diversas espécies de fauna e flora e a destruição da biodiversidade regional (ROJAS et al., 2013). Cada vez mais perdendo seus ambientes de alimentação e reprodução, os animais se veem obrigados a se afugentar nas metrópoles, causando conflitos com os habitantes das cidades. Ainda, Herbert (2009) aponta que as cidades são responsáveis por 75% do consumo dos recursos naturais do planeta e por 80% da emissão dos GEEs. Além do mais, um quarto de toda a emissão de CO2 no planeta provém do setor de transportes, e que dessa quantia, três quartos são emitidos pelo setor rodoviário (YIN et al., 2013).

Outro agravante que as cidades representam é a contribuição para o aumento da temperatura em pequena e média escala. O Painel Internacional para as Mudanças Climáticas (IPCC) projetou que a temperatura média do planeta tende a aumentar 2°C até por volta do ano de 2100, devido principalmente às atividades humanas (INTERNATIONAL PANEL ON CLIMATE CHANGE - IPCC, 2007). Os centros urbanos, com suas ruas pavimentadas e áreas concretadas, contribuem para o aumento da temperatura local e para o desequilíbrio do microclima regional, gerando um fenômeno conhecido como “ilha de calor”. Estudos na região metropolitana de São Paulo mostram que em um mesmo horário do dia, a temperatura registrada em duas regiões distintas variou cerca de 14°C. A maior temperatura foi registrada no centro da cidade (30°C), cuja intensa impermeabilização – asfalto, calçadas, edificações e ausência de áreas verdes – contribuem para a retenção do calor, enquanto que nas regiões periféricas onde há uma maior cobertura florestal, a temperatura média registrada foi de 16°C

(LOMBARDO et al., 2012). As cidades ainda contribuem para o aumento na emissão de GEEs, como o CO2, por exemplo. A grande frota de automóveis e os incentivos ao transporte individual ao invés do coletivo sobre trilhos tornam as cidades grandes geradoras de poluição que, muitas vezes, fica concentrada, afetando a qualidade de vida da população (FIGLIOZZI, 2011; MAKIDO et al, 2012; CHEN et al., 2013; HUANG; MENG, 2013; SIMIO et al, 2013).

Nesse contexto, a silvicultura urbana contribui para amenizar os reflexos negativos causados pelas cidades. Em sua definição, a silvicultura urbana, no sentido estrito de plantio, é uma atividade que integra manejo e manutenção das árvores nos ambientes urbanos de forma que fiquem assegurados os múltiplos benefícios sociais e ambientais aos cidadãos (MILLER, 1996). O autor acrescenta os benefícios psicológicos e econômicos que as florestas urbanas geram à sociedade. Ele define, ainda, que a silvicultura urbana abrange as árvores tanto a nível individual quanto em grupos ou ainda em remanescentes nativos inseridos na matriz urbana. As florestas urbanas são responsáveis pela melhoria da qualidade do ar, filtrando o ar e imobilizando o CO_2 atmosférico em matéria orgânica (i.e., folhas, galhos, tronco) (McPHERSON, 2006; REN et al., 2013); aumento do conforto térmico, acústico e psicológico; quebra na velocidade dos ventos; redução da amplitude térmica; e, pela regulação dos processos hídricos, amenizando a aridez do concreto das metrópoles (SILVA FILHO et al., 2002; McPHERSON, 2006; CONWAY; URBANI, 2007; ROSSATO et al., 2008; SEAMANS, 2013). Sob o ponto de vista social, as áreas públicas arborizadas – parques, praças, canteiros – se integram ao cotidiano da população, promovendo a convivência dos habitantes e atraindo-os para praticar esportes ao ar livre como ciclismo e caminhadas, por exemplo (KUO, 2003; McPHERSON, 2006; CONWAY; URBANI, 2007; SEAMANS, 2013; THOMPSON et al., 2013). Outras funções desempenhadas por estas áreas são: servir de abrigo à fauna, proteção a cursos d’água e de corredores de conexão entre fragmentos florestais inseridos na paisagem urbana (SILVA FILHO et al., 2002; McPHERSON, 2006). A existência de ruas arborizadas ao redor de parques e praças permite o deslocamento da fauna em busca de abrigo e alimento.

Dessa forma, o planejamento da silvicultura urbana se torna imprescindível para que tais benefícios sejam alcançados em sua totalidade. Para tanto, novas tecnologias de sensoriamento remoto têm surgido para auxiliar os tomadores de decisão a elaborar projetos que integrem as árvores as cidades sem que haja

conflitos com a infraestrutura urbana (GIONGO et al., 2010; ZHANG; QIU, 2012a). A tecnologia LiDAR (*Light Detection And Ranging,* sigla em inglês para Varredura Remota a Laser, em uma tradução livre) vem se tornando cada vez mais útil para a obtenção remota e precisa dos parâmetros biofísicos da floresta. Essa tecnologia é capaz de fornecer uma representação em três dimensões do objeto de interesse por meio da emissão e recepção de feixes de luz. De suas mais diversas utilizações, o LiDAR vem cada vez mais sendo aplicado aos estudos florestais, agregando informações obtidas remotamente a inventários e levantamentos florísticos, por exemplo.

Aliada a outras tecnologias, o LiDAR possibilita, também, a identificação individual de espécies por meio da análise da área de copa e do estrato florestal (LI et al., 2012). Os autores Holmgren e Persson (2004), Popescu e Wynne (2004), Popescu et al. (2004), Suárez et al. (2005), Chen et al. (2006), Koetz et al. (2007), Dalponte et al. (2008), Giongo et al. (2010), Li et al. (2012) indicam que o cruzamento de dados de LiDAR com dados de sensores multiespectrais (ou ainda hiperespectrais que fornecem melhores informações do ambiente) permitem a caracterização da vegetação e a identificação de espécies florestais, isso porque os sensores oferecem diferentes informações e quando analisados em conjunto atuam complementarmente (KIM et al., 2009). Na silvicultura urbana essa capacidade do sistema de possibilitar a identificação de espécies foi pouco explorada pelo ambiente urbano ser heterogêneo e repleto de interferências externas as árvores. A necessidade de filtrar a nuvem de pontos para melhor visualização das feições silviculturais é um desafio quando se trabalha em ambiente urbano. Outra questão é a alta heterogeneidade das condições das árvores nas cidades, variando de espécie, idade, estágio de desenvolvimento. Porém estudos recentes dos autores Oshio et al. (2012), Shreshta e Wynne (2012), Huang et al. (2013), vêm aprimorando as técnicas de captura de informações da nuvem de dados, ampliando a capacidade do LiDAR em auxiliar no planejamento urbano.

Diante do exposto, a tecnologia LiDAR se destaca como uma ferramenta promissora no planejamento ambiental das cidades no Brasil e oferece uma ampla variedade de informações essenciais às atividades silviculturais.

Uma questão precisa ser esclarecida antes de se dar continuidade a esse trabalho. Embora o título indique o emprego de uma imagem hiperespectral nos processos de segmentação e classificação que serão abordados mais adiante, foi

utilizada uma imagem multiespectral WorldView-2, pois não foi possível, à época, ter acesso a uma imagem hiperespectral da área. Espera-se que no futuro, se possa ter acesso à uma imagem hiperespectral da mesma área, para que se faça a comparação dos resultados.

2 OBJETIVOS

2.1 Objetivo Geral

O trabalho teve como objetivo verificar a contribuição do uso de informações derivadas da nuvem de pontos LiDAR, na identificação e classificação das seis espécies florestais mais frequentes do Parque Municipal Américo Renné Giannetti em Belo Horizonte, Minas Gerais, Brasil, a fim de auxiliar no planejamento e manejo da silvicultura urbana. Para tanto, por meio de classificação supervisionada, cruzou-se informações de levantamento de campo, segmentação de copas, pontos de topo de copa de árvore extraídos da nuvem LiDAR, e uma imagem multiespectral WordlView-2.

2.2 Objetivos específicos

Como objetivos específicos citam-se: 1) Conhecer como as imagens multiespectrais e LiDAR podem ser utilizadas em conjunto; 2) Verificar o desempenho de três programas na segmentação da imagem WorldView-2, e comparar os resultados às informações fornecidas pela nuvem LiDAR ; 3) Verificar o desempenho de sete classificadores na identificação e classificação de 14 classes de uso e ocupação de solo definidos para o Parque Municipal Américo Renné Giannetti; 4) Encontrar o melhor classificador para a imagem WorldView-2; 5) Verificar a contribuição dos pontos derivados da nuvem LiDAR na classificação supervisionada da imagem WorldView-2 do parque.

3 REVISÃO BIBLIOGRÁFICA

3.1 Os parques no contexto urbano

A criação dos primeiros parques urbanos no Brasil está intimamente relacionada ao desenvolvimento econômico de meados do século XIX e às influências internacionais que o país sofria a época. Antes, porém, é preciso contextualizar historicamente, de forma breve, as condições que levaram as cidades brasileiras a se desenvolverem desordenadamente como se vê hoje, e como se deu a criação dos parques urbanos.

3.1.1 A urbanização no Brasil

O processo de urbanização no Brasil ocorreu de maneira particular, complexa e dotada de influências políticas e econômicas, internas e externas. A vocação agrícola do Brasil, praticamente desde seu “descobrimento”, conduziu a maneira com que a cidade se inseria na sociedade e como a sociedade construía as cidades.

O primeiro elemento determinante na urbanização foi o próprio desenho adotado pelos portugueses no estabelecimento de vilas e povoados. Ele reflete a estratégia exploratória que Portugal definira para sua colônia que, em comparação à estratégia espanhola de conquista e colonização, parece desordenada e confusa. A ordem que vinha da Espanha era estabelecer colônias como uma extensão da metrópole. Por esse motivo que em 1573 o rei Felipe II da Espanha instituiu a Lei das Índias, primeira lei de ordenamento territorial que definia regras urbanísticas consideradas ideais para o estabelecimento bem sucedido de um povoado, e que deveria ser empregada nas novas colônias da América. Segundo a Lei das Índias, o novo povoado deveria ser estabelecido em um local aprazível, plano, seguindo uma grade ortogonal de ruas partindo de uma praça central. A igreja principal e os edifícios administrativos deveriam estar localizados próximos a praça (Figura 1).

Por outro lado Portugal não definira nenhuma regra para o planejamento de novos povoados em suas colônias, à exceção, tal qual visto no desenho espanhol, da obrigação das ruas partirem da praça (ou largo) da sede eclesiástica local, com os edifícios administrativos ladeando a praça. Devido a essa liberdade, as cidades portuguesas cresceram de maneira espontânea, irregular e pouco densa, de acordo com as circunstâncias (HOLANDA, 1995).

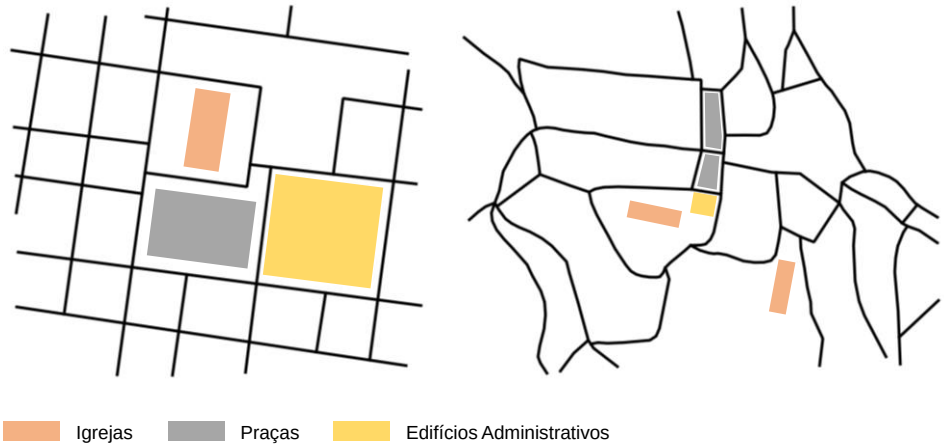

Figura 1 - Desenho básico característico de cidades espanholas e portuguesas durante os anos de colonização. À esquerda, grade de ruas da Cidade do México respeitando um plano ortogonal; à direita, grade de ruas de Ouro Preto, MG, seguindo a topografia montanhosa da cidade.

Os espanhóis viam o estabelecimento de cidades como ferramentas de domínio sobre o novo território. Elas deveriam refletir o sentimento de controle da coroa sobre seus súditos. Não se podia abandonar o rígido modelo urbanístico. Portugal, por sua vez, adotava uma postura mais liberal pois o que lhes realmente interessava era lucrar com a exploração dos recursos naturais. A adoção do sistema de sesmarias transferiu a responsabilidade da terra ao proprietário, cabendo à coroa a cobrança de impostos e o controle da movimentação de mercadoria para a metrópole. Para os portugueses as cidades eram apenas locais de apoio e serviços às grandes fazendas; locais de passagem, entrepostos de mercadoria com destino a Portugal.

A inércia portuguesa no estabelecimento de cidades como símbolo de domínio do território brasileiro, retrata uma natureza passiva, puramente mercantilista e desinteressada em definitivamente se estabelecer na colônia. A esta cabia somente o papel de gerar lucro, seja pelo fornecimento de recursos, seja pela dependência dos bens de consumo feitos na Europa.

Outro fator que definiu a ocupação territorial do Brasil nos primeiros anos de colonização é a indissociável ligação do português com o mar. A ordem era ocupar o litoral, criando e protegendo os portos. Investidas território a dentro eram desencorajadas e sujeitas a punições severas. Tudo que era relacionado com o sertão era perigoso e desinteressante. A expansão para o planalto só se fortaleceu devido às bandeiras que, ao passo em que descobriam recursos minerais iam estabelecendo núcleos urbanos. Por outro lado, os espanhóis estabeleciam-se o

mais distante possível do litoral. Para eles, as regiões interioranas ofereciam, além de condições sanitárias e climáticas mais favoráveis, principalmente segurança ao ataques de corsários.

Todavia, as planícies áridas da américa central e do sul ofereciam pouco de um recurso essencial: água fresca corrente. As cidades espanholas dependiam de poços profundos para o abastecimento da população, enquanto que as cidades portuguesas interioranas resolviam muito bem esse problema, se estabelecendo ao longo das margens de rios. A topografia, então, definiu o desenho de muitas cidades brasileiras. As ruas eram traçadas em curvas de nível e as casas eram erguidas próximas aos corpos d'água, facilitando ao mesmo tempo o abastecimento e o esgotamento (FERREIRA, 1996).

O segundo elemento motor da urbanização é a economia. O Brasil é essencialmente agrícola, e desde os séculos coloniais essa condição influenciou a forma que as cidades se desenvolviam. Entre os séculos XVI e XVII o Brasil passou pelo chamado ciclo do Açúcar. A economia era baseada no plantio de cana (acontecendo principalmente no litoral) e no comércio de açúcar para a Europa. A elite agrícola colonial vivia em suas fazendas que assumiam, ao mesmo tempo, papel de moradia e escritório para as transações comerciais. As cidades funcionavam como fonte de serviços e entrepostos de mercadoria, como dito anteriormente. A partir do século XVIII, porém, com o declínio do ciclo do Açúcar e o surgimento do ciclo do Ouro – baseado na exploração mineral em Minas Gerais, urbanização começa a tomar forma. Os núcleos urbanos se adensam e passam a funcionar como centros de negócios. Como símbolo de status social, os senhores de engenho se mudam para as cidades, retornando às fazendas somente nas épocas de colheita de cana (SANTOS, 2009), formando uma nova elite urbana.

O surgimento do café como commodity agrícola no princípio do século XIX motivou o surgimento de um novo ciclo econômico, o ciclo do Café. Os grandes latifundiários influenciavam política e economicamente o país na época. Financiavam diversas obras de infraestrutura para o escoamento do café, notadamente a implantação de estradas de ferro, e transformavam as antigas cidades coloniais em modernas cidades aos moldes europeus. A industrialização no Brasil, se dando em meados do século XIX, também fez surgir uma elite exclusivamente urbana.

O quesito político também incentivou a melhoria nas condições de vida nas cidades. A vinda da coroa portuguesa para o Rio de Janeiro em 1808, deu início a

um processo de urbanização forçado, transformando a antiga cidade colonial para poder comportar a família real. A independência do Brasil, em 1822 seguida da proclamação do Império marca a troca do controle político português pelo controle econômico inglês. O país se via dependente economicamente da Inglaterra, importando bens de consumo e de infraestrutura. Com a abolição da escravatura, em 1888, e a vinda dos imigrantes europeus para trabalhar nas plantações de café, a população de negros livres mudava-se cada vez mais para as cidades, provocando períodos de adensamento urbano. A proclamação da república (motivada pelos latifundiários cafeicultores paulistas), em 1889, marcou a influência política e econômica que o capital privado tinha sobre os rumos do país. Esse mesmo capital privado definiu o modelo urbano do Brasil, inspirado nos movimentos liberais e modernistas que ocorriam na Europa nas últimas décadas do século XIX e princípios do século XX.

3.1.2 Os parques urbanos no Brasil

As influências econômicas e culturais que o país sofria nas últimas décadas dos anos 1800, principalmente da Europa e dos Estados Unidos, refletiriam de diversas maneiras no espaço urbano, e entre elas, no surgimento dos primeiros parques urbanos. Nos séculos anteriores, nas cidades coloniais, praticamente não existiam parques, praças ou jardins públicos. Os únicos espaços ajardinados eram pátios internos de igrejas e conventos e quintais de grandes propriedades. Em ambos, os jardins cumpriam um papel funcional: de ambientes voltados à meditação e contemplação; e de apoio às cozinhas, com o cultivo de árvores frutíferas, hortaliças e ervas medicinais (ROBBA; MACEDO, 2003).

O conceito de parque urbano que se conhece hoje surgiu em meados do século XIX, como um equipamento urbano ajardinado que se incorporasse à cidade, e que servisse fundamentalmente ao lazer, recreação e contemplação. Este é o caso do Central Park em Nova York, obra do paisagista norte-americano Frederick Law Olmsted (SILVA; PASQUALETTO, 2013), que buscava, em seu desenho, integrar o ambiente urbano a um parque que recriasse e reunisse as características de um ambiente natural tal qual deveria parecer em estado selvagem.

No Brasil, o primeiro parque urbano foi o Passeio Público no Rio de Janeiro, em 1783. No entanto, devido à falta de uma elite urbana estruturada e a sua localização fora do centro, ele foi abandonado. Em 1862, inserido em uma proposta

urbanística inovadora para os padrões brasileiros da época, coordenada pelo paisagista francês Auguste François Marie Glaziou, o Passeio Público foi reformado e entregue ao público novamente. Ele, agora, fazia parte de uma rede de novos parques e praças ajardinadas da capital brasileira. Apesar do Jardim Botânico do Rio de Janeiro ter sido criado em 1808, não foi considerado o primeiro Parque Urbano do país, devido a seu papel de ambiente de aclimatação de espécies e seu uso exclusivo da nobreza.

A partir de então, entre as décadas finais do século XIX e início do século XX foram criados parques em Belém, Fortaleza, Recife, Curitiba, Belo Horizonte e São Paulo (SILVA; PASQUALETTO, 2013), cidades que viviam os anos de pujança econômica e de pleno desenvolvimento urbano. O desenho romântico dos parques ingleses, marcado pelos caminhos curvos e grandes gramados, e o desenho clássico dos parques franceses, que, sob influência dos jardins renascentistas, são marcados pelas linhas retas e simetria, perdurariam até meados do século XX, quando o parque urbano adotaria outros papeis nas cidades.

A partir dos anos 1940 as cidades modernas cresciam e os espaços publicas tinhas que se adequar à nova realidade de uma sociedade motorizada e dinâmica. Paisagistas modernistas como Roberto Burle Marx, Thomas Church e Garret Eckbo começaram a traçar os parques com olhos na função recreativa e de lazer, e os jardins deixaram de fazer parte da paisagem como elementos de moldura, para assumir um papel integrado no contexto geral, um elemento da paisagem em si.

Os jardins da Lagoa da Pampulha e o Parque das Mangabeiras em Belo Horizonte, o Aterro do Flamengo no Rio de Janeiro e o Parque Ibirapuera em São Paulo, são exemplos desse movimento.

Nos anos que se seguiram, a função dos parques mudou novamente, obrigando-os a se adaptarem às novas necessidades sociais. No meio tempo, porém, muitos passaram por momentos de abandono, tornando-se ambientes degradados e sinônimos de insegurança. A muito disso se atribui ao inchaço populacional das grandes metrópoles, gerado pela crescente industrialização entre os anos 1970 e 1980.

As cidades contemporâneas, maiores e mais industrializadas exigiram que os parques servissem não somente como locais de contemplação da natureza e descanso, mas principalmente, áreas públicas destinadas ao lazer e à prática de esportes. Assim, os parques se tornaram mais amplos, gramados e dotados de

equipamentos e infraestrutura para a prática de atividades físicas. Os parques Tanguá, Tingui e Barigui e o Jardim Botânico em Curitiba, e o parque Villa Lobos, Belém e da Juventude, em São Paulo são exemplos de parques com uso misto. Os dois últimos exemplos na capital paulista, ainda, trazem consigo a requalificação do espaço urbano. Em ambos, áreas degradadas e subutilizadas foram transformadas em parques, trazendo melhorias à população em escala local.

3.2 A extração de informações de recursos digitais

O sensoriamento remoto é a ciência de extração de informações de objetos, feições ou fenômenos, por meio da análise de dados obtidos por sensores de forma indireta, remota (NOVO, 1992; LILLESAND et al., 2004). As mais diversas áreas de trabalho e campos de pesquisa se utilizam do sensoriamento remoto devido a sua versatilidade e variedade de ferramentas e aplicações. O usuário, por sua vez, ganha agilidade nas tomadas de decisão, otimizando tempo e recursos. Para compreender de que forma as informações acerca do objeto estudado são obtidas, é preciso, primeiramente, entender o comportamento e interações da energia eletromagnética.

3.2.1 A radiação eletromagnética

Qualquer corpo que possua temperatura absoluta acima do zero grau kelvin (0°K) emite radiação. De acordo a teoria ondulatória, uma carga elétrica acelerando no vácuo provoca perturbações repetitivas no campo elétrico e magnético. Estas perturbações são denominadas ondas eletromagnéticas (Figura 2).

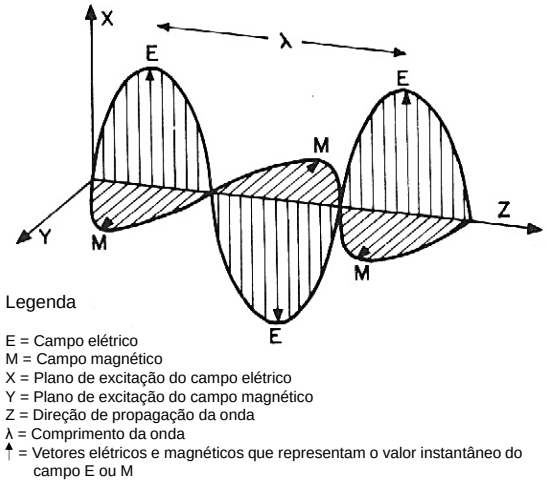

Figura 2 – Propagação de característica ondulatória da energia eletromagnética. Fonte: Adaptado de Novo (1992).

Como visto na Figura 2, os campos elétrico e magnético seguem um padrão ondulatório harmônico, propagando-se perpendicularmente entre si. A razão entre a velocidade ($3x10^8$ m s^{-1}) e a frequência (f) determinam o comprimento de onda (λ):

$$\lambda = \frac{c}{f} \qquad \text{Eq. 1}$$

onde c = velocidade da luz; e f = frequência.

A velocidade da onda eletromagnética no vácuo é a velocidade da luz ($3x10^8$ m s^{-1}). Analisando a equação 1, pode-se concluir que f é diretamente proporcional à c. Assim, quanto maior a velocidade de propagação da onda, maior será sua frequência em um determinado Δt. Por outro lado, λ é inversamente proporcional a f, diminuindo sempre em que a frequência aumentar.

Ao longo do tempo descobriu-se que a energia radiante era transmitida por meios de pulsos de uma certa quantidade de energia. O físico alemão Max Planck (1858-1947) descobriu que um corpo irradia a outro quantidades, “pacotes” fixos de energia, ou quanta (plural quantum), representado pela equação 2:

$$Q = h.f \qquad \text{Eq. 2}$$

onde Q = energia; h = constante de Planck ($6,626x10^{-34}$ Ws^2); f = frequência.

Substituindo f da equação 1, tem-se:

$$\lambda = \frac{hc}{Q} \qquad \text{Eq. 3}$$

Assim, percebeu-se que um quanta de energia é diretamente proporcional à f e inversamente proporcional a λ.

Devido as composições química e física intrínsecas da matéria, cada objeto se comportará de maneira diferente à energia eletromagnética, absorvendo mais energia em um certo comprimento de onda do que outros. Este fenômeno se deve à transferência de energia para os elétrons, que saem do seu estado fundamental nas

camadas de valência, para um estado excitado. Ao passo em que o elétron retorna para seu estado fundamental, ele libera um quantum de energia na forma de fótons. O fóton é uma partícula elementar. É a menor porção quantificável de energia eletromagnética, independente do comprimento, frequência ou tempo. O fóton é geralmente associado à luz, que por sua vez está relacionada a porção visível do espectro eletromagnético.

3.3 O espectro eletromagnético

O espectro eletromagnético é a representação de todas as radiações eletromagnéticas possíveis ordenadas de acordo com o comprimento de onda (Figura 3). Geralmente os comprimentos de onda de maior frequência, e por sua vez de maior energia penetrante, estão a esquerda do espectro, variando de 0,003 a 400 nm de comprimento. As micro-ondas e as ondas de rádio se encontram no oposto do espectro, à direita. Essas ondas possuem frequências baixas, variando de 1000 nm a 30 cm de comprimento. Mais ou menos ao centro, entre 400 e 700 nm, encontra-se a faixa visível do espectro, i.e., o conjunto de ondas que conseguimos interpretar visualmente, ou simplesmente luz.

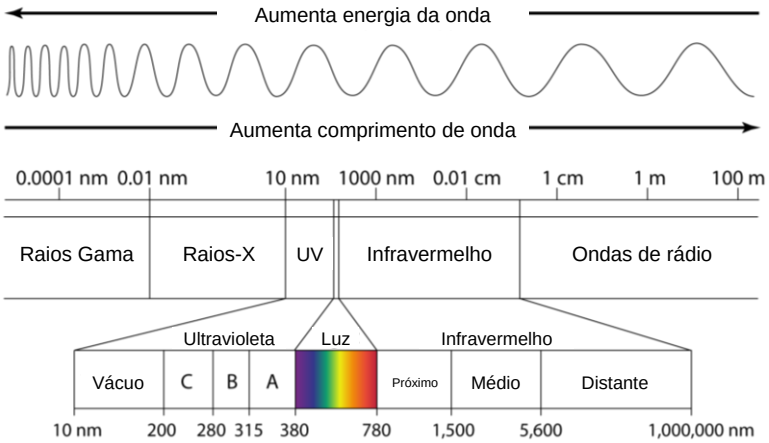

Figura 3 – Espectro eletromagnético. Fonte: Adaptado de ARMSTRONG, M. **The Schema Frequency**. 2015. Disponível em: <http://www.armstrongeconomics.com/archives/tag/third-dimension-of-the-ecm>. Acesso em: 05 out. 2015.

A principal fonte natural de energia eletromagnética é o sol. Ele emite ondas em diversos comprimentos de onda, inclusive a luz, resultantes das intensas reações de fusão nuclear, que transformam hidrogênio em hélio. A luz pode ser decomposta, por meio de um prisma, em faixas que interpretamos como cores: violeta (400 a 446

nm); azul (446 a 500 nm); verde (500 a 578 nm); amarelo (578 a 592 nm); laranja (592 a 620 nm) e vermelho (620 a 700 nm). A cor de um objeto é na verdade o comprimento de onda refletido o material constituinte daquele objeto não consegue absorver. Assim, uma folha verde absorve todas as cores menos o verde.

O conceito básico do sensoriamento remoto é a detecção das diversas alterações sofridas pela energia eletromagnética ao interagir com um objeto, superfície ou com a atmosfera terrestre. Algumas medidas radiométricas (que se diz à radiação) são bastante utilizadas no sensoriamento remoto (Tabela 1) para explicar os fenômenos da luz interagindo com a atmosfera, superfície terrestre e objetos, como a vegetação por exemplo.

Tabela 1 – Principais grandezas radiométricas utilizadas no sensoriamento remoto.

Grandeza Radiométrica	Símbolo	Equação	Unidade de Medida	Conceito
Energia Radiante	Q	-	Joules (J)	Energia transportada em forma de ondas eletromagnéticas
Fluxo Radiante	ϕ	$\phi = \frac{\partial Q}{\partial t}$	Watt (W)	Taxa de variação de energia radiante no tempo
Irradiância	E	$E = \frac{\partial \Phi}{\partial A}$	Watt por metro quadrado (W m^{-2})	Fluxo incidente sobre uma superfície por unidade de área
Excitância	M	$M = \frac{\partial \Phi}{\partial A}$	Watt por metro quadrado (W m^{-2})	Fluxo deixando uma superfície por unidade de área
Intensidade	I	$I = \frac{\partial \Phi}{\partial \Omega}$	Watt por esferorradiano e ângulo sólido (W SR^{-1})	Fluxo radiante deixando uma fonte por unidade de ângulo sólido numa direção especificada
Radiância	L	$L = \frac{\partial^2 \Phi}{\partial A cos\theta \ \partial \Omega}$	Watt por esferorradiano	Intensidade radiante por unidade de área normal à fonte, numa dada direção
Emissividade	E	$E = \frac{M}{M\ corpo\ negro}$	Adimensional	Razão entre a excitância de um material pela excitância de um corpo negro a uma mesma temperatura
Absortância	α	$\alpha = \frac{\partial \Phi a}{\partial \Phi i}$	Adimensional	Razão entre o fluxo absorvido (φa) e o fluxo incidente (φi) numa superfície
Reflectância	ρ	$\rho = \frac{\partial \Phi r}{\partial \Phi i}$	Adimensional	Razão entre o fluxo refletido (φr) e o fluxo incidente (φi) numa superfície
Transmitância	τ	$\tau = \frac{\partial \Phi t}{\partial \Phi i}$	Adimensional	Razão entre o fluxo transmitido (φt) e o fluxo incidente (φi) numa superfície

Fonte: Adaptado de Novo (1992).

3.4 Interação da vegetação com a energia eletromagnética

As folhas das plantas, assim como qualquer material, interagem de maneira particular ao fluxo incidente de energia (φi) proveniente do sol. O φi é formado por três componentes (equação 4):

$$\Phi i = \Phi r + \Phi a + \Phi t \qquad \text{Eq. 4}$$

onde Φr é o fluxo refletido, Φa é o fluxo absorvido e Φt é o fluxo transmitido.

Quando normalizamos a equação 4 por Φi, encontramos algumas propriedades radiométricas da folha (equação 5):

$$1 = \rho + \alpha + \tau \qquad \text{Eq. 5}$$

onde ρ é a reflectância, α é a absortância e τ a trasmitância.

De uma maneira simples, a folha provoca três processos distintos em relação à luz incidente: ela reflete (relacionado a ρ), absorve (relacionado a α) e transmite (relacionado a τ) a energia eletromagnética em proporções diferentes de acordo com propriedades fisiológicas e estruturais (Figura 4). Essa característica permite diferenciar grupos, ou até mesmo espécies de vegetais, sendo utilizado como parâmetro de estudos de sensoriamento remoto.

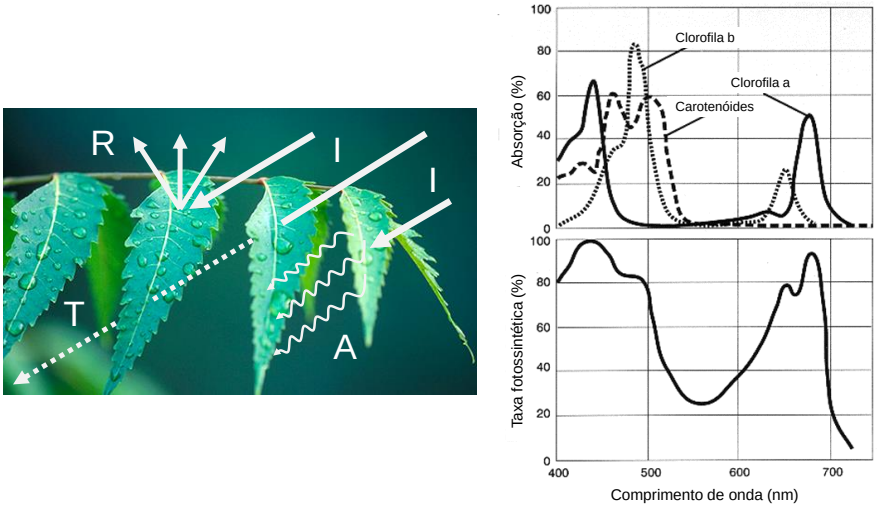

Figura 4 – A imagem da esquerda exemplifica as diferentes formas de interação da radiação eletromagnética incidente (I) na folha: Absorção (A), Transmissão (T) e Reflexão (R). A imagem da direita mostra a relação entre a Radiação Fotossintéticamente Ativa – RFA à taxa fotossintética das plantas. Nota-se que os picos de absorção de energia dos pigmentos fotossintéticos estão estritamente relacionados aos picos de atividade fotossintética. Fonte: Adaptado de imagens disponíveis na internet.

As plantas absorvem luz em bandas específicas do espectro visível (chamada de região da Radiação Fotossinteticamente Ativa) de acordo com os fotorreceptores associados a um processo fisiológico específico, tal como a fotossíntese, por exemplo (Figura 4). As clorofilas e carotenóides absorvem luz entre 445 e 710 nm (do azul ao vermelho distante) para alimentar o processo fotossintético de redução

de CO_2 e H_2O em $C_6H_{12}O_6$ mais O_2. No entanto, devido à condições estruturais, físicas e ao teor de água das células, a reflectância das folhas é alta na região do infravermelho (entre 700 nm e 1 mm), permitindo que, no sensoriamento remoto, a vegetação possa ser diferenciada de outros materiais. A energia eletromagnética nessa região do espectro carrega pouca energia aproveitável pelo vegetal, e, no intuito de evitar possíveis danos estruturais e superaquecimento dos órgãos, os vegetais evoluíram de maneira a refletir a energia nessa faixa do espectro.

O *Normalized Difference Vegetation Index* – NDVI, ou Índice de Vegetação da Diferença Normalizada é uma ferramenta amplamente utilizada no sensoriamento remoto em estudos de monitoramento de vegetação (PONZONI, SHIMABUKURO, 2009). Ele é empregado para traçar perfis sazonais e temporais da vegetação, tais como atividades fenológicas, mudanças fisiológicas e períodos de senescência, possibilitando a comparação em diferentes épocas.

O NDVI é calculado por meio da razão entre a reflectância no infravermelho próximo (NIR) e a reflectância na região do vermelho visível (V), mostrado na equação 6:

$$NDVI = \frac{(\rho\mathrm{NIR} - \rho\mathrm{V})}{(\rho\mathrm{NIR} + \rho\mathrm{V})} \qquad \text{Eq. 6}$$

As imagens resultantes da aplicação do NDVI possuem uma resolução muito abaixo daquela conseguida em sensores multiespectrais tradicionais, como o MSS e TM da série LANDSAT por exemplo. No entanto a área de cobertura é sensivelmente maior, permitindo seu uso em grandes áreas vegetadas (CAMPBELL, 1996; PONZONI, SHIMABUKURO, 2009).

3.5 Formas de aquisição dos padrões espectrais

3.5.1 Sistemas sensores

Os sensores, ou radiômetros, são dispositivos capazes de detectar e registrar a radiação eletromagnética refletida ou emitida pelo alvo, em determinadas faixas do espectro, e transformá-la em informação. Um sensor é basicamente um equipamento dotado de um sistema escaneador/óptico – lentes e espelhos que coletam, decompõe a radiância em diferentes comprimentos de onda, convertendo-

os em um sinal óptico que é enviado ao componente detector. Este converte o sinal óptico em sinal eletrônico contínuo que é ampliado e processado. Nesta última etapa, o sinal processado é amostrado no tempo e quantificado em valores numéricos discretos por elemento de imagem (pixel) (SCHOWENGERDT, 2007). Um pixel é indivisível e é o menor componente da imagem digital (JENSEN, 2000). Os valores numéricos que carregam correspondem a uma média do comprimento de onda captado pelo tempo e espaço. O pixel pode ser imaginado de maneira análoga a um espaço tridimensional (x,y,λ), definido por duas dimensões, x e y, e uma terceira, o comprimento de onda (λ).

A análise das interações espectrais dos objetos à radiação eletromagnética perfaz um dos objetivos do sensoriamento remoto. A vegetação, o solo, minerais e rochas, por exemplo, interagem de maneira particular com a radiação eletromagnética do emitida por fontes naturais tais como o sol, e por fontes artificiais, como radares e *lasers*. Os sensores que medem a radiância naturalmente refletida ou emitida pela superfície ou alvo, são denominados Passivos. As faixas do visível e infra vermelho próximo (NIR) (400-1100 nm) estão na denominada faixa refletiva do espectro eletromagnético, pois a energia fornecida pelo sol excede aquela emitida pela superfície terrestre (radiação termal), medida por sensores que operam em faixas de maior comprimento (infra vermelho distante, micro-ondas e radar) (SCHOWENGERDT, 2007). Por outro lado, sensores Ativos empregam fontes de energia eletromagnética artificial para medir as respostas espectrais dos alvos.

Independentemente da fonte de energia eletromagnética utilizada pelo sensor, o produto final de sua operação deve ser passível de interpretação. Desse modo, é possível separá-los divididos quanto ao tipo de produto que geram: Sensores não-imageadores e sensores imageadores.

3.5.1.1 Sensores não-imageadores

Os sensores não-imageadores são utilizados para medições pontuais de reflectância do alvo. Devido ao fato de a obtenção de dados não ser contínua, não é possível formar uma imagem da área medida. Os principais produtos desses dispositivos serão tabelas numéricas e curvas espectrais (NOVO, 1992; MOREIRA, 2005).

As curvas espectrais são representações gráficas da potência eletromagnética emitida, refletida ou transmitida pelo objeto, expressa em

porcentagem de reflectância por comprimento de onda. Todos os objetos que interagem com a radiação eletromagnética geram curvas características referentes a sua composição química e física.

Existem os sensores não-imageadores de bandas e os espectrorradiômetros que se diferenciam quanto a sua resolução espectral. Resolução é a medida da habilidade que um sensor possui de distinguir respostas nos domínios espacial, espectral, temporal e radiométrico. A resolução espacial está associada a capacidade do sensor em diferenciar objetos na superfície terrestre em contraste com o plano de fundo. Quanto mais próximos estiverem os objetos, maior deverá ser a resolução espacial para que o sensor discrimine um do outro. Caso contrário se diz que o sensor tem baixa resolução espacial. A resolução espectral está relacionada à sensibilidade do sensor em distinguir um objeto por meio da análise espectral de sua reflectância. Assim, quanto mais numerosas e estreitas forem as bandas correspondentes às faixas do espectro eletromagnético que o sensor pode operar, maior será sua resolução espectral. A resolução temporal está associada ao menor intervalo de tempo de aquisição de duas imagens sucessivas de uma mesma área. Por fim, a resolução radiométrica está associada à eficiência do sensor em distinguir níveis intermediários de radiação incidente.

Os sensores de bandas geram informações provenientes da radiação eletromagnética emitida pelos alvos em faixas (ou bandas espectrais) largas do espectro eletromagnético, como por exemplo o Exotech, que opera em quatro faixas espectrais (0,5-0,6 µm; 0,6-0,7 µm; 0,7-0,8 µm e 0,8-1,1 µm) (NOVO, 1992; MOREIRA, 2005), o Thermopoint, que opera exclusivamente entre 8 e 14 µm (mede a temperatura de alvos), ou ainda o sensor quântico de linha LAI-2000 que mede a radiação fotossinteticamente ativa na banda de 400 a 700 nm (MOREIRA, 2005). Os valores de radiância de cada banda expressam valores médios de cada comprimento de onda contido na banda.

Por outro lado, os espectrorradiômetros possuem uma resolução espectral muito mais sensível. Eles operam em bandas mais estreitas do espectro eletromagnético, variando de 350 a 2500 nm. Sensores desse tipo possuem sistemas sensores que decompõem a radiação incidente em diferentes comprimentos de onda de maneira que se possa medir a resposta do alvo quase que de forma contínua ao longo do espectro eletromagnético (NOVO, 1992).

3.5.1.2 Sensores imageadores

Os sensores imageadores por sua vez, são capazes de converter e quantificar os sinais ópticos processados em valores numéricos discretos por pixel (RICHARDS, JIA, 2006; SCHOWENGERDT, 2007). A imagem, ou cena, gerada é formada por uma matriz de pixels. A posição de cada pixel na matriz é determinada pela forma cujo o escaneamento é realizado: perpendicular ao movimento da plataforma (*cross-track direction* ou *whiskbroom scanning*), ou no sentido do movimento da plataforma (*along-track direction* ou *push-broom scanning*) (SCHOWENGERDT, 2007).

Os avanços tecnológicos na área do sensoriamento remoto permitiram que os sensores pudessem cobrir áreas maiores com resoluções muito maiores. Os primeiros sensores utilizados no sensoriamento remoto foram do tipo óptico tais como câmeras fotográficas. Estas era instaladas na fuselagem de aviões, e dependiam do controle das condições de voo para que os registros fossem realizados com qualidade e precisão. Mesmo com o surgimento de sensores eletro-ópticos multiespectrais, ainda se dependia de plataformas não orbitais para a coleta de dados. O sensoriamento remoto alcançaria um novo patamar tecnológico com o surgimento dos primeiros satélites imageadores.

Os satélites LANDSAT foram as primeiras plataformas orbitais a coletarem informações acerca da radiação emitida ou refletida pela superfície terrestre, em 1972. Os primeiros sistemas de coleta de dados instalados nos LANDSAT 1 e 2 foram o RBV ou *Return Bean Vidicon* e o Imageador Multiespectral – MSS (*Multispectral Scanner Subsystem*). O primeiro consistia em um equipamento semelhante a uma câmera de televisão. Gerava cenas de baixa resolução espacial (185 por 170 km), compostas por três bandas espectrais, e permitia registros instantâneos do terreno. O MSS, por sua vez, foi o primeiro sensor dotado de um sistema escaneador eletro-óptico (espelho oscilante) perpendicular à órbita do satélite, capaz de cobrir uma faixa de 185 km do terreno (CAMPBELL, 1996). Gerava imagens compostas por uma banda verde (500-600nm), uma vermelha (600 a 700 nm) e duas infravermelhas (uma de 700 a 800 nm e outra de 800 a 1100 nm). Outros sensores como o *Thematic Mapper* – TM e o *Enhanced Thematic Mapper Plus* – ETM+ foram desenvolvidos e aprimorados a partir da mesma tecnologia do MSS e empregados nos satélites LANDSAT mais recentes. A série LANDSAT foi desenvolvida pelo governo norte-americano no intuito de empregar os princípios do

sensoriamento remoto no estudo dos recursos naturais do planeta. Ao todo foram lançados oito satélites: cinco fora de operação (1 a 5), um falhou ao entrar em órbita (6) e dois ativos (7 e 8) (Tabela 2). Atualmente, o satélite mais recente da série, o LANDSAT 8, é capaz de cobrir grande parte do espectro eletromagnético (do visível ao termal) por meio de dois sensores multiespectrais: o *Operational Land Imager* – OLI (nove bandas de 30 m de resolução espectral (a exceção da banda 8 pancromática de 15 m)), e o *Thermal Infrared Sensor* – TIRS (duas bandas termais de 100 m de resolução espacial). Orbita a terra a 705 km de altitude, com uma resolução temporal de 16 dias (USGS, 2014).

Tabela 2 – Principais sensores multiespectrais instalados por satélite LANDSAT.

(continuação)

		Bandas		Satélites
Sensor	RBV	1	Green - 475 a 575 nm	Landsat 1 e 2
		2	Red - 580 a 680 nm	
		3	NIR - 690 a 830 nm	
	MSS	4	Green - 500 a 600 nm	
		5	Red - 600 a 700 nm	
		6	NIR - 800 a 700 nm	
		7	NIR - 800 a 1100 nm	
	RBV	-	500 a 750 nm (resposta pancromática)	Landsat 3
	MSS	4	Green - 500 a 600 nm	
		5	Red - 600 a 700 nm	
		6	NIR - 800 a 700 nm	
		7	NIR - 800 a 1100 nm	
		8	NIR - 1040 a 1260 nm	
	TM	1	Blue-green - 450 a 520 nm	Landsat 4 e 5
		2	Green - 520 a 600 nm	
		3	Red - 630 a 690 nm	
		4	NIR - 760 a 900 nm	
		5	MIR - 1550 a 1750 nm	
		6	FIR - 10400 a 12500 nm	
		7	MIR - 2080 a 2350 nm	

Tabela 2 – Principais sensores multiespectrais instalados por satélite LANDSAT

(conclusão)

		Bandas		Satélites
Sensor	MSS	1	Green - 500 a 600 nm	Landsat 4 e 5
		2	Red - 600 a 700 nm	
		3	NIR - 800 a 700 nm	
		4	NIR - 800 a 1100 nm	
	ETM+	1	Blue - 450 a 520 nm	Landsat 7
		2	Green - 530 a 610 nm	
		3	Red - 630 a 690 nm	
		4	NIR - 760 a 900 nm	
		5	MIR - 1550 a 1750 nm	
		6	Thermal IR - 10400 a 12500 nm	
		7	MIR - 2080 a 2350 nm	
		8	PAN - 520 a 900 nm	
	OLI	1	Coastal aerosol - 430 a 450 nm	Landsat 8
		2	Blue - 450 a 510 nm	
		3	Green - 530 a 590 nm	
		4	Red - 640 a 670 nm	
		5	NIR - 850 a 880 nm	
		6	SWIR 1 - 1570 a 1650 nm	
		7	SWIR 2 - 2110 a 2290 nm	
		8	PAN - 500 a 680 nm	
		9	Cirrus - 1360 a 1380 nm	
	TIRS	10	TIRS 1 - 10600 a 11190 nm	
		11	TIRS 2 - 11500 a 12510 nm	
Resolução	RBV	80 m		
	MSS	60 m		
	TM	30 m		
	ETM+	15 a 30 m		
	OLI	15 a 30 m		
	TIRS	100 m		

Legenda: RBV - *Return Bean Vidicon*; MSS - *Multispectral Scanner Subsystem*; TM - *Thematic Mapper*; ETM+ - *Enhanced Thematic Mapper Plus*; OLI - *Operational Land Imager*; TIRS - *Thermal Infrared Sensor*; PAN - pancromático; NIR - *Near Infrared*; MIR - *Mid Infrared*; FIR - *Far Infrared*; SWIR - *Short Wave Infrarerd*.

Fonte: Adaptado de United States Geological Survey (2014)

Ao longo do tempo, o nível de detalhamento exigido em estudos de sensoriamento remoto provocou a necessidade de se desenvolver sensores mais sensíveis ao espectro eletromagnético. O aumento no número de bandas analisadas permitiu um volume maior e mais acurado de informações que cada pixel pode carregar, melhorando o entendimento dos objetos e da superfície terrestre. Nesse sentido, os sensores podem ser categorizados quanto ao número de bandas ou resolução espectral em que operam: os sensores multiespectrais e hiperespectrais.

3.5.2 Sensores multiespectrais

Sensores multiespectrais são aqueles que operam em múltiplas bandas do espectro eletromagnético, variando de 300 a 14000 nm. São exemplos dessa

categoria o MSS, TM, ETM+, OLI e TIRS, todos sensores do programa LANDSAT visto anteriormente. Existem, porém, diversos outros sensores empregados nos mais diversos estudos da superfície terrestre e da atmosfera, tais como: HRV, HRVIR, HRG, HRS, VEGETATION e VEGETATION-2 da série de satélites do programa franco/europeu SPOT (*Satellite pour l'Observation de la Terre*); AVHRR e AVHRR/3 dos satélites norte-americanos NOAA (*National Oceanic and Atmospheric Administration*); ATSR-1 e 2, MS e GOME da série ERS (*European Remote Sensing*) da Agência Espacial Européia; SAR do satélite RADARSAT-1 (Agência Espacial Canadense); CÂMARA CCD, IRMSS e WFI dos satélites CBERS 1 e 2 do programa CBERS (*China-Brazil Earth Resources Satellite*); ASTER e MODIS do satélite TERRA do programa EOS (*Earth Observing System*) da Agência Espacial Norte-americana (NASA); QUICKBIRD do satélite norte-americano QUICKBIRD-2 e os sensores multiespectrais e pancromáticos instalados nos satélites norte-americanos IKONOS, GEO-EYE-1 e WORLDVIEW 1, 2 e 3.

Os sensores dos satélites da série WorldView são um dos mais avançados tecnologicamente na atualidade. O satélite mais recente da série, o WorldView-3, é o primeiro satélite comercial da classe de satélites superespectrais de altíssima resolução espacial. Ele traz consigo, além de sensores pancromáticos e multiespectrais presentes nos satélites anteriores, dois novos sensores: o *Short Wave Infrarerd* – SWIR e o *Clouds, Aerosols, Vapors, Ice, and Snow* – CAVIS, empregados em estudos ambientais e atmosféricos. O SWIR é capaz de diferenciar materiais por meio da assinatura espectral de sua composição química e física (SATELLITE IMAGING CORPORATION, 2015).

Muito embora os sensores multiespectrais vêm sendo aperfeiçoados a fim de poderem captar a maior quantidade possível de informação por banda, sua resolução espectral não se compara a obtida por sensores hiperespectrais.

3.5.3 Sensores hiperespectrais

Sensores hiperespectrais, ou também conhecidos como espectrômetros imageadores, se diferenciam dos sensores multiespectrais por gerarem imagens compostas por centenas de bandas estreitas do espectro – de até 10 nm de largura, variando da região do visível à do termal (CAMPBELL, 1996; JENSEN, 2000; LILLESAND et al., 2004). Espectrometros imageadores aplicam os princípios da espectroscopia. Eles coletam a radiação emitida pelos alvos e a decompõem em

faixas espectrais mensuráveis eletronicamente. Devido a capacidade de operar em um trecho tão amplo do espectro de maneira tão detalhada, equipamentos desse tipo geram curvas espectrais quase contínuas do alvo.

Esta propriedade proporciona a essa classe de sensores distinguir materiais na superfície terrestre por meio das assinaturas espectrais dos compostos químicos dos quais são feitos (CAMPBELL, 1996; LILLESAND et al., 2004). Empresas do ramo mineral se utilizam de imagens hiperespectrais para identificar depósitos e/ou jazidas de minérios de valor econômico.

Existem diferentes plataformas em que sensores hiperespectrais podem ser instalados. Os primeiros foram desenvolvidos para utilização laboratorial, captando informações de modo muito pontual. Estes sensores são portáteis, podendo ser utilizados em estudos de campo, por exemplo. Plataformas orbitais e sub-orbitais permitem o imageamento de áreas maiores do terreno.

Veículos sub-orbitais são as plataformas mais comumente utilizadas para obtenção de imagens hiperespectrais, tais como aviões e helicópteros. Atualmente no mercado, há uma imensa variedade de sensores e módulos empregados comercialmente e em pesquisas científicas. Os de maior relevância estão reunidos na tabela 3.

Tabela 3 – Principais sensores hiperespectrais sub-orbitais em operação comercial.

Plataforma	Sensor	Número de Bandas	Alcance espectral (nm)
Sub-orbital	AAHIS	288	432 a 832
	AIS-1	128	900 a 2400
	AIS-2	128	800 a 2400
	AISA	286	450 a 900
	AMSS	46	500 a 12000
	ARES	75	2000 a 6500
	ASAS	62	400 a 1060
	ASTER Simulator	24	760 a 12000
	AVIRIS	224	400 a 2450
	CAMODIS	91	400 a 12500
	CASI	288	430 a 870
	CHRISS	40	430 a 860
	DAIS 3715	37	400 a 12000
	DAIS 7915	79	400 a 12000
	DAIS 16115	160	400 a 12000
	GER-63	63	400 a 12500
	HYDICE	206	400 a 2500
	ISM	128	800 a 3200
	MAS	50	544 a 1452144
	MEIS	>200	350 a 900
	MISI	60	400 a 1000
	MIVIS	102	433 a 12733

Os primeiros sensores hiperespectrais aerotransportados foram o *Airborne Imaging Spectrometer* AIS, que operava entre 700 e 2500 nm, oferecendo 128 bandas, o *Flourescence Line Imager* FLI e o *Advanced Solid State Array Spectrometer* ASAS, que operavam entre 400 e 1000 nm (JENSEN, 2000; MOREIRA, 2005). No entanto, o sensor que foi mais amplamente utilizado em estudos da superfície e atmosfera terrestre, e que ainda está em operação é o *Airborne Visible Infrared Imaging Spectrometer* – AVIRIS. O AVIRIS foi desenvolvido pelo *Jet Propulsion Laboratory* – JPL da NASA, em 1983. Ele possui um alcance espectral de 2050 nm (operando entre 400 e 2450 nm), oferencendo 224 bandas de 10 nm de largura. O sistema realiza sobrevoos regulares, marcados por meio de solicitação de imageamento.

A evolução na obtenção de imagens hiperepectrais parece estar no uso de Veículos Aéreos Não Tripulados (VANTs) e DRONES. Estes veículos modernos se destacam pela versatilidade, praticidade e custo, mantendo a mesma capacidade de imageamento e armazenamento de dados das aeronaves convencionais.

As plataformas orbitais, por sua vez, permitem que faixas maiores do território sejam imageadas, contribuindo para estudos climáticos e ambientais. Os principais sensores e seus respectivos satélites estão reunidos na tabela 4.

Tabela 4 – Principais sensores hiperespectrais orbitais em operação.

Plataforma	Sensor	Satélite	Número de Bandas	Alcance Espectral (nm)	Resolução (m)	Status
Orbital	CHRIS	PROBA	63	415 a 1050	18 a 36	ativo
	FTHSI	MightySat-2.1	146	475 a 1050	30	inativo
	Hyperion	EO-1	220	400 a 2500	30	ativo
	MODIS	TERRA; AQUA	36	405 a 14385	250, 500 e 1000	ativo

Embora a Tabela 4 indique três sensores hiperespectrais orbitais ativos, somente o Hyperion do satélite EO-1 fornece imagens hiperespectrais em uma ampla faixa do espectro (220 bandas). Os outros dois satélites possuem aplicação especifica na análise da superfície terrestre, dos teores de vapor d'água, gases e da composição da atmosfera; é por esse motivo que operam em poucas bandas espectrais.

3.5.4 Aplicações de imagens hiperespectrais

3.5.4.1 Uso Florestal

O emprego de imagens hiperespectrais em estudos florestais vem crescendo ao passo em que aumenta a exigência de um detalhamento maior da estrutura das florestas, a fim de que o manejo destas seja cada vez mais eficiente. A alta resolução espectral de imagens dessa natureza permite a diferenciação e identificação de características dos vegetais, levando a um diagnóstico mais preciso da composição e condições sanitárias da floresta.

Nesse contexto, diversos autores descrevem a aplicação de imagens hiperespectrais em inventários (LEFSKY et al., 2001), para a obtenção de diversos parâmetros biofísicos das florestas (TREITZ, HOWARTH, 1999; BEGUET et al., 2014), na mensuração do estresse provocado pela seca na produtividade primaria da floresta Amazônica (ASNER et al., 2004), na detecção e mensuração da temperatura do fogo em incêndios florestais (MATHESON, DENNISON, 2012) e na identificação de espécies invasoras em plantios comerciais (PEERBHAY et al., 2015).

Dois dos parâmetros florestais mais importantes em estudos de ecologia e de manejo florestal são o padrão de distribuição e a identificação das espécies de uma determinada área. O valor dessa informação reflete na otimização de tempo e recursos na tomada de decisões. O alcance espectral das imagens hiperespectrais possibilita a geração de curvas características das assinaturas espectrais de cada

espécie, viabilizando a diferenciação de uma espécie da outra, como verificado por Pearlman et al. (2003), Erickson (2004), Buddenbaum et al. (2005), Clarck et al. (2005), Aardt e Wynne (2007), Alonzo et al. (2014) e Fassnacht et al. (2014).

Outro parâmetro amplamente estudado é o tamanho e distribuição das copas das árvores. Dependendo da distribuição dos indivíduos e do tipo de floresta, o fechamento do estrato superior determinará o desenvolvimento dos indivíduos dominados e influenciará na área basal do talhão, por exemplo. O reflexo prático da análise da cobertura florestal é a estimativa do desenvolvimento da floresta, indicando momentos ideais para desbastes. O uso de imagens de altíssima resolução espectral, aliado a técnicas de segmentação e classificação multi-resolução (baseada em contexto, i.e., relação dos objetos entre si) (MOLENAAR, 1998), para definir e extrair as copas das árvores, tem mostrado resultados satisfatórios tanto para florestas nativas, quanto para plantadas (SONG; WOODCOCK, 2003; LAMONACA et al., 2008; KE; QUACKENBUSH, 2011; OZDEMIR; KARNIELI, 2011; DALPONTE et al., 2014; CHO et al., 2015).

Diversos autores descrevem resultados promissores do uso conjunto de imagens hiperespectrais com dados de sensores ativos como o LiDAR, por exemplo. Sensores desse tipo são conhecidos por fornecerem informações bastante acurados acerca do perfil do alvo. Isso se deve pelo fato da tecnologia LiDAR gerar uma representação em três dimensões do objeto, que nas florestas, facilita a visualização da distribuição das árvores e da densidade dos estratos, assim como a mensuração remota dos parâmetros biofísicos. Autores como Dalponte et al. (2008), Jones et al. (2010) e Dalponte et al. (2012) avaliaram o uso do LiDAR e das imagens hiperespectrais para a identificação de espécies em florestas nativas, enquanto que Antonarakis et al. (2008), Chen et al. (2009), Rahman e Gorte (2009), Arroyo et al. (2010), Zhou et al. (2010), Barbier et al. (2011), Cho et al. (2012), Dupuy et al. (2013), Ozdemir e Donoghue (2013), Hu et al. (2014) e Räsänen et al. (2014), descrevem resultados satisfatórios na definição de copas.

3.5.4.2 Uso urbano

A característica heterogênea natural do ambiente urbano exige recursos que possibilitem a distinção entre os mais diversos componentes da paisagem urbana de maneira confiável. É por esse motivo que as imagens hiperespectrais são frequentemente utilizadas em estudos sobre a dinâmica e evolução nos padrões de

uso e ocupação de solo urbano. A exemplo disso, Ardila et al. (2011, 2012b), Jensen et al. (2012), Pu e Landry (2012), Sebari e He (2013), Hamedianfar et al. (2014) e Lu et al. (2014) aplicaram procedimentos de classificação em imagens hiperespectrais de áreas urbanas, a fim de extrair as diferentes feições e analisar os padrões de uso e ocupação de solo.

Sob o ponto de vista das florestas urbanas, as imagens hiperespectrais podem ser utilizadas para a extração dos mesmos parâmetros biométricos vistos no item 3.5.4.1. Na posse desses dados, a autoridade responsável pela arborização pode, com mais precisão, avaliar os benefícios que as arvores trazem ao ambiente urbano e planejar, de maneira mais direcionada, intervenções em áreas com menos árvores. Exemplos de aplicações de imagens de altíssima resolução espectral aliada a outras fontes de informações, como o LiDAR, podem ser vistos nos trabalhos de Ardila et al. (2012a), Im et al. (2012), Zhang e Qiu (2012a) e Alonzo et al. (2014).

3.6 Classificação de imagens

A heterogeneidade na distribuição das feições da superfície terrestre é uma importante característica descritiva do ambiente. Os padrões espaciais, espectrais e temporais dessas feições podem ser quantificados e avaliados para formar um diagnóstico das mudanças sofridas pelo ambiente ao longo do tempo. No entanto é preciso, primeiramente, reconhecer, extrair e categorizar as feições da imagem por meio de métodos de classificação (SCHOWENGERDT, 2007).

A classificação de imagens é considerada uma das etapas mais importantes do sensoriamento remoto. Nela, cada pixel é associado à um tema, ou classe de uso e ocupação do solo da superfície, por meio da transformação dos dados numéricos que cada um carrega, em classes descritivas. O produto dessa transformação se assemelha a um mapa temático que pode servir de ferramenta para tomadas de decisão no manejo florestal, por exemplo.

Os fatores encontrados na imagem que nos faz distinguir um objeto de outro, tais como cor, sombra, topografia etc, são registrados na imagem digital como variações de brilho (associado às respostas espectrais do material de que o alvo é feito). Os pixels que compartilham brilho uniforme são agrupados em classes espectrais. O analista que conseguir seguramente associar as classes espectrais às feições da imagem, gerará uma imagem com informações confiáveis sobre o alvo;

caso contrário, a imagem formada não seria considerada uma boa fonte de informações (CAMPBELL, 1996).

De acordo com a necessidade, as classes espectrais podem ser subdivididas para formar subclasses de feições como, por exemplo, os tipos de árvores em uma floresta mista de coníferas e folhosas. O nível do detalhamento dependerá da qualidade espectral e espacial da imagem, assim como a capacidade do analista em interpretar as feições.

O analista, por sua vez, não precisa necessariamente conhecer as feições da imagem para executar um método de classificação. Por esse motivo a classificação de imagens digitais foi dividida em não supervisionada e supervisionada – há autores que preferem os termos *bottom-up* e *top-down* que, todavia, baseiam-se no mesmo princípio: cabe somente ao analista definir as relações semânticas dos objetos, i.e., sua importância ou significância dentro do contexto da classificação. Ambos pares de termos referem-se ao modo com que a hierarquia dos objetos da imagem é definida, criando, dessa forma, uma ordem ou sentido da sequência dos processos da classificação (GONZALES; WOODS, 2002; BLASCHKE, 2010; MENESES; ALMEIDA, 2012).

A diferença básica entre a classificação não supervisionada e supervisionada é o grau de interferência do analista no processo. No primeiro caso, o analista não precisa ter conhecimento prévio das feições presentes na imagem, cabendo ao algoritmo identificar e categorizar automaticamente as feições. Já no segundo caso, o analista deve conhecer as feições e cabe a ele treinar o programa para que as identifique e automaticamente as classifique. Uma descrição mais detalhada de ambos métodos vem a seguir:

3.6.1 Classificação não supervisionada

Como dito anteriormente, a classificação não supervisionada não pressupõe que o usuário tenha um conhecimento prévio da área imageada, nem que conheça as propriedades estatísticas e espectrais da imagem que se está trabalhando. A interferência no processo de classificação é muito baixa, cabendo ao pesquisador designar parâmetros básicos para que o algoritmo classificador identifique as feições de interesse e possa classificá-las. Devido ao fato de não se conhecer o número de classes que serão criadas pelo programa, a técnica da classificação não supervisionada é amplamente utilizada em caráter exploratório da imagem,

buscando identificar a quantidade máxima possível de classes para que, por fim, possa refinar o processo com somente classes de interesse.

Os algoritmos utilizados nessas ferramentas, tais como o ISODATA (ou *Iterative Self-Organizing Data Analysis Technique* em inglês) e K-médias, baseiam-se no mesmo princípio: buscam, entre todos os pixels da imagem, padrões espectrais semelhantes, reunindo-os em agrupamentos ou *clusters*. Estes *clusters* podem ser reagrupados em segmentos maiores para que o produto final seja a imagem classificada.

Os parâmetros estatísticos avaliados pelos algoritmos para a geração dos agrupamentos baseiam-se nas matrizes de covariância e nas medidas de similaridade, que no caso podem sem distância mínima entre pixels ou distância de Mahalanobis. Normalmente o processo de classificação não supervisionada é dividido em quatro etapas: pré-agrupamento; agrupamento; reagrupamento e iterações. Na primeira, o usuário define o limiar de aceitação. O limiar de aceitação indica a distância (mínima ou Mahalanobis) limite entre clusters que o programa os pode agrupar em uma mesma classe. Assim, clusters que forem distantes entre si em valores superiores ao limiar serão agrupados em classes distintas. Na segunda etapa o algoritmo percorre a imagem, analisando as matrizes de covariância espectral dos pixels, gerando os clusters de acordo com o limiar preestabelecido. Na terceira etapa o processo é repetido até que todos os pixels estejam associados a uma classe. E por fim, na quarta etapa, o produto final ou a imagem classificada é gerada.

3.6.2 Classificação supervisionada

A classificação supervisionada, por sua vez, se difere da não supervisionada por assumir que o analista conhece as feições da imagem em estudo e, por conseguinte, exige maior grau de interferência deste na definição dos parâmetros básicos para a execução da classificação. Dessa forma, o programa precisa ser “treinado” para que reconheça as feições e as corretamente classifique de acordo com as classes definidas pelo analista. Para tanto é preciso, antes, dividir a imagem em segmentos que facilitam o processo de classificação.

3.6.2.1 Segmentação

A segmentação é o processo de divisão da imagem em parcelas menores cujos pixels compartilham entre si características espectrais semelhantes. Esta etapa é indispensável na classificação de imagens multiespectrais, para a extração de informações, identificação de objetos e alocação das amostras de treinamento e teste. Existem programas cujos algoritmos realizam automaticamente a segmentação e a classificação. No entanto é possível ser feita separadamente da classificação.

A característica intrínseca da imagem, analisada pelo programa para segmentar e classificar os pixels é a homogeneidade de resolução espectral. Os parâmetros que compõem a homogeneidade e que podem ser alterados pelo analista – por meio da atribuição de pesos, a fim de melhorar a segmentação e por consequência a classificação final, são: cor – associada à heterogeneidade espectral; e forma, associada à heterogeneidade espacial. Ainda, é possível alterar o critério semelhança que controla a uniformidade do segmento de pixels. A heterogeneidade espectral é definida por:

$$H_e = \Sigma \omega_c \sigma_c \qquad \text{Eq. 7}$$

, onde ω_c são os pesos e σ_c os desvios padrão dos valores de reflectância de cada pixel. Já a heterogeneidade espacial é definhada por:

$$H_f = {}^{L}/_{\sqrt{n}} \qquad \text{Eq. 8}$$

, onde L é o comprimento linear da borda do objeto e n é o número de pixels que compõem o objeto. A atribuição de pesos no processo de classificação depende da natureza e qualidade da imagem. Em imagens muito texturizadas, por exemplo, que naturalmente possuem um alto grau de heterogeneidade espectral, precisam receber pesos altos para que sejam criados segmentos maiores e mais homogêneos, facilitando a identificação das feições, alocação de amostras e a classificação final. Isto se deve, pois a He é inversamente proporcional à fragmentação da imagem, i.e., quanto menor os valores de He, mais abundantes e menores serão os segmentos

definidos para a imagem Dependendo do objetivo de estudo, este resultado é indesejado por dificultar a definição de classes.

3.6.2.2 Classificação

A classificação de imagens é a etapa final do processo iniciado pela segmentação, cujo objetivo é a obtenção de informações sobre os objetos contidos na imagem. Assim como na etapa anterior, a classificação pode ser realizada por mais de uma maneira em que o grau de influência do operador no processo é a principal diferença.

A classificação não supervisionada é executada quando o operador não tem influência direta na definição dos parâmetros da classificação. Nela o algoritmo utilizado percorre a imagem em busca de pixels de características espectrais semelhantes, agrupando-os em classes. Assim, cabe ao operador somente a função de identificar as classes.

Por outro lado, a classificação supervisionada depende da interferência do operador para ser executada. É preciso que se conheçam previamente os objetos da imagem para que sejam definidas as classes de interesse. Nessa etapa são lançadas amostras de treinamento e teste que tem como função primordial indicar ao programa a relação do padrão dos pixels nas amostras com a classe que se quer agrupá-los. Dessa forma, todos os pixels da imagem que contiverem o mesmo padrão dos pixels das amostras serão agrupados em uma mesma classe.

O propósito do lançamento de amostras de treinamento e teste está na necessidade de mostrar ao programa os padrões espectrais que cada classe deve conter. Quanto mais numerosas e homogêneas as amostras forem, mais chance de o programa corretamente classificar os pixels da imagem. A forma de avaliação do procedimento ocorre por meio da geração e análise de uma matriz de confusão ou erro. A matriz de confusão carrega as relações de acerto na classificação dos demais pixels da imagem em relação àqueles definidos nas amostras. A matriz expõe, também, a exatidão global do processo, que é a razão da quantidade total de pixels corretamente classificados pelo total de pixels da imagem. Com esse valor, expresso em porcentagem, é possível aferir o desempenho do classificador. Outra forma de avaliação do desempenho do classificador é a análise do índice Kappa, que será melhor abordado mais adiante nos resultados e discussão do trabalho.

3.7 Tecnologia LiDAR

O LiDAR, assim como o RADAR, é um instrumento de sensoriamento remoto ativo, i.e., emite radiação própria para colher dados dos alvos. Ele é empregado na geração de perfis em três dimensões dos alvos (Figura 5), por meio da mensuração da emissão e recepção de pulsos discretos de luz, ou laser. O termo laser (*Light Amplification by Stimulated Emission of Radiation*), que pode ser traduzido como Amplificação da Luz por Emissão Estimulada de Radiação, designa todo o equipamento que estimula um determinado material a gerar feixes de luz de características bastante particulares como. As propriedades do laser são: a coerência – os feixes de luz mantêm uma relação de fase fixa, não interferindo entr si; a monocromia: os feixes de luz possuem um único comprimento de onda; e o pequeno ângulo de divergência, onde o feixe se espalha pouco mesmo a grandes distancias (SERWAY; JEWETT Jr., 2015). Os lasers são classificados de acordo com seu comprimento de onda no vácuo. Aqueles utilizados pelo sistema LiDAR emitem feixes de 1040 nm de comprimento de onda no infravermelho próximo (LILLESAND et al., 2004).

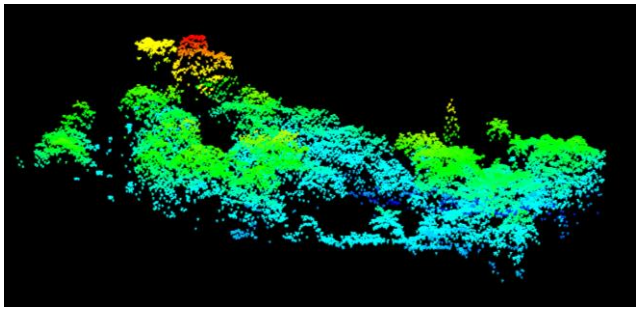

Figura 5 – Exemplo de uma nuvem de pontos LiDAR do parque municipal Américo Renné Giannetti, em Belo Horizonte, MG.

O sensor LiDAR é composto por um conjunto de quatro equipamentos: 1) unidade escaneadora emissora-receptora de laser; 2) unidade de posicionamento global (GPS) instalado na aeronave e no chão; 3) uma unidade medidora inerte altamente sensível (IMU), utilizado para medir os ângulos do movimento da aeronave (arfagem – eixo lateral, guinada – eixo vertical, e rolamento – eixo longitudinal); e 4) sistema computacional que armazena os dados obtidos nas três primeiras unidades (REUTEBUCH et al., 2005). O sistema pode emitir pulsos de laser discretos, i.e., não contínuos, a uma frequência de até 200.000 pontos por segundo (RODRIGUEZ et al., 2010), cobrindo uma área mínima da superfície (o

footprint do sensor). Ao interceptar um obstáculo, o feixe de luz emitido é refletido de volta ao sensor, sendo registrado como um ponto. Cada ponto possui três dimensões (x,y,z): uma dimensão espacial (x,y) determinada pelo funcionamento integrado do GPS com a unidade emissora-receptora de laser, e uma terceira dimensão (z) associada a um valor de elevação do alvo. Os valores de elevação são obtidos por meio da diferença entre o tempo de emissão e recepção do pulso. Estes valores podem ser convertidos em valores de altura (Figura 6). Instrumentos mais recentes são capazes de gerar elevações do terreno com uma acurácia entre 10 a 20 cm (NOAA, 2012).

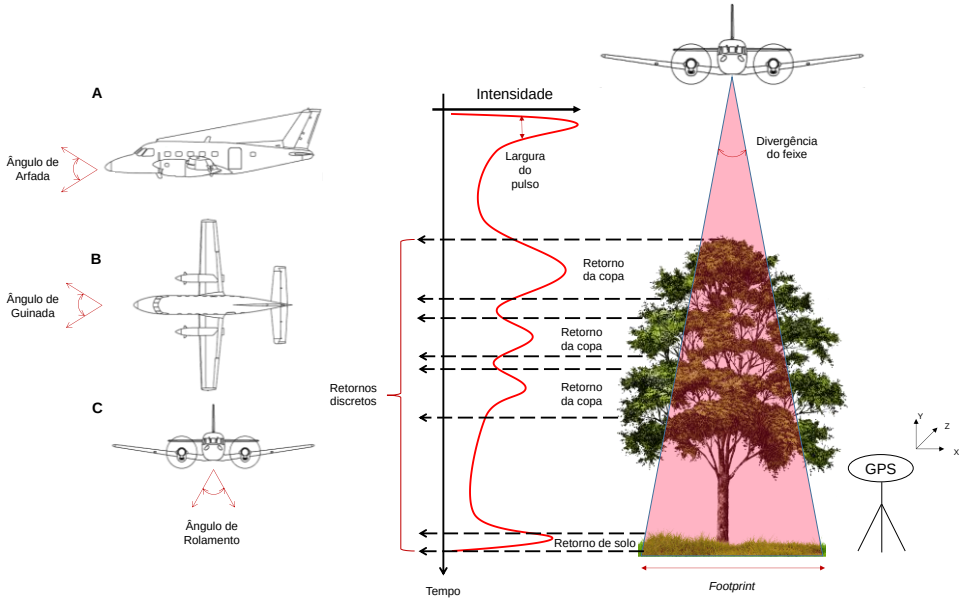

Figura 6 – Principais movimentos de rotação de uma aeronave medidos pelo IMU: A) ângulo de arfada, B) ângulo de guinada, e C) ângulo de rolamento (à esquerda). Esquema de aquisição de dados LiDAR por meio da emissão de feixes de laser interceptando um alvo (varredura) (à direita).

As plataformas mais utilizadas com sensores LiDAR são sub-orbitais, podendo, também, serem do tipo portátil (terrestre). Na área florestal, a realização de sobrevoos é o método mais empregado para a obtenção de dados LiDAR. O sensor é afixado voltado para baixo, na parte inferior da fuselagem da aeronave. Para que a varredura seja a mais precisa possível o IMU é calibrado, e são definidas a intensidade do pulso e o *footprint* previamente.

Desde sua conversão do uso militar para o civil, em meados da década de 1980, o LiDAR vem sendo amplamente utilizado na área da topografia por gerar um perfil ricamente detalhado da superfície. Estudos de vegetação com dados LiDAR

surgiram somente a partir da década de 1990. Antes os dados de vegetação eram descartados em parte pela dificuldade no manuseio e análise das informações causada pela limitação tecnológica da época, e por desinteresse da comunidade científica.

Desde então pesquisadores se utilizam do LiDAR para obter informações nos mais diversos campos das ciências florestais:

3.7.1 Manejo e inventário florestal

Em seu estudo Hudak et al. (2002) testaram cinco diferentes métodos de predição de altura de copa por meio da integração de imagens LANDSAT ETM+ e dados LiDAR de uma floresta experimental da Oregon State University, Estados Unidos. Os autores observaram que o uso integrado de técnicas de regressão e krigagem mostrou ser o melhor método de predição do tamanho de copa. Além do mais, as imagens LANDSAT ETM+ e LiDAR melhoraram a eficiência do mapeamento das árvores estudadas, podendo ser utilizados em outros estudos. Persson et al. (2002) buscaram validar o uso de dados LiDAR na detecção e medição de árvores individuais em uma área florestada no sul da Suécia, por meio da aplicação de um algoritmo e de medições de campo. Os autores obtiveram uma acurácia de 71% entre o campo e o detectado pelo LiDAR, corroborando seu uso na detecção de árvores individuais para a região do estudo.

Com o objetivo de testar o uso de LiDAR na obtenção de métricas florestais para melhorar atividades de inventário, Schardt et al. (2002) realizaram estudos em áreas montanhosas de floresta de coníferas na Áustria. Os resultados desses estudos indicam o potencial da tecnologia LiDAR em auxiliar trabalhos de inventário, porém, sem deixar de lado a necessidade de se realizar um levantamento de campo bem estruturado a fim de comparação e validação das informações. Em sua tese, Andersen (2003) desenvolveu uma metodologia baseada na aplicação de modelos estocásticos e em técnicas de análise de imagens, para relacionar padrões de distribuição de árvores geradas pelo LiDAR a métricas estruturais da floresta. O autor verificou que os dados LiDAR possibilitam a obtenção de métricas essenciais ao manejo florestal, podendo com sucesso ser empregado em outros estudos.

Straub (2003) apresenta, em seu estudo, um procedimento para extração automática de árvores por meio de métodos de segmentação de imagens derivadas da nuvem de pontos LiDAR e de cenas urbanas. Clarck et al. (2004) aplicaram um

LiDAR de *footprint* pequeno para gerar modelos digitais de terreno e estimar a altura do sub-bosque e das copas das árvores do estrato dominante em uma floresta ombrófila densa da La Selva Biological Station, na Costa Rica. Embora a vegetação tenha interferido na acurácia da superfície de elevação, o LiDAR de *footprint* pequeno mostrou ser uma ferramenta promissora em estudos com florestas tropicais.

A fim de detectar e estimar a altura de árvores individuais Kwak et al. (2007) usaram dados LiDAR de uma áreas florestada ao norte da Coréia do Sul, composta por espécies de coníferas e folhosas. Os autores não só conseguiram obter as métricas, como também apontam o uso do LiDAR na detecção de espécies diferentes, auxiliando em inventários florestais. Hyyppä et al. (2008) fazem uma revisão dos métodos de extração de métricas em florestas boreais por meio de LiDAR de *footprint* pequeno. Zawila-Niedzwiecki et al. (2008) aplicaram LiDAR terrestre e aerotransportado em áreas florestadas na Polônia, para avaliar o desempenho de ambas plataformas na aquisição de métricas florestais. Resultados indicaram que os dois sistemas puderam, satisfatoriamente, gerar perfis de solo e fornecer métricas da floresta estudada. Os autores van Leeuwen e Nieuwenhuis (2010) apresentam uma revisão das diferentes técnicas utilizadas para extrair métricas florestais por meio de LiDAR aerotransportado.

3.7.2 Quantificação de biomassa e de cobertura foliar das árvores

Em seu estudo, Drake et al. (2002) aplicam um LiDAR de *footprint* grande para estimar a biomassa acima do solo em trechos de floresta ombrófila densa da La Selva Biological Station, na Costa Rica. Os autores notaram alta correlação entre os dados LiDAR e as características estruturais da floresta estudada, inclusive a biomassa. Eles reforçam, ainda, que o LiDAR é uma ferramenta promissora para estudo de biomassa florestal. Zhao et al. (2009) buscaram desenvolver métodos para estimar a biomassa de uma floresta de coníferas e folhosas ao leste do estado norte-americano do Texas. Os autores constataram que o LiDAR demonstrou ser uma eficiente ferramenta remota para estimar e medir parâmetros florestais. O estudo de Estornell et al. (2011) foi estimar a biomassa de pequenos povoamentos de uma vegetação arbustiva típica da região mediterrânea da Espanha, por meio da aplicação de LiDAR aerotransportado. Os resultados indicam que para aquela

vegetação, o uso de LiDAR com densidades acima de oito pontos por metro quadrado mostrou ser uma boa ferramenta barra estimativa de biomassa.

Em um estudo conduzido em uma região florestada montanhosa no noroeste da China, Tian et al. (2009) avaliaram a possibilidade de extrair valores de biomassa vegetal por meio da comparação de dados obtidos por levantamento de campo, sensores passivos e ativos, como o LiDAR. Em seus resultados os autores mostram que conseguiram estimar a biomassa e que o LiDAR teve um bom desempenho frente aos outros sensores. Næsset et al. (2013) compararam duas técnicas de estimativa de biomassa em uma região de floresta ao sudeste da Noruega, tomando como base levantamentos de campo e dados LiDAR. Os resultados indicam que os levantamentos de campo feitos em parcelas delimitadas com auxílio dos dados LiDAR aumentaram substancialmente a precisão da estimativa de biomassa, quando comparado com o levantamento de campo tradicional, para florestas daquele país. Para avaliar o estoque de carbono de uma floresta montanhosa ao sul do Nepal, Karna et al. (2015) utilizaram imagens multiespectrais de alta resolução espacial WorldView-2 e dados LiDAR. Os autores verificaram que o uso conjunto de dados LiDAR e imagens WorldView-2 mostraram ser bastante promissores em estudos de estimativa de estoque de carbono para as florestas nepalesas.

3.7.3 Análise tridimensional do estrato florestal

Em seu estudo Brandtberg et al. (2003) desenvolveram uma técnica robusta para detecção e extração de árvores individuais, em uma floresta decídua da West Virginia University, nos Estados Unidos, utilizando dados LiDAR de alta densidade de amostragem e *footprint* pequeno. Os autores conseguiram com sucesso detectar e extrair árvores decíduas por meio da análise dos dados LiDAR e ainda sugerem seu uso para a identificação de espécies. Zimble et al. (2003), em seu estudo, investigam a possibilidade de aplicação do LiDAR na classificação dos atributos da estrutura vertical de uma floresta mista de coníferas e folhosas na região central do estado norte-americano do Idaho. Os resultados obtidos indicam que a tecnologia LiDAR utilizada pôde diferenciar diferentes estrados florestais e que poderia ser utilizado em estudos semelhantes em florestas mistas americanas.

A fim de definir uma técnica para delinear arvores individuais em florestas mistas e decíduas temperadas no sudoeste da Alemanha, Koch et al. (2006) utilizaram dados e imagens derivadas de sobrevoos LiDAR, e algoritmos de

segmentação de imagens. Os autores mostram que o emprego do LiDAR em inventários em pequenas áreas de florestas traz bons resultados, melhorando a aquisição de informações acerca da estrutura florestal. Os problemas encontrados foram referentes à subestimação do número de indivíduos em florestas decíduas densas, pela dificuldade do feixe laser atingir estratos inferiores da floresta. Zhao et al. (2011) buscaram explorar métodos para caracterizar a estrutura do extrato superior de talhões de diferentes idades de pinheiro, no leste do Texas, Estados Unidos, por meio de dados LiDAR. Os resultados indicam que o uso integrado dos modelos estatísticos escolhidos e os dados LiDAR superaram modelos tradicionais de classificação e de regressão linear. Corrobora-se, desse modo, o emprego do LiDAR em estudos da estrutura de florestas de pinheiros no estado do Texas.

4 MÉTODOS

4.1 Local de estudo

4.1.1 Belo Horizonte

Belo Horizonte é a capital do Estado de Minas Gerais. Está compreendida entre as coordenadas 19º49'01" sul e 43º57'21" oeste, a 852 m de altitude em relação ao nível do mar. O relevo acidentado que predomina a paisagem local faz parte do domínio geomorfológico do Complexo de Belo Horizonte – parte da unidade geomorfológica da Depressão de Belo Horizonte, cuja característica maior é a diversidade litológica e o relevo acidentado. A cidade é delimitada por diversas serras (ramificações da Serra do Espinhaço), cujo pinto culminante se localiza ao sul na Serra do Curral, atingindo 1538 m de altitude.

De acordo com Nimer (1979), Belo Horizonte está compreendida na transição dos climas Aw (tropical com estação seca) e Cwa (subtropical úmido), de acordo com a classificação de Köppen, registrando temperaturas médias anuais de 21°C e pluviosidade média anual de 1400 mm.

A vegetação da capital mineira não pode ser definida com exatidão pois a cidade está localizada em uma região de transição entre os biomas Mata Atlântica e Cerrado, havendo a presença de indivíduos de ambos os biomas. Há ainda traços de Campos Rupestres e de Altitude[1] ocorrendo na serra do Curral. Segundo o Manual Técnico da Vegetação Brasileira (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2012), os Campos de Altitude são considerados refúgios ecológicos. Refúgios ecológicos são regiões condicionadas à parâmetros ambientais específicos que promovem o surgimento de uma vegetação diferenciada (vegetação relíquia) com espécies endêmicas que, em geral, apresenta alta sensibilidade a intervenções antrópicas. Este é o caso dos Campos de Altitude que se constituem por uma vegetação gramíneo-lenhosa de altitudes acima de 1800 m.

4.1.2 Parque Municipal Américo Renné Giannetti

A área de estudo é o Parque Municipal Américo Renné Giannetti, localizado na região central da cidade de Belo Horizonte, MG (Figura 7).

---

[1] PARQUE da Serra do Curral. Disponível em: <http://www.parqueserradocurral.com.br/>. Acesso em: 03 set. 2014.

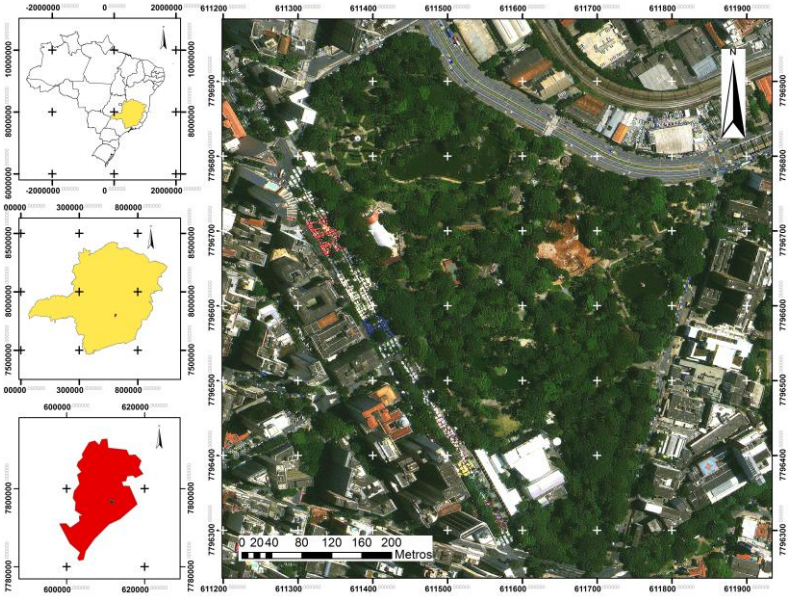

Figura 7 – Área de estudo: Parque Municipal Américo Renné Giannetti, cidade de Belo Horizonte, Minas Gerais, Brasil. Fonte: Arquivo pessoal.

Desde sua concepção o parque municipal Américo Renné Giannetti está estritamente ligado com o crescimento e desenvolvimento da capital mineira. A concepção do projeto inicial data de meados da década de 1890, quando, por decreto estadual, transferiu-se a capital do Estado de Minas Gerais de Ouro Preto para Belo Horizonte (antigamente denominada Curral del Rei). A mudança foi devido a limitação espacial para a expansão urbana que Ouro Preto apresentava, e que em Belo Horizonte não parecia ser problema. A nova capital foi uma das primeiras cidade planejadas do país, fruto do engenheiro Aarão Reis (Figura 8).

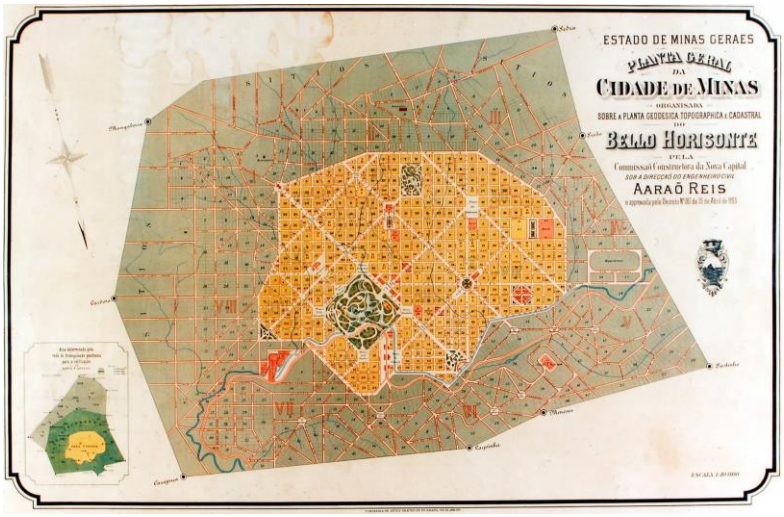

Figura 8 – Plano urbano desenhado por Aarão Reis para Belo Horizonte, em 1895. O parque municipal Américo Renné Gianetti aparece na região central do mapa, ainda com sua configuração e desenho originais. Imagem de domínio público.

O parque municipal foi implantado na antiga chácara do Sapo, que era propriedade de Aarão Reis, às margens do córrego Acaba-Mundo. O arquiteto e jardineiro francês Jean Villon foi contratado para desenhar um parque que refletisse a modernidade que a Belo Horizonte do princípio do século XX buscava expor. O arquiteto estabeleceu um desenho romântico vanguardista, inspirado nos parques ingleses, a fim de quebrar a geometria baseada em ângulos retos e de 45º do plano urbano da nova capital.

Inaugurado em 26 de setembro de 1897, três meses antes da inauguração da nova cidade, o então parque municipal se tornaria referência de lazer para os belo-horizontinos nos anos seguintes. Porém, ao longo das décadas, diversas intervenções públicas alteraram as características originais do parque, reduzindo sua área original de aproximadamente 560 mil m² para os atuais 180 mil m² (Figura 9).

Figura 9 – Configuração atual do parque municipal Américo Renné Giannetti. Ao longo das décadas parte do parque foi cedido para a construção do complexo de saúde, para a construção do campo do América Futebol Clube – AFC, e para zoneamento urbano.

A partir dos anos 1960 o parque iniciaria seu período de decadência devido, principalmente, à ausência de grades perimetrais e pelos contínuos atrasos na estrega do Palácio das Artes (complexo cultural instalado dentro do parque), o que atraiu batedores de carteira e outros pequenos crimes, distanciando o lugar dos

belo-horizontinos. Porém, durante as décadas de 1970 e 1980, o parque serviu de palco para movimentos culturais de vanguarda na capital mineira, e a partir dos anos 1990 começaram a ser implementados projetos que efetivamente devolviam o parque a população[2]. Áreas comuns foram reformadas e a vegetação foi manejada para proporcionar um ambiente melhor iluminado aos usuários. Desde então diversas iniciativas vêm sendo tomadas para requalificar o Américo Renné Giannetti.

Atualmente o parque conta com três lagos, coretos, quadras poliesportiva, áreas de recreação e para prática de exercícios físicos, além do Palácio das Artes, do Teatro Chico Nunes e um espaço cultural multiuso (ainda em obras).

4.2 Base de Dados

4.2.1 Levantamento de campo

Um levantamento de campo realizado no mesmo ano do aerolevantamento serviu de base para a identificação das espécies do parque. Uma planta do parque e uma lista das espécies identificadas foram fornecidas pela Fundação de Parques Municipais da Prefeitura de Belo Horizonte, em conjunto com a nuvem LiDAR. Os pontos referentes a cada indivíduo foram georreferenciados e somente aqueles classificados como de hábito arbóreo, em concordância com o Manual Técnico da Vegetação Brasileira (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2012), foram selecionados. A partir destes pontos, uma lista contendo os números de identificação, nome popular, nome científico (conforme APG III), quantidade, tipo – dividido entre “Palmeira” e “Árvore” – origem (exótico ou nativo) e país/região de origem foi criada para servir como referência ao processo de classificação (Anexo A).

A tabela foi convertida para o formato .CSV que permite a edição em ambiente SIG. Cada ponto correspondente ao indivíduo contêm as informações descritas acima (Figura 10). Por fim, a tabela foi convertida pra o formato *shapefile*, que facilita o manuseio e o armazenamento dos dados.

---

[2] COMPANHIA VALE DO RIO DOCE. **Parque municipal:** crônica de um século. Belo Horizonte, 1992.

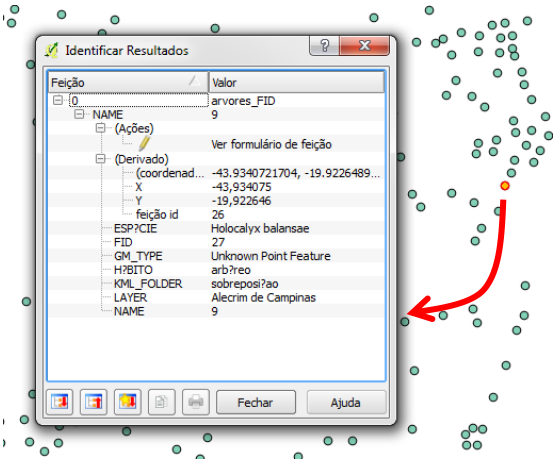

Figura 10 – Informações referentes a cada árvore (pontos georreferenciados) do levantamento de campo: Localização geográfica, espécie, número de identificação exclusivo (FID), hábito e nome popular.

Foram selecionadas as seis espécies arbóreas mais frequentes no parque para utilização na classificação supervisionada: *Spathodea campanulata* P. Beauv.; *Ficus benjamina* L.; *Syzygium cumini* (L.) Skeels; *Ceiba speciosa* (A. St.-Hil.) Ravenna; *Handroanthus impetiginosus* (Mart. ex DC.) Mattos; e *Eucalyptus sp.* (Figura 11). A lista completa da frequência das espécies pode ser encontrada nos anexos (Anexo B). Como o levantamento de campo não possui informação sobre as dimensões da copa de cada indivíduo, foram determinadas copas de cinco metros de raio, baseado em uma análise de vizinhança dos pontos. Estas copas são representadas por áreas de influência (*buffers*), assumindo que cada ponto se refere à posição central da árvore. Estes *buffers* foram utilizados para auxiliar o lançamento de amostras de treinamento e teste no processo de classificação supervisionada.

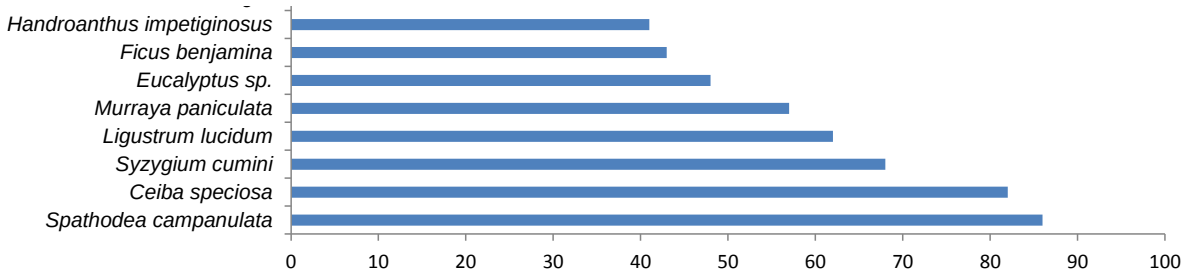

Figura 11 – Seis espécies arbóreas mais frequentes no Parque Municipal Américo Renné Giannetti: *Spathodea campanulata* P. Beauv.; *Ficus benjamina* L.; *Syzygium cumini* (L.) Skeels; *Ceiba speciosa* (A. St.-Hil.) Ravenna; *Handroanthus impetiginosus* (Mart. ex DC.) Mattos; e *Eucalyptus sp.* As espécies *Murraya paniculata* e *Ligustrum lucidum* não foram utilizadas por pertencerem a um estrato intermediário, que não se sobressai na imagem WorldView-2.

4.2.2 Imagem multispectral

A imagem multiespectral utilizada é uma WorldView-2 (WV2) pancromática com oito bandas fusionadas, datada de 23 de fevereiro de 2014. Imagens desse satélite são empregadas em trabalhos que exigem alto grau de detalhamento devido a sua alta resolução espacial – pixels de 0,5 X 0,5m, e seu grande alcance espectral (Figura 12).

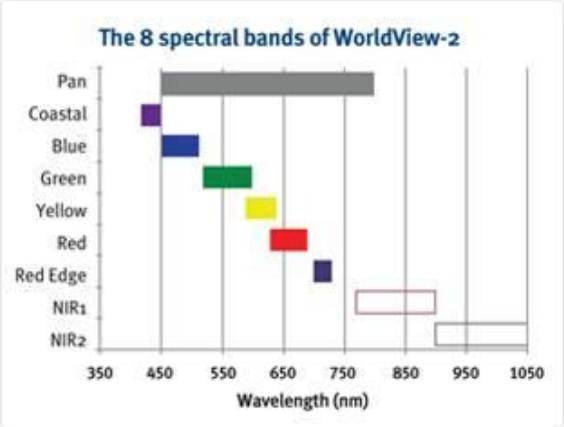

Figura 12 – Gráfico de alcance dos comprimento de onda de cada banda da imagem WorldView - 2. **Satellite Sensor**. 2013. Disponível em: <http://www.spot-7.com/satellite-sensors/worldview-2.html>. Acesso em: 01 abr. 2015.

A série WorldView conta com três satélites dotado de sensores multiespectrais operando entre 400 e 2365 nm, com resoluções espaciais de 30 m até 0,46 m em alguns casos (Tabela 5).

Tabela 5 – Especificações técnicas dos satélites da série WorldView: Órbita, sensores e resolução espacial.

Satélite		**WorldView-1**	**WorldView-2**	**WorldView-3**
Lançamento		18/09/2007	08/10/2008	13/08/2014
Órbita		Altitude: 496 km Tipo: heliossíncrona Período: 95 min.	Altitude: 770 km Tipo: heliossíncrona Período: 100 min.	Altitude: 617 km Tipo: heliossíncrona Período: 97 min.
Sensor	Pancromático	400 a 900 nm	450 a 800 nm	450 a 800 nm
	Multiespectral	-	Coastal - 400 a 450 nm Blue - 450 a 510 nm Green - 510 a 580 nm Yellow - 585 a 625 nm Red - 630 a 690 nm Red Edge - 705 a 745 nm Near-IR 1 - 770 a 895 nm Near-IR 2 - 860 a 1040 nm	Coastal - 400 a 450 nm Blue - 450 a 510 nm Green - 510 a 580 nm Yellow - 585 a 625 nm Red - 630 a 690 nm Red Edge - 705 a 745 nm Near-IR 1 - 770 a 895 nm Near-IR 2 - 860 a 1040 nm
	SWIR	-	-	SWIR-1 - 1195 a 1225 nm SWIR-2 - 1550 a 1590 nm SWIR-3 - 1640 a 1680 nm SWIR-4 - 1710 a 1750 nm SWIR-5 - 2145 a 2185 nm SWIR-6 - 2185 a 2225 nm SWIR-7 - 2235 a 2285 nm SWIR-8 - 2295 a 2365 nm
	CAVIS	-	-	Desert Clouds - 405 a 420 nm Aerosol-1 - 459 a 509 nm Green - 525 a 585 nm Aerosol-2 - 635 a 685 nm Water-1 -845 a 885 nm Water-2 - 897 a 927 nm Water-3 - 930 a 965 nm NDVI-SWIR - 1220 a 1252 nm Cirrus - 1365 a 1405 nm Snow - 1620 a 1680 nm Aerosol-3 - 2105 a 2245 nm
Resolução	Pancromático	0,50 a 0,55 m	0,46 a 0,52 m	0,31 a 0,34 m
	Multiespectral	-	1,85 a 2,07 m	1,24 a 1,38 m
	SWIR	-	-	3,70 a 4,10 m
	CAVIS	-	-	30 m

Legenda: NIR - *Near Infrared*; SWIR - *Short Wave Infrarerd*; NDVI-SWIR - *Normalized Difference Vegetation Index-Short Wave Infrared*; CAVIS - *Clouds, Aerosols, Vapors, Ice, and Snow*.

Fonte: DIGITAL GLOBE. 2015. Disponível em: <https://www.digitalglobe.com/about-us/content-collection>. Acesso em: 08 out. 2015

O sensor multiespectral do WV2 traz consigo, além das tradicionais bandas vermelho (630 – 690nm), verde (510 – 580nm) e azul (450 – 510nm), novas bandas: costal (*Coastal*), 400 – 450nm; amarela (*Yellow*), 585 – 625nm; *Red Edge*, 705 – 745nm; pancromática (*Panchomatic*), 450 – 800nm; NIR-1 (*Near Infrared 1*), 770 – 895nm; e NIR-2, 860 – 1040nm. Com uma cobertura espectral maior, as imagens WV2 oferecem a possibilidade de se obter informações mais detalhadas de feições tais como a vegetação.

Como dito anteriormente, as bandas NIR são amplamente utilizadas para analises de vegetação, pois a folhagem das plantas reflete a radiação nos comprimentos de onda próximos ao infravermelho (PONZONI, 2002). Foi feita uma composição com as bandas 7 (NIR-1), 5 (vermelha) e 3 (verde) colocadas nos canais do vermelho, verde e azul, respectivamente, para ressaltar a vegetação como se vê na Figura 13.

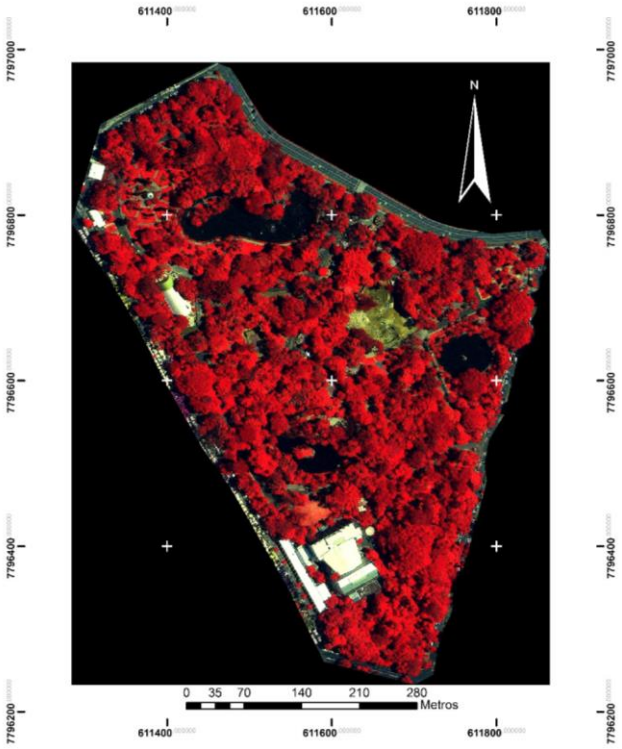

Figura 13 – Imagem hiperespectral recortada do Parque Municipal Renné Giannetti em Belo Horizonte, MG, Brasil.

4.2.3 Nuvem LiDAR

A nuvem de pontos LiDAR utilizada no trabalho foi obtida por meio de uma parceria do Centro de Métodos Quantitativos do Departamento de Recursos Florestais da ESALQ/USP com a Fundação de Parques Municipais da prefeitura de Belo Horizonte. A prefeitura possui nuvens LiDAR de todos os parques e praças municipais, entre elas, a do Parque Américo Renné Giannetti.

Os dados do aerolevantamento estão reunidos na Tabela 6.

Tabela 6 – Dados gerais do sobrevoo e especificações do sensor LiDAR utilizado na aquisição da nuvem de pontos do parque municipal Américo Renné Giannetti.

Aeronave	EMB-810c SENECA (PT-RQA)
Sensor	Leica ALS 50
Frequência	150 Khz
Altitude do voo	2746 m
Ângulo de visada	20°
Nº de faixas levantadas	76
Dimensões das faixas levantadas	Variadas
Densidade dos pulsos	4 pontos por m²
Intensidade dos pulsos	114.600 Hz
Taxa de varredura (*scan rate*)	63 Hz
Acurácia vertical	30 m
Data do sobrevoo	entre outubro e novembro de 2007

4.2.3.1 Processamento da nuvem e extração de informações básicas

As etapas do processamento da nuvem LiDAR, bem como a extração dos arquivos e informações básicas para a classificação supervisionada estão reunidas na figura 14. O processamento foi realizado por meio do programa Fusion versão 3.42 e da execução de códigos de comando pelo prompt de comando do Windows.

O Fusion é um programa gratuito desenvolvido pelo serviço florestal norte-americano para manejar nuvem de pontos LiDAR.

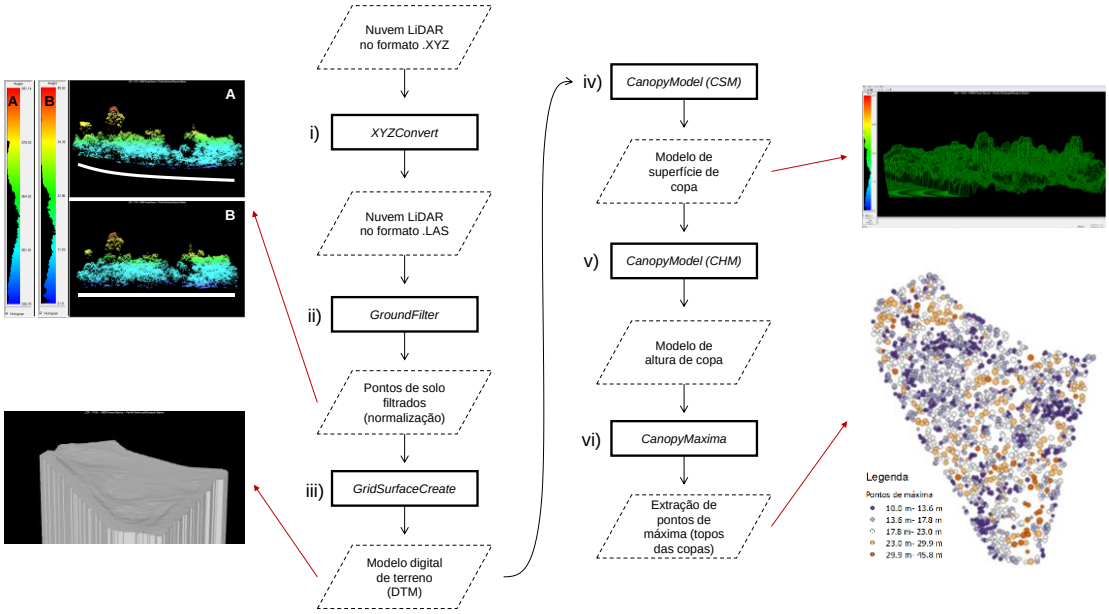

Figura 14 – Esquema simplificado do processamento da nuvem LiDAR. Etapas compreendem da conversão do formato original da nuvem em .LAS até a extração dos pontos de máxima, pelo comando *CanopyMaxima*.

As seis etapas do processamento da nuvem de pontos LiDAR ilustrados na figura 14 são descritos a seguir:

i) A nuvem LiDAR foi fornecida originalmente no formato de armazenamento *.XYZ*. Este formato não é editável, sendo preciso transformá-la em um arquivo do tipo *.LAS*. Para tanto, executou-se o comando *XYZConvert*, e com a nuvem devidamente convertida, ela pode ser normalizada no passo seguinte.

ii) A normalização é a etapa em que se ajusta os valores de elevação da nuvem (associados originalmente ao geóide de referência SAD 69 23 S) para o solo imediatamente abaixo da nuvem. Dessa forma os valores de elevação são transformados em valores de altura. Desse modo executou-se o comando *GroundFilter*. Este filtra os pontos referentes ao solo, que são subtraídos do restante da nuvem, deixando-a plana.

iii) O arquivo gerado pelo *GroundFilter* será utilizado na próxima etapa, que é a criação do modelo digital do terreno (MDT). O comando *GridSurfaceCreate* interpola os pontos referentes ao solo e gera um

modelo que contém a representação acurada do solo imediatamente abaixo dos pontos da nuvem.

iv) A partir da nuvem normalizada é possível criar um modelo digital de superfície de copa (MDS) por meio da execução do comando *CanopyModel*. O MDS é formado pelo lançamento de uma grade sobre a nuvem que liga os pontos superiores, formando uma superfície contínua em três dimensões.

v) O MDS, por sua vez, é utilizado para se obter o valor de altura das copas. O comando *CanopyModel*, então, gera um modelo de altura de copa (MDAC) do qual é possível se obter os pontos de máximo das copas, i.e., pontos mais superiores.

vi) Com o comando *CanopyMaxima*, são extraídos os pontos mais altos de uma região do MDAC. Pode-se interpretar esses pontos como sendo o topo das copas. Por essa razão o arquivo contendo estes pontos foi transformado em *shapelfile* para melhor manuseio e para facilitar a edição com outros arquivos em ambiente SIG.

4.3 Análise dos dados

As etapas para a obtenção da imagem WV2 classificada estão resumidas na Figura 15.

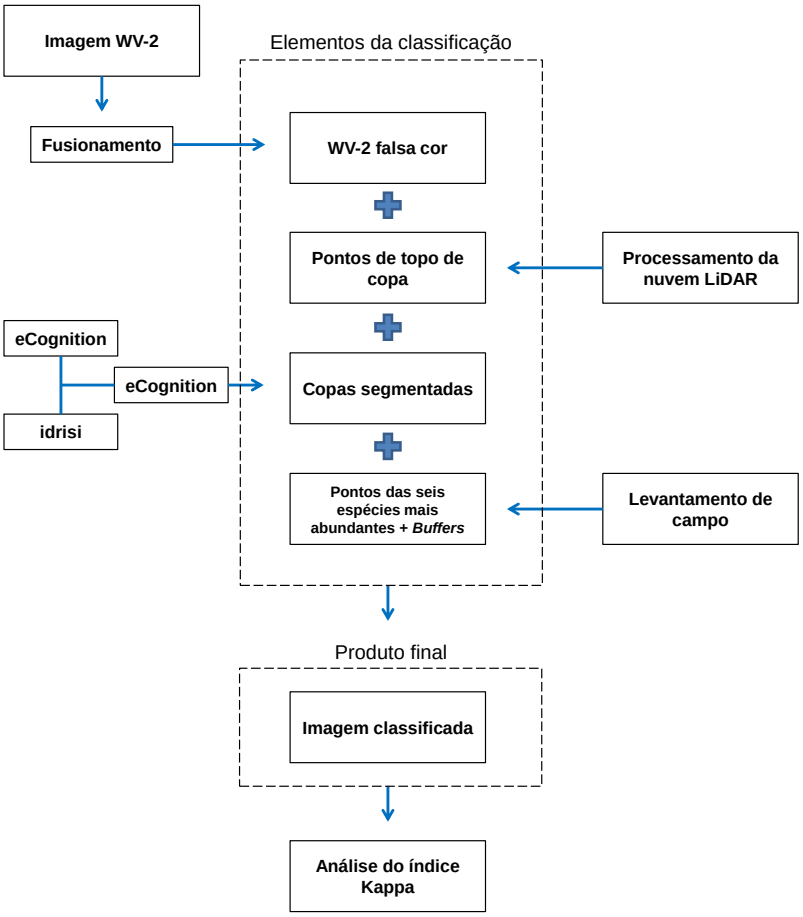

Figura 15 – Esquema resumido para a obtenção da imagem classificada final.

Os processos executados em cada etapa estão detalhados nos itens a seguir:

4.3.1 Segmentação

Como visto na seção 3.6.2.1, o processo de segmentação é uma etapa essencial no processo de classificação supervisionada de imagens digitais, por permitir a descriminação de feições com padrões espectrais semelhantes. Neste trabalho, foram testadas as ferramentas de segmentação de três programas – ArcGis, Idrisi e eCognition, tomando como base a imagem WV2 e o MDE derivado da nuvem LiDAR. Também foram utilizados na comparação as dimensões das copas das árvores geradas pelo programa Fusion.

Os resultados com a imagem WV2 foram utilizados na classificação final, enquanto que os resultados do MDE foram utilizados para discutir a utilização de modelos desse tipo para a definição das copas das árvores. Dessa forma, dividiu-se esta seção em duas: A segmentação aplicada à imagem WV2 e aquela aplicada ao MDE.

4.3.1.1 Segmentação aplicada à imagem WV2

Um esquema ilustrando as etapas básicas realizadas na segmentação com a imagem WV2 está reunido na figura 16.

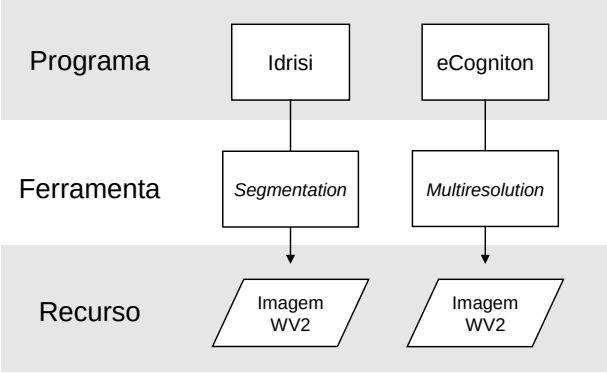

Figura 16 – Esquema de segmentação realizado pelos programas Idrisi e eCognition na imagem WV2.

4.3.1.1.1 Segmentação com Idrisi

O programa Idrisi possuí uma ferramenta específica chamada *Segmentation* para a segmentação de imagens digitais. A figura 17 mostra a interface da ferramenta.

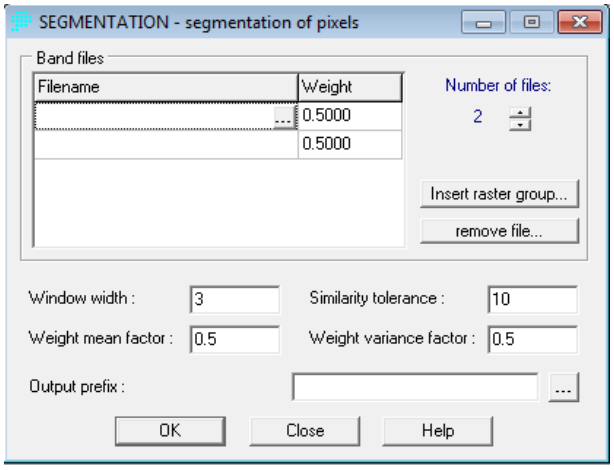

Figura 17 – Interface da ferramenta Segmentation do programa Idrisi. É possível alterar os critérios de análise da imagem.

A *Segmentation* se baseia no princípio de modelagem hidrológica de definição de bacias hidrográficas. O algoritmo da ferramenta faz uma varredura na imagem identificando pixels com similaridades espectrais homogêneas, agrupando-os em

segmentos, cada qual contendo características espectrais distintas. O analista pode modificar os critérios de tolerância de similaridade (*Similarity Tolerance* - ST), o tamanho da janela de varredura (*Window Width* - WW), os fatores de variância (*Weight Variance Fator* - WVF) e de média (*Weight Mean Fator* - WMF). Quanto menor a tolerância de similaridade, mais homogêneos os segmentos serão, enquanto que valores maiores resultarão em segmentos maiores e mais heterogêneos (CLARK LABS, 2009; GABRIEL, 2013). De acordo com Clark Labs (2009), desenvolvedor do programa, a segmentação é dividida em três etapas básicas:

i) Atribui-se pesos à imagem de entrada. A atribuição de pesos deve acontecer para designar a importância (hierarquia) da banda da imagem no processo de segmentação. Em seguida a imagem de entrada é derivada e é criada uma imagem contendo valores de variância de valor de pixel. A pixels com homogeneidade de variação é atribuído valores baixos de variância, enquanto que os pixels limítrofes das áreas com homogeneidade de variância, são atribuídos valores altos. A imagem final é a média ponderada das bandas da imagem de entrada.

ii) O comando interpreta os valores de variância dos pixels da imagem como sendo valores de elevação, tais como em um modelo digital de elevação (MDE). Assim, pixels com valores de elevação próximos são agrupados em segmentos maiores.

iii) Estes segmentos são agrupados novamente em outros segmentos até que o critério de homogeneidade seja atingido.

Foram testadas 48 combinações de segmentação cujas variações de ST, WW, WMF e WVF estão descritos na tabela 7.

Tabela 7 – Relação das combinações possíveis para os comandos de segmentação dos programas Idrisi e eCognition.

Segmentação	IDRISI				ECOGNITION		
	ST	WW	WMF/WVF	total de combinações possíveis	SP	S/C	total de combinações possíveis
WV2	10 20 30 50	2x2 3x3 4x4 5x5	0.5/0.5 0.25/0.75 0.75/0.25	48	10 20 30 50	0.5/0.5 0.25/0.75 0.75/0.25	12

4.3.1.1.2 Segmentação com eCognition

O algoritmo *Multiresolution* criado pela Trimble, desenvolvedora do programa eCognition, funciona de forma semelhante ao *Segmentation* do Idrisi, porém leva em consideração, também, parâmetros de cor, textura e topologia da imagem de entrada, como pode ser visto na janela de interface da ferramenta (Figura 18). A segmentação é do tipo *bottom-up*, que agrupa segmentos menores em maiores até que os critérios de homogeneidade sejam atingidos. Na prática essa técnica diminui a heterogeneidade e aumenta a homogeneidade dos objetos.

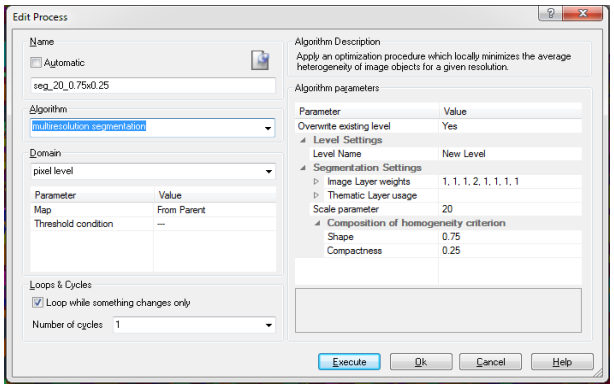

Figura 18 – Interface do comando Multiresolution Segmentation do programa eCognition. É possível modificar diversos critérios de análise da imagem.

Nas definições de segmentação (*Segmentation settings*) atribui-se o peso das bandas da imagem de entrada. Nele é possível, também, ajustar os valores de tolerância de similaridade entre objetos em *Scale Parameter* (SP) ou parâmetros de escala (equivalente ao ST do Idrisi). Da mesma forma que o algoritmo do Idrisi, quanto menor forem os valores de tolerância de similaridade, menores e mais numerosos serão os segmentos, enquanto que valores altos retornam poucos segmentos maiores. No item *Composition of homogeneity criterion*, onde são

definidos os critérios de homogeneidade, é possível ajustar as razões de forma (*Shape - S*) e a compacidade (*Compactness - C*) (equivalentes ao WMF e WVF). Variando de 0,0 a 0,9, os valores de forma medem em que grau a forma do objeto influenciam a segmentação frente à cor. Por exemplo: valor de forma igual a 0,8 resulta em valor de cor igual a 0,2. Exemplo semelhante pode ser feito para compacidade. Aumentando valores de compacidade, altera-se a razão para suavidade. Ambas baseiam-se na textura da imagem de entrada. Ao todo, é possível realizar 12 combinações de SP, S e C no eCognition (Tabela 7).

4.3.1.1.3 Escolha da melhor segmentação para a classificação final

A escolha da segmentação que melhor definisse as copas das árvores na imagem WV2, baseou-se em análises visuais de todas as combinações possíveis para os dois programas utilizados, resultando em uma segmentação do programa Idrisi e outra do eCognition. Por sua vez, para escolher a melhor segmentação entre as duas selecionadas, para, por fim, ser utilizada na classificação final, foi feita uma análise estatística das áreas dos polígonos formados, como demonstrado na figura 19.

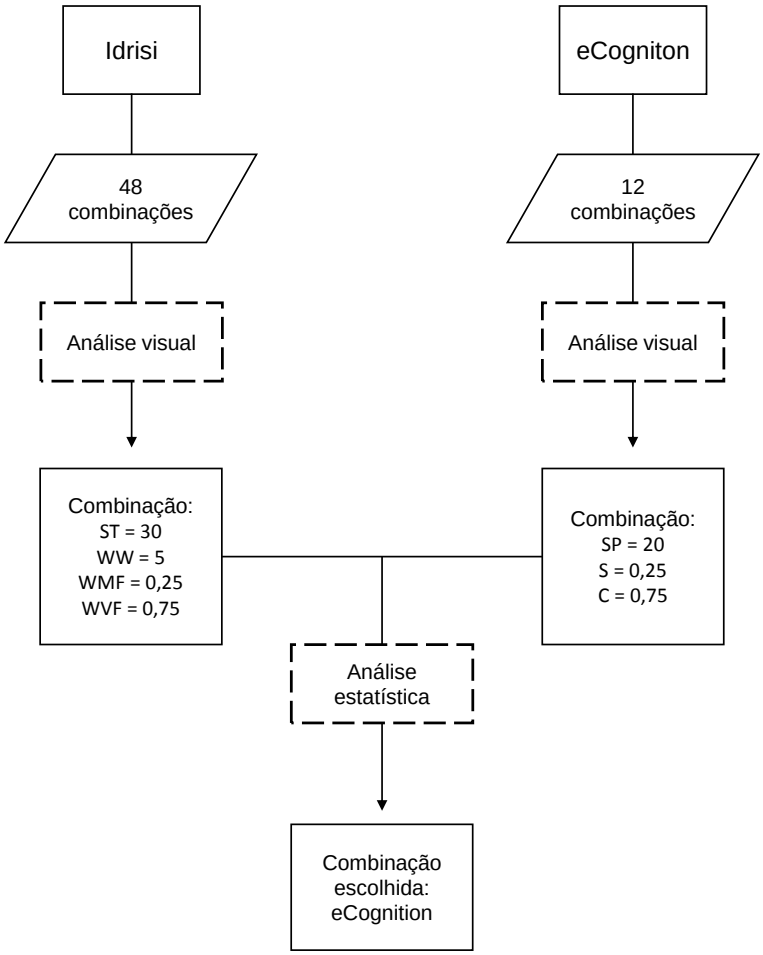

Figura 19 – Escolha da melhor segmentação para ser utilizada na classificação final. Por meio de uma análise visual dentre todas as combinações possíveis de segmentação dos programas Idrisi e eCognition, chegou-se a uma segmentação cada. Em seguida, por meio de análise estatística das áreas dos polígonos formados, escolheu-se a segmentação gerada pelo programa eCognition.

A figura 20 traz a comparação visual entre as segmentações escolhidas do programa Idrisi e eCognition.

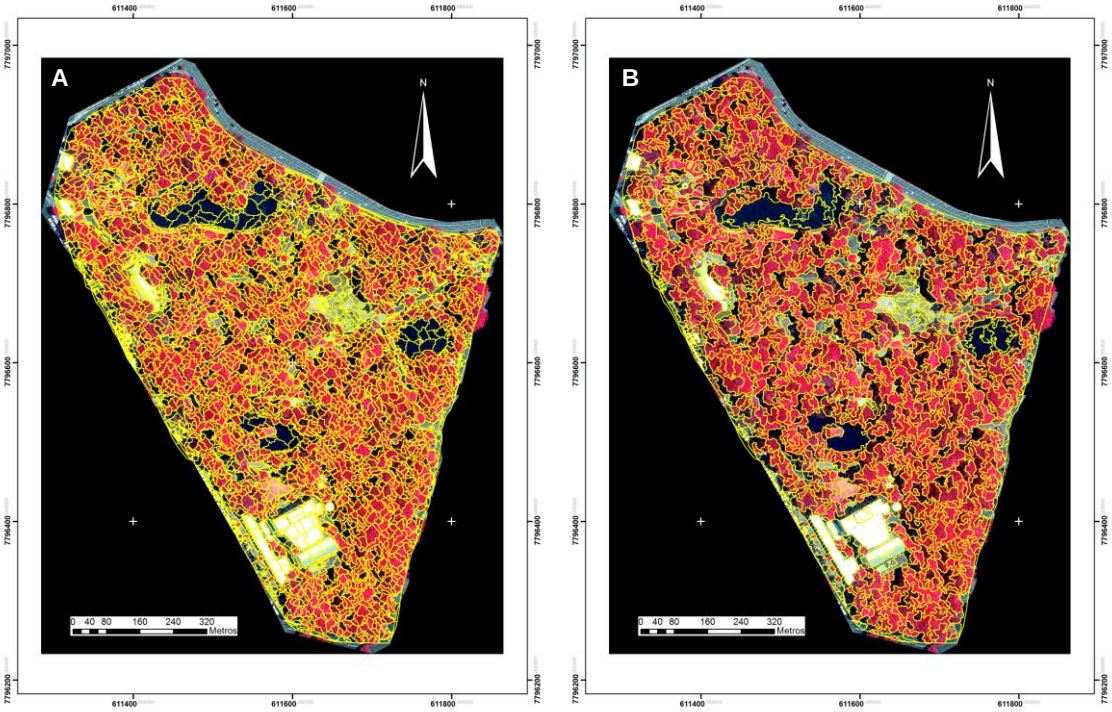

Figura 20 – Comparação visual do padrão de segmentação executado pelos programas eCognition e Idrisi. Em A, a segmentação escolhida do Idrisi: ST = 30, WW = 5, WMF = 0.25 e WVF = 0.75; e em B, a segmentação escolhida do eCognition: SP = 20, S = 0.25 e C = 0.75.

Em seguida, para selecionar entre as duas segmentações aquela a ser utilizada na classificação final, realizou-se uma análise estatística da média e do desvio padrão das áreas dos segmentos formados em ambas as ferramentas (Tabela 8).

Tabela 8 – Estatística básica exploratória aplicada às segmentações escolhidas realizadas pelos programas Idrisi e eCognition, na imagem WV2. A menor média (m²) e desvio padrão (m²) foram encontrados para a segmentação do programa eCognition.

	Média (m²)	Desvio Padrão (m²)	Soma (m²)	Minimo (m²)	Máximo (m²)	N	CV	Número de valores únicos	Intervalo (m²)	Mediana (m²)
ECOGNITION	58.97	45.0651	227373.00	1.00	461.00	3856	0.7643	239	460.00	49.00
IDRISI	220.95	213.1676	221392.00	1.00	3027.00	1002	0.9648	440	3026.00	164.00

Ao se analisar a tabela 8, nota-se que o eCognition gerou segmentos de menor área média, e com desvio padrão mais baixo em comparação ao Idrisi. Isto se deve ao fato do programa ter delimitado um número de segmentos três vezes maior que o Idrisi, mesmo com tolerâncias de similaridade próximas. No entanto, o valor máximo das áreas dos segmentos definidos pelo eCognition foi muito baixo (461 m²) em comparação ao Idrisi (3027 m²). Não se espera encontrar copas com área tão

grande quanto o apontado pelo Idrisi e, como o levantamento de campo fornecido não consta informações de dimensão das copas, preferiu-se adotar a segmentação que definisse copas menores ou mais próximas à realidade. Assim, a segmentação do programa eCognition foi selecionado para ser utilizado na classificação final.

4.3.1.2 Segmentação aplicada ao MDE

Optou-se por testar, em caráter exploratório, as ferramentas de segmentação no MDE derivado da nuvem LiDAR, mesmo não havendo dados das dimensões das copas do levantamento de campo para uma comparação mais confiável, para verificar se modelos desse tipo podem ser utilizados para a delimitação de copas de árvores. Um esquema ilustrando as etapas básicas realizadas na segmentação com o MDE está reunido na figura 21.

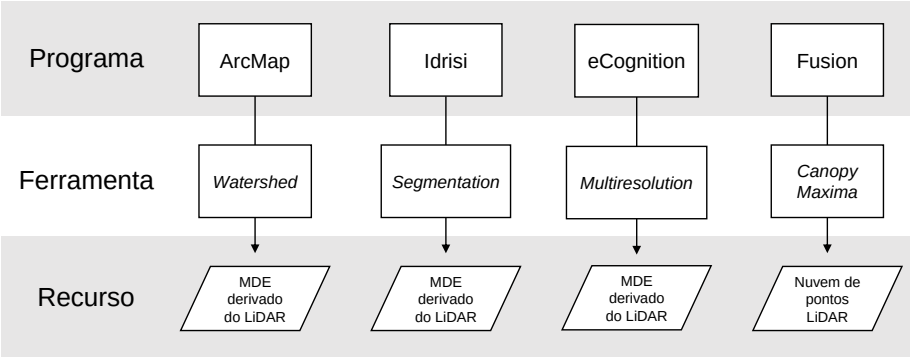

Figura 21 – Esquema de segmentação realizado pelos programas ArcGis, Idrisi, eCognition e Fusion no MDE derivado da nuvem LiDAR.

O procedimento para a escolha das segmentações dos programas Idrisi e eCognition foi semelhante ao realizado para a imagem WV2. Testou-se todas as combinações possíveis dos critérios de segmentação, e por meio de uma análise visual, chegou-se a uma segmentação para o Idrisi (ST = 10, WW = 3, WMF = 0,50 e WVF = 0,50) e uma para o eCognition (SP = 20, S = 0,25 e C = 0,75). A figura 22 ilustra os padrões de segmentação para os programas ArcGis, Idrisi e eCognition.

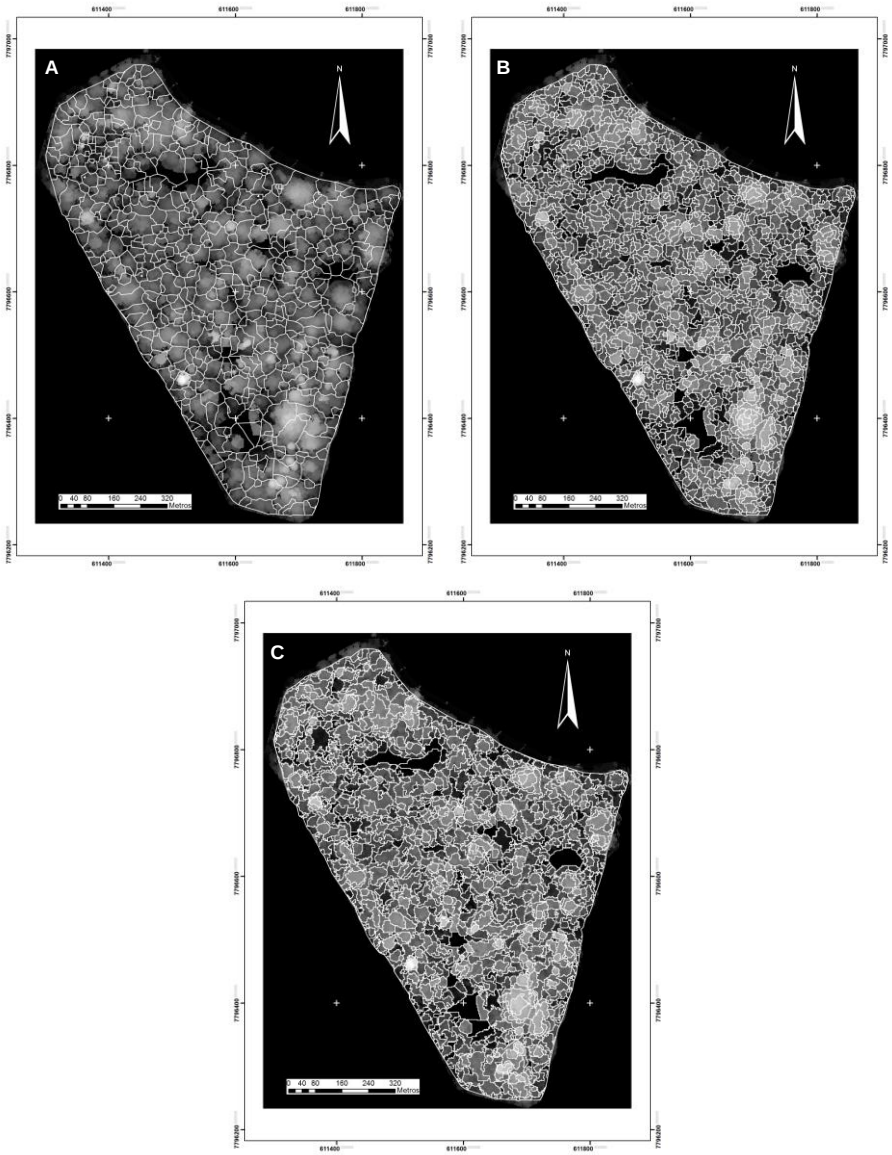

Figura 22 – Padrões de segmentação gerados pelos programas: A) ArcGis; B) Idrisi; e C) eCognition.

A ferramenta utilizada no programa ArcGis para a segmentação do MDE será descrita a seguir. O programa Fusion não possui uma ferramenta especifica para segmentar imagens. O produto derivado da nuvem de pontos utilizado na comparação desta seção é um mapa de pontos categorizados, em que os tamanhos dos pontos são as áreas das copas das árvores, como será melhor descrito a seguir.

4.3.1.2.1 ArcGis

O programa ArcGis versão 9.3 da Esri não dispõe de uma ferramenta específica para a segmentação de imagens tal qual será vista nos outros programas. A ferramenta que gera um resultado que melhor se aproxima de uma segmentação é a ferramenta de delimitação de bacias hidrográficas ou *Watershed*. Ela é a última

etapa de um conjunto de seis processos (Figura 23) aplicados ao MDE, para encontrar regiões de drenagem, e que pode ser utilizada, também, na delimitação de copas de árvores, como descrito por Swamer (2012).

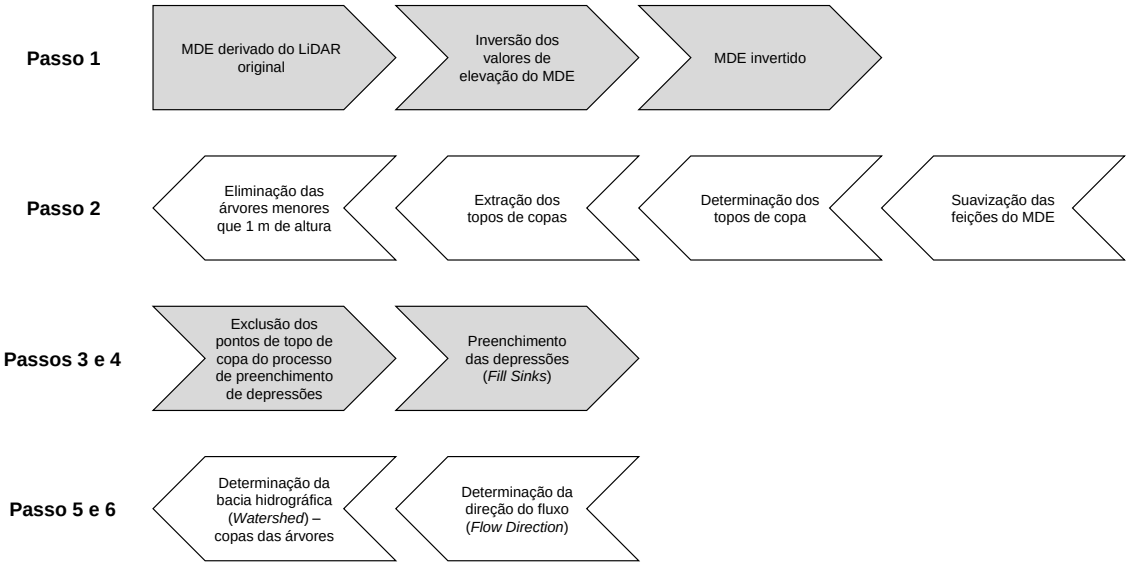

Figura 23 – Fluxograma dos passos realizados no programa ArcGis para a segmentação das copas, por meio da ferramenta *Watershed*.

Cada passo descrito na figura 23 é melhor detalhado a seguir:

i) Inversão dos valores de elevação: Os valores de elevação do MDE são invertidos (*Spatial Analyst Tools> Map Algebra> Raster Calculator>* MDE * -1> “MDE_invertido”) para tornar regiões de maior elevação em depressões (*sinks*);

ii) Determinação dos pontos de mínima: Para que sejam definidos os pontos referentes aos topos das árvores, o “MDE_invertido” precisa passar por um filtro passa baixa (*Spatial Analyst Tools> Neighborhood> Filter> LOW*) para suavizar as feições. Em seguida são determinados (*Spatial Analyst Tools> Neighborhood> Focal Flow*) e extraídos (*Spatial Analyst Tools> Conditional> Con>* “VALUE = 255” (caso dê certo o “MDE_invertido” os valores de elevação serão negativos) os pontos referentes ao topo das copas das árvores. Em seguida, exclui-se as árvores de altura inferior a 1 metro de altura

(*Spatial Analyst Tools*> *Conditional*> *Con*> “VALUE<= -1”> “arvores_1”);

iii) Preparação para preenchimento de depressões (*fill sinks*): Os pontos do topo das árvores precisam ser excluídos do processo de preenchimento de depressões (*Spatial Analyst Tools*> *Map Algebra*> *Raster Calculator*> IsNull”arvores_1”> “arvores_1_null”; em seguida *Spatial Analyst Tools*> *Map Algebra*> *Raster Calculator*> SetNull”arvores_1_null”==0, “MDE_invertido”> “MDE_null”).

iv) Preenchimento de depressões (*fill sinks*): Executa-se o preenchimento de depressões (*Spatial Analyst Tools*> *Hydrology*> *Fill* > “MDE_null_fill”);

v) Determinação da direção de fluxo (*flow direction*): A direção do fluxo é determinada (*Spatial Analyst Tools*> *Hydrology*> *Flow Direction*> “MDE_flow”);

vi) Delimitação da bacia (*watershed*): Por fim, delimita-se a bacia hidrográfica (*Spatial Analyst Tools*> *Hydrology*> *Watershed*)

O resultado desse processo são uma imagem segmentada, onde cada polígono delimita a copa de uma árvore, e um arquivo de pontos, onde cada um representa um topo de copa.

4.3.1.2.2 Fusion

O programa Fusion não possui ferramentas de segmentação. O que é possível obter é um mapa de pontos categorizado contendo valores de área de copa e altura da árvore, como visto na figura 24.

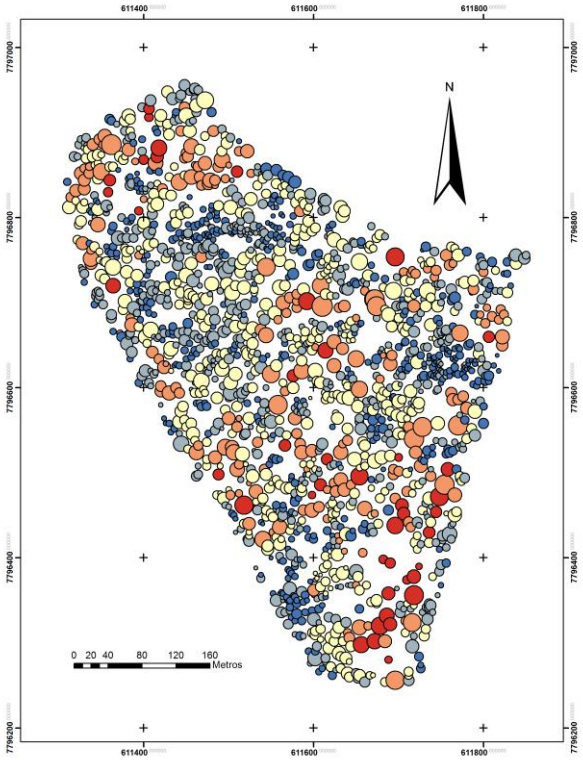

Figura 24 – Mapa categorizado de pontos provenientes da nuvem LiDAR.

Assim como o realizado na imagem WV2, a análise estatística se baseou nas áreas dos polígonos formados e nos desvios padrão gerados por cada programa, como pode ser visto na tabela 9.

Tabela 9 – Estatística básica exploratória aplicada às segmentações escolhidas realizadas pelos programas ArcGis, Idrisi, eCognition e Fusion, no MDE. A menor média (m²) e desvio padrão (m²) foram encontrados para a segmentação do programa eCognition.

	Média (m²)	Desvio Padrão (m²)	Soma (m²)	Minimo (m²)	Máximo (m²)	N	CV	Número de valores únicos	Intervalo (m²)	Mediana (m²)
ARCGIS	390.92	208.8294	247842.00	9.00	763.00	634	0.5342	634	754.00	390.50
ECOGNITION	198.61	154.7381	247667.00	1.00	1344.00	1247	0.7791	315	1343.00	168.00
FUSION	65.58	47.4791	114104.08	8.97	324.92	1740	0.7240	162	315.95	53.45
IDRISI	143.72	133.3511	221189.00	1.00	2540.00	1539	0.9278	299	2539.00	118.00

Ao se analisar os resultados reunidos na tabela 9, pode-se verificar que o programa Fusion gerou áreas menores, com um desvio padrão também menor, em comparação ao desempenho dos outros programas. Embora este estudo não possua dados de campo completos e mais acurados para uma comparação confiável e uma discussão estruturada, melhor fundamentada, sabe-se que o uso de dados LiDAR para a definição das copas das árvores é promissor em estudos florestais. Autores como Rahman e Gorte (2009), Arroyo et al., (2010), Zhou et al.,

(2010), Barbier et al., (2011), Dupuy et al., (2013), Ozdemir e Donoghue (2013) e Hu et al., (2014) apontam o uso de MDE derivados da nuvem LiDAR como recurso base em processos de segmentação para a identificação e delineamento de copas de árvores em florestas. A tecnologia se mostrou útil, permitindo a diferenciação de diferentes estratos em florestas de coníferas, e a definição de copas com acurácias maiores quando comparada aos processos de segmentação que se utilizam de imagens multi ou hiperespectrais como base. No entanto, o desempenho dessa tecnologia em florestas deciduais e tropicais, ainda merece uma investigação mais aprofundada. As acurácias conseguidas em florestas destes tipos são baixas devido ao alto grau de fechamento e de densidade do estrato superior. As copas das árvores se sobrepõem competindo por luz, dificultando a determinação de seus limites. Além do mais, a densidade do estrato superior cria uma barreira para o feixe de laser penetrar mais a fundo na floresta, tornando a tarefa de identificar o sub-bosque e árvores dominadas mais complicada.

Por outro lado, em ambiente urbano, a tarefa de identificação e delimitação das copas das árvores é mais fácil pela própria natureza menos densa da arborização. As acurácias conseguidas com o uso do LiDAR também são maiores que as conseguidas com o uso de imagens de satélite, como apontado por Ardila et al. (2011, 2012a), Zhang e Qiu (2012a) e Alonzo et al. (2014). Os autores reforçam, porém, a necessidade de que o levantamento de campo seja feito o mais completo e preciso possível, para que a validação da delimitação seja acurada.

4.3.2 Classificação

O processo de classificação é a etapa culminante deste trabalho. Nesta seção buscou-se, em um primeiro momento, explorar o desempenho dos classificadores do programa livre Multispec versão 3.4 em uma classificação não-supervisionada da imagem WV2. Em uma segunda etapa, executou-se uma classificação supervisionada na imagem WV2, com os mesmos classificadores anteriores, a fim de encontrar aquele que apresentasse o melhor desempenho para ser utilizado na classificação final. Um esquema ilustrando os passos seguidos nessa seção está reunido na figura 25.

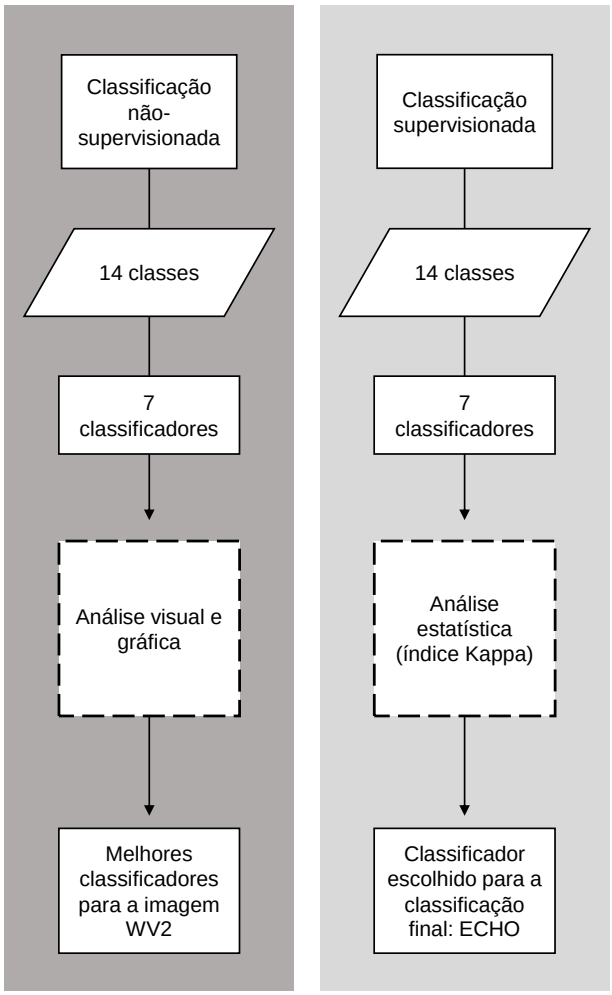

Figura 25 – Esquema ilustrando as classificações realizadas na imagem WV2, por meio do programa livre Multispec versão 3.4.

4.3.2.1 Classificação não-supervisionada

Foi executada uma classificação não-supervisionada da imagem WV2, utilizando um dos sete classificadores oferecidos pelo programa Multispec por vez: *Maximum Likelihood*, *Fisher Linear Likelihood*, *Minimum Euclidean Distance*, *ECHO Spectral-spatial*, *Correlation (SAM)*, *Matched Filter (CEM)*, e *Parallel Piped*. Foram definidas 14 classes de uso e ocupação do solo (Tabela 10) de acordo com um levantamento prévio do número de feições identificadas na área, incluindo as seis espécies de maior frequência no parque.

Tabela 10 – Classes de uso e ocupação do solo definidas tanto para a classificação não-supervisionada quanto para a supervisionada da imagem WV2.

Classes
Asfalto
Água
Telhado Claro
Piso de Cimento
Solo Exposto
Gramado
Espatodea campanulata
Ficus benjamina
Syzygium cumini
Ceiba speciosa
Handroanthus impetiginosus
Eucalyptus sp.
Sombra

Como dito na seção 3.6.1, na classificação não-supervisionada, o programa automaticamente agrupa os pixels de características espectrais semelhantes, de acordo com o número de classes definido, cabendo ao analista identifica-las e nomeá-las. Embora tenham sido definidas 14 classes de interesse, seus nomes diferem dos nomes dados às classes da classificação supervisionada, como será visto adiante, devido, justamente, a técnica de agrupamento de pixels de cada classificador.

O resultado das classificações realizadas pelos sete classificadores estão reunidos na figura 26.

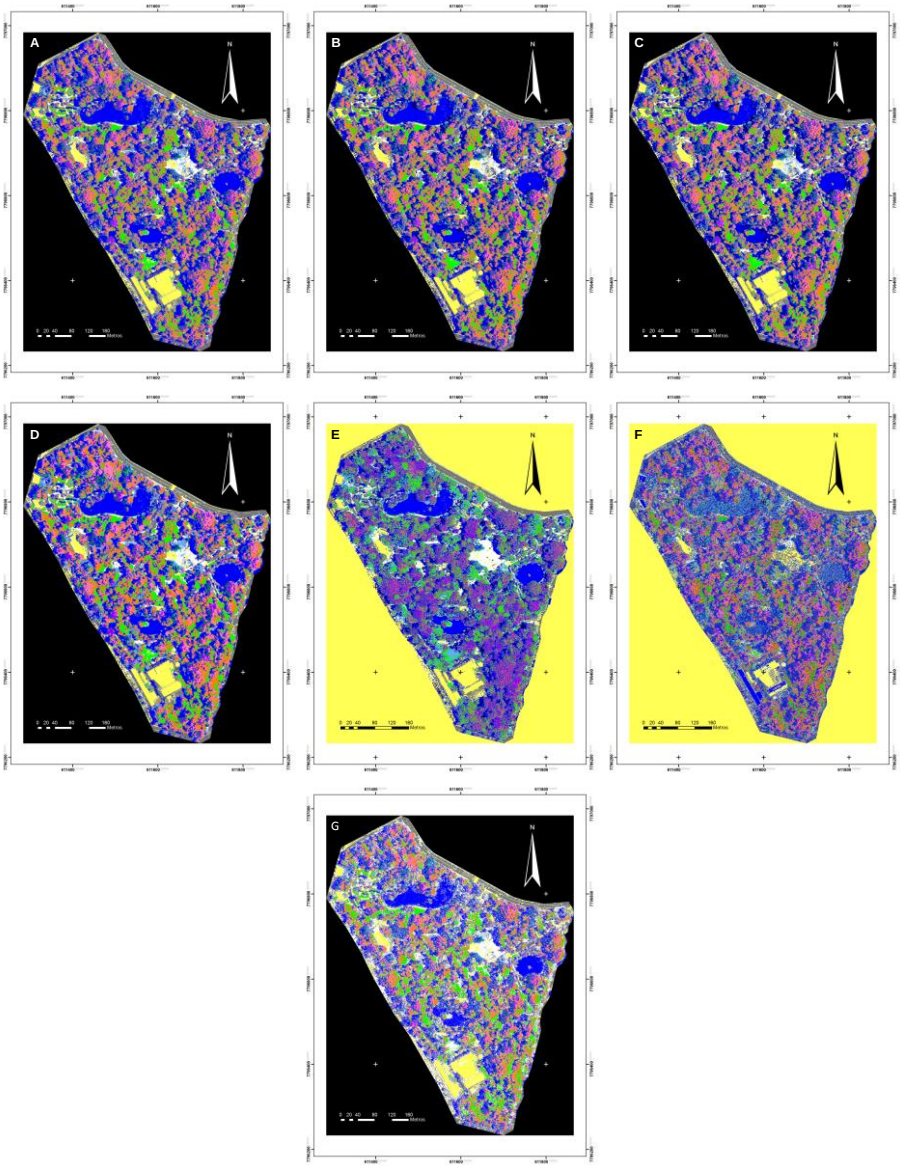

Figura 26 – Imagem WV classificada pelos classificadores: A) Maximum Likelihood, B) Fisher Linear Likelihood, C) Minimum Euclidean Distance, D) ECHO Spectral-spatial, E) Correlation (SAM), F) Matched Filter (CEM), e G) Parallel Piped.

Para avaliar melhor o padrão de classificação apresentado por cada classificador, aproximou-se as imagens na região do coreto do parque. A diversidade de classes presentes na área permite a comparação visual entre cada classificação (Figura 28).

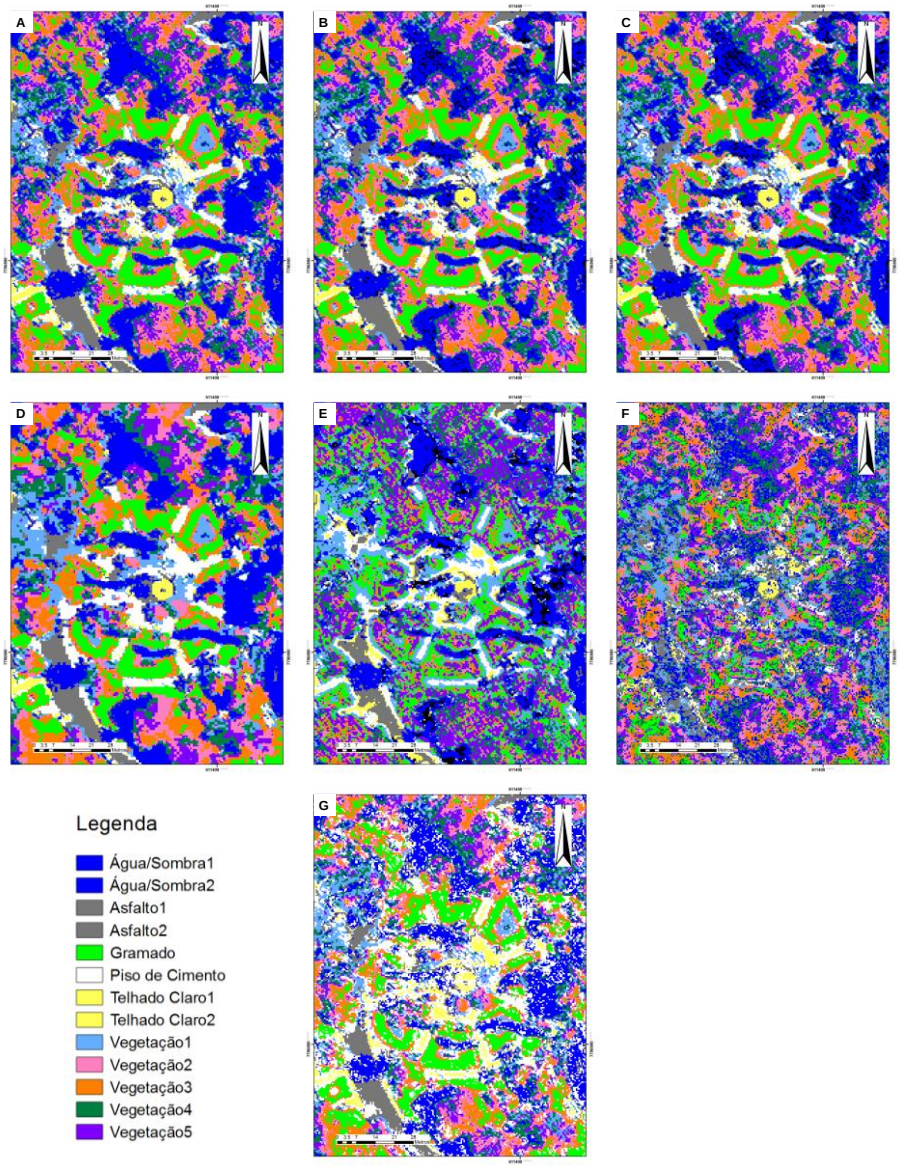

Figura 278 – Região do coreto do parque aproximada para ilustrar as diferenças no padrão de classificação não-supervisionada realizada pelos classificadores: A) *Maximum Likelihood*, B) *Fisher Linear Likelihood*, C) *Minimum Euclidean Distance*, D) *ECHO Spectral-spatial*, E) *Correlation (SAM)*, F) *Matched Filter (CEM)*, e G) *Parallel Piped*.

As diferenças notadas entre as classificações da figura 27 se devem, principalmente, em função do algoritmo utilizado pelo classificador, e da maneira com que este atua na imagem para gerar os agrupamentos de pixel. O algoritmo é desenvolvido para reconhecer os valores espectrais dos pixels e criar agrupamentos de acordo com um padrão. Existem algoritmos que são capazes de realizar essa tarefa de maneira mais eficiente que outros, por avaliarem ao mesmo tempo os parâmetros espaciais e espectrais da imagem, como no caso do classificador *ECHO Spectral-spatial*. O *ECHO*, ou *Extraction and Classification of Homogeneous Objects* é um dos classificadores mais úteis no pré processamento de imagens digitais por

executar uma classificação baseada nas propriedades espaciais e espectrais da imagem (KETTIG; LANDGREBE, 1979; RICHARDS; JIA 2006). Primeiro ele reúne pixels de características espectrais semelhantes em pequenos agrupamentos para em seguida, uni-los em regiões distintas maiores.

A escolha do algoritmo depende do objetivo do trabalho. Como cada material possui uma curva espectral característica, há algoritmos construídos para identificar somente alguns padrões espectrais de certos materiais. Estes terão melhor desempenho na classificação destes materiais do que na classificação de outros.

A figura 28 compara graficamente o desempenho dos classificadores utilizados na determinação das áreas, em porcentagem do total, das 14 classes de uso e ocupação de solo definidas.

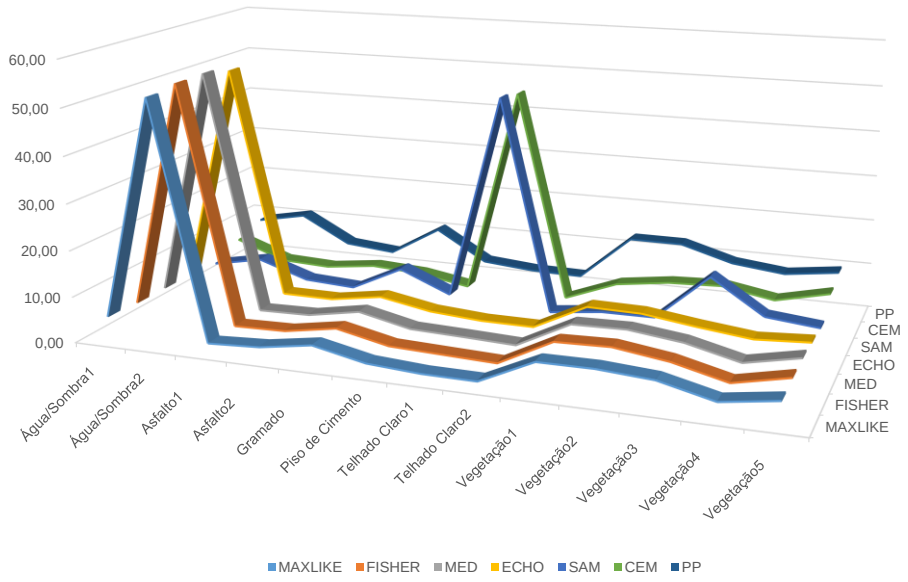

Figura 28 – Comparação gráfica do desempenho dos sete classificadores utilizados na definição, em porcentagem do total, das áreas das classes de uso e ocupação de solo estabelecidas. Legenda: MAXLIKE = *Maximum Likelihood*; FISHER = *Fisher Linear Likelihood*; MED = *Minimum Euclidean Distance*; ECHO = *ECHO Spectral-spatial*; SAM = *Correlation (SAM)*; CEM = *Matched Filter (CEM)*; e PP = *Parallel Piped*.

Ao se analisar a figura 28, pode-se verificar que os classificadores *Maximum Likelihood*, *Fisher Linear Likelihood*, *Minimum Euclidean Distance* e *ECHO Spectral-spatial* apresentaram um desempenho semelhante, identificando grandes áreas de Água/Sombra (por volta de 50% da área total), e praticamente as mesmas porcentagens nas demais classes. Este fato pode ser verificado, também, na figura 26, que reúne os padrões de classificação na imagem WV2.

Por sua vez, os classificadores *Correlation (SAM)* e *Matched Filter (CEM)* identificaram maiores áreas de Telhado Claro (por volta dos 45% do total), enquanto que o *Parallel Piped* apresentou um desempenho singular. Novamente, as diferenças entre os resultados se devem à estrutura do algoritmo, que de forma diferente identificam os parâmetros espaciais e espectrais da imagem, agrupando os pixels de maneira distinta.

A partir dessas análise exploratória dos algoritmos, pode-se sugerir o uso de qualquer um dos quatro classificadores: *Maximum Likelihood*, *Fisher Linear Likelihood*, *Minimum Euclidean Distance* e *ECHO Spectral-spatial*, para a classificação não-supervisionada de imagens WV2. Eles irão apresentar resultados semelhantes e satisfatórios, se diferindo, apenas, pela exatidão global e índice Kappa.

4.3.2.2 Classificação supervisionada

Esta seção foi dividida em duas etapas principais: i) A comparação entre o desempenho dos classificadores a fim de se eleger um para ser utilizado na classificação final, e ii) a classificação final em si. Na segunda etapa buscou-se avaliar a contribuição dos pontos de topo de copa derivados da nuvem LiDAR no processo de definição de amostras de treinamento e teste da classificação. O resultado dessa comparação em particular auxilia no entendimento de como o LiDAR pode ser utilizado para a descriminação de feições de uma imagem, no caso, uma WV2.

4.3.2.2.1 Comparação entre os classificadores

Como dito na seção 3.6.2, na classificação supervisionada é preciso indicar ao classificador os padrões espectrais dos pixels referentes às classes de interesse, por meio do lançamento de amostras de treinamento e teste. Esse passo também é conhecido simplesmente como treinamento do classificador. Nesta etapa, os sete classificadores do programa Multispec mencionados anteriormente, foram treinados e, por meio de análise do índice Kappa, elegeu-se aquele que apresentasse a melhor acurácia entre as amostras de treinamento e teste. A figura 29 reúne os padrões de classificação supervisionada gerados pelos classificadores.

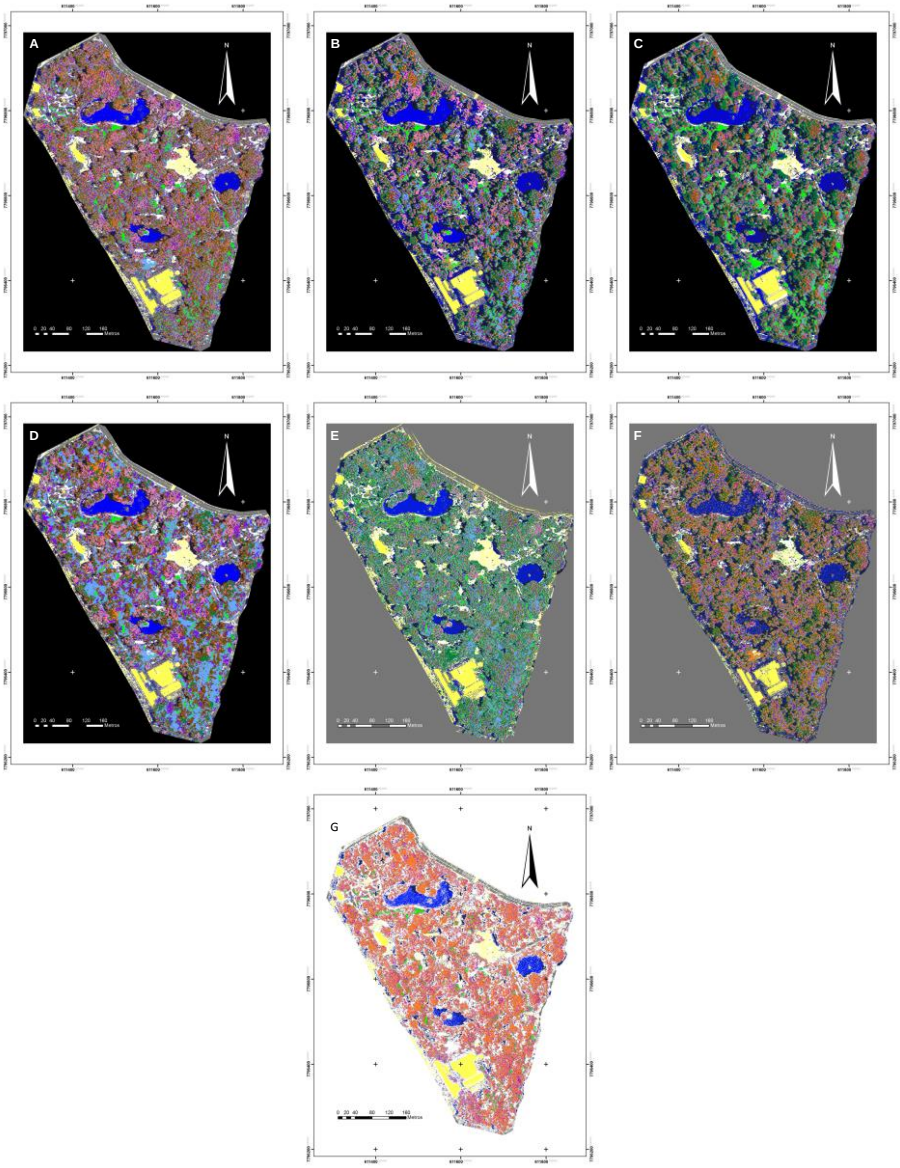

Figura 29 – Padrões de classificação supervisionada gerados pelos classificadores: aproximada para ilustrar as diferenças no padrão de classificação realizada pelos classificadores: A) *Maximum Likelihood*, B) *Fisher Linear Likelihood*, C) *Minimum Euclidean Distance*, D) *ECHO Spectral-spatial*, E) *Correlation (SAM)*, F) *Matched Filter (CEM)*, e G) *Parallel Piped*.

Assim como na figura 26, aproximou-se a área do coreto do parque para facilitar a visualização dos diferentes padrões de classificação supervisionada da imagem WV2 (Figura 30).

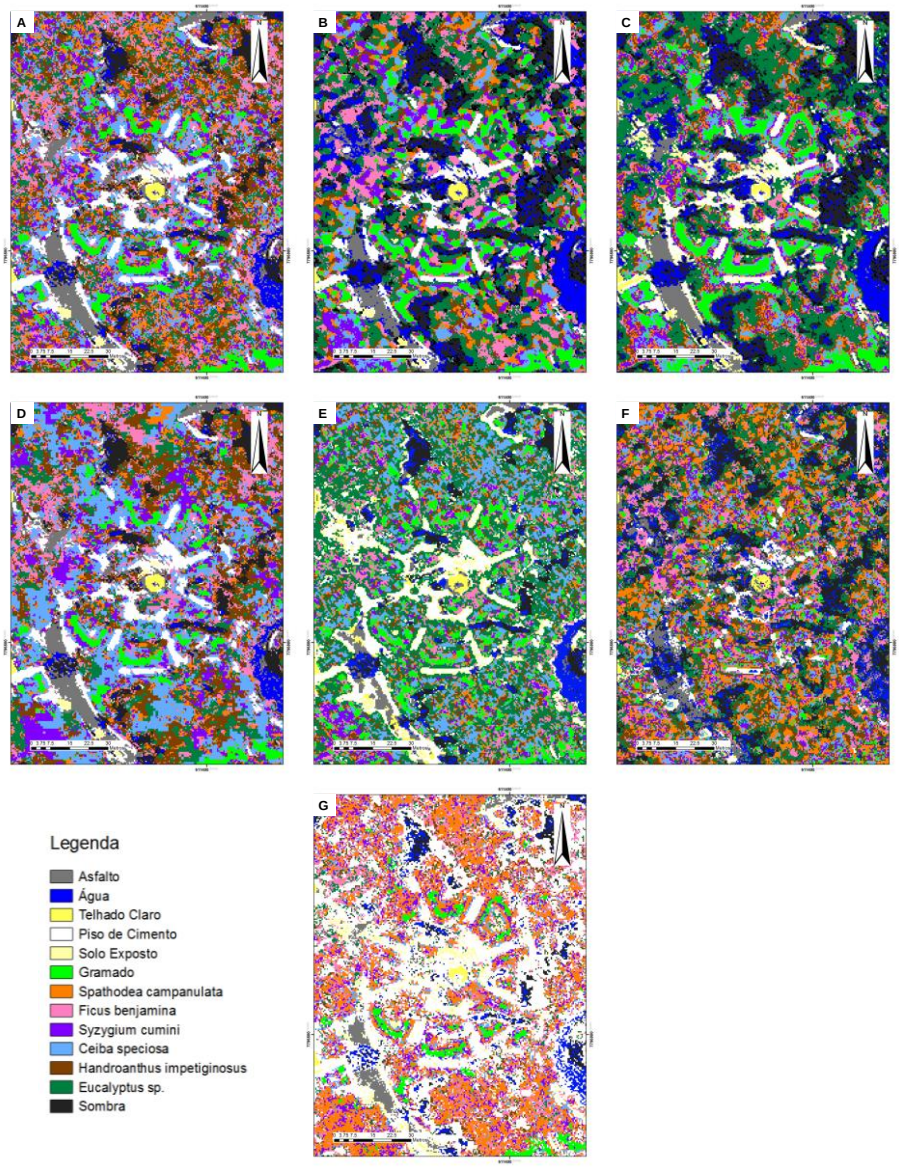

Figura 30 – Região do coreto do parque aproximada para ilustrar as diferenças no padrão de classificação supervisionada realizada pelos classificadores: A) *Maximum Likelihood*, B) *Fisher Linear Likelihood*, C) *Minimum Euclidean Distance*, D) *ECHO Spectral-spatial*, E) *Correlation (SAM)*, F) *Matched Filter (CEM)*, e G) *Parallel Piped*.

A cada classificação, uma matriz de erro era formada contendo as porcentagens de acurácia do usuário (UA), exatidão global (EG) e índice Kappa (Kappa) do classificador, reunidas de forma resumida na tabela 11.

Tabela 11 – Acurácia do usuário (UA), exatidão global (EG) e índice Kappa (Kappa) obtidos para os sete classificadores disponíveis no programa Multispect.

Classificador	Acurácia do usuário (%)													Exatidão Global (%)	Kappa (%)
	Asfalto	Água	Telhado Claro	Piso de Cimento	Solo Exposto	Gramado	Spatodea campanulata	Ficus benjamina	Syzygium cumini	Ceiba speciosa	Handroanthus impetiginosus	Eucalyptus sp.	Sombra		
Maximum Likelihood	83,70	88,90	100,00	81,50	99,20	73,70	13,20	33,60	22,90	9,10	13,30	59,20	80,00	99,00	86,90
Fisher Linear Likelihood	84,20	84,10	100,00	100,00	100,00	77,20	14,10	62,20	28,40	14,90	29,50	73,00	66,10	98,90	85,90
Minimum Euclidean Distance	91,90	84,50	98,70	54,10	89,50	70,00	12,50	60,90	28,90	14,00	37,90	61,30	54,70	98,80	82,30
ECHO Spectral-spatial	85,30	97,20	100,00	81,50	99,20	78,50	22,00	47,70	17,50	9,00	7,50	54,80	98,30	99,20	90,00
Correlation (SAM)	0,20	85,10	87,20	82,10	98,30	67,20	9,30	34,10	16,10	25,50	17,80	43,30	66,40	2,70	2,40
Matched Filter (CEM)	0,10	71,90	100,00	44,40	100,00	74,80	5,70	22,30	32,50	16,50	10,00	31,70	49,30	2,00	1,80
Parallel Piped	99,20	83,20	100,00	98,20	96,10	82,70	11,50	21,10	26,70	11,10	0,00	68,40	83,10	98,50	80,80

A UA é a medida, em porcentagem, da probabilidade dos pontos da imagem, delimitados pelos treinadores, terem sido corretamente classificados na classe designada a eles (CONGALTON; GREEN, 2009). As variações da UA encontrados entre os classificadores são devido aos algoritmos e a maneira em que estes classificam a imagem, como discutido anteriormente na seção 4.3.2.1.

A EG, medida que relaciona, em porcentagem, a quantidade de pontos corretamente classificados pelo total de pontos de referência, i.e, pelos pontos delimitados pelos treinadores. Assim, uma EG maior indica que a maioria dos pontos de referência foram corretamente classificados. A EG do classificador *ECHO* indica que 99,2% de todos os pontos de referência delimitados pelos treinadores foram corretamente classificados.

Outro fator que auxilia a tomada de decisões é o índice Kappa ou estatística K. O índice Kappa fornece a medida de concordância entre o resultado e o esperado. Variando de 0, que representa concordância nenhuma, a 1, concordância absoluta, o índice Kappa para o classificador foi de 90%. Isso significa que 90% da concordância é explicada pela classificação. Landis e Koch (1977) estabeleceram interpretações dos resultados baseados em intervalos do índice Kappa (Tabela 12).

Tabela 12 – Tabela de interpretação dos valores do índice Kappa, elaborado por Landis e Koch (1977).

Valores do índice Kappa	Interpretação
<0,00	pobre
0,00 a 0,20	ligeira
0,21 a 0,40	considerável
0,41 a 0,60	moderada
0,61 a 0,80	subtancial
0,81 a 1,00	excelente

De acordo com a tabela acima, o valor do índice Kappa atingido pelo *ECHO* é considerado excelente. Dessa forma, escolheu-se esse classificador para a realização da classificação final da imagem WV2.

4.3.2.2.2 Classificação final

Como visto nas seção anterior, o classificador *ECHO Spectral-spatial* foi escolhido para executar a classificação final, por apresentar um índice Kappa excelente (90%). Assim como nos testes guia para a escolha do classificador, foram utilizados os pontos referentes às seis espécies mais frequentes no parque para auxiliar o lançamento de amostras de treinamento e teste. Adicionalmente, foram utilizados as áreas segmentadas provenientes do programa eCognition e os pontos de topo de copa derivados da nuvem LiDAR. Buscou-se, também, verificar a contribuição dos pontos de topo de copa derivados da nuvem LiDAR no aumento da exatidão global, realizando-se duas classificações distintas: uma classificação com os pontos das espécies, áreas segmentadas e os pontos de topos de copas do LiDAR, e outra com as mesmas informações adicionais, porém sem os pontos de topos de copa do LiDAR.

A figura 31 traz dois esquemas que ilustram os procedimentos adotados no lançamento de amostras de treinamento e teste da classificação supervisionada final.

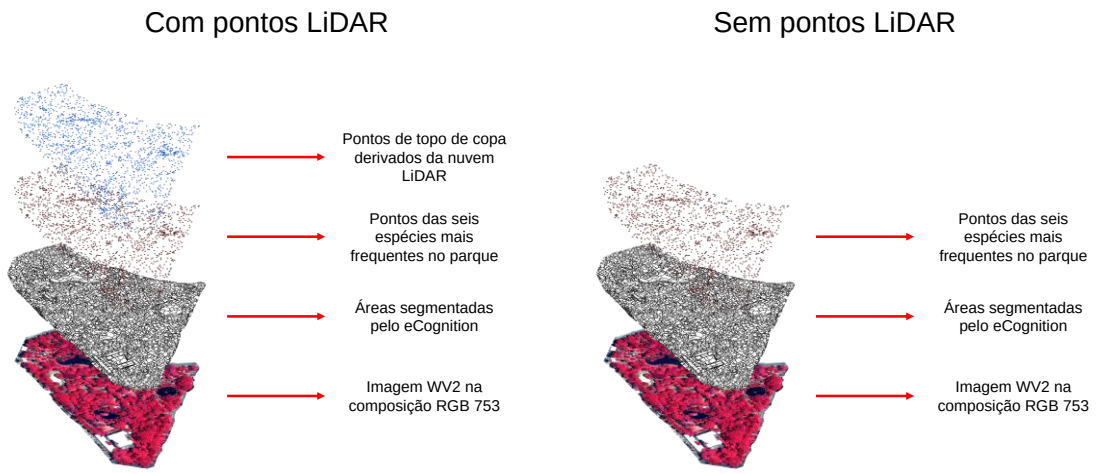

Figura 31 – Esquemas que ilustram os procedimentos adotados para auxiliar o lançamento de amostras de treinamento e teste da classificação final da imagem WV2.

O lançamento das amostras de treinamento e teste para as classes: Asfalto, Água, Telhado Claro, Piso de Cimento, Solo Exposto, Gramado e Sombra foi feito

sem auxílio de informações adicionais. Para o lançamento das amostras das seis espécies mais frequentes no parque, no entanto, respeitou-se as seguintes condições:

i) Na classificação supervisionada sem os pontos de topo de copa derivados da nuvem LiDAR, as amostras deveriam ser lançadas, ao mesmo tempo, dentro dos limites do *buffer* dos pontos das espécies e da área segmentada do eCognition;

ii) Na classificação supervisionada com os pontos de topo de copa derivados da nuvem LiDAR, as amostras deveriam ser lançadas somente onde esses pontos estivessem contidos, ao mesmo tempo, nos limites dos *buffers* do ponto das espécies e da área da segmentação do eCognition.

A figura 32 ilustra melhor as condições para o lançamento das amostras de treinamento e teste, trazendo um exemplo real de comparação entre as classificações com e sem os pontos de topo de copa do LiDAR.

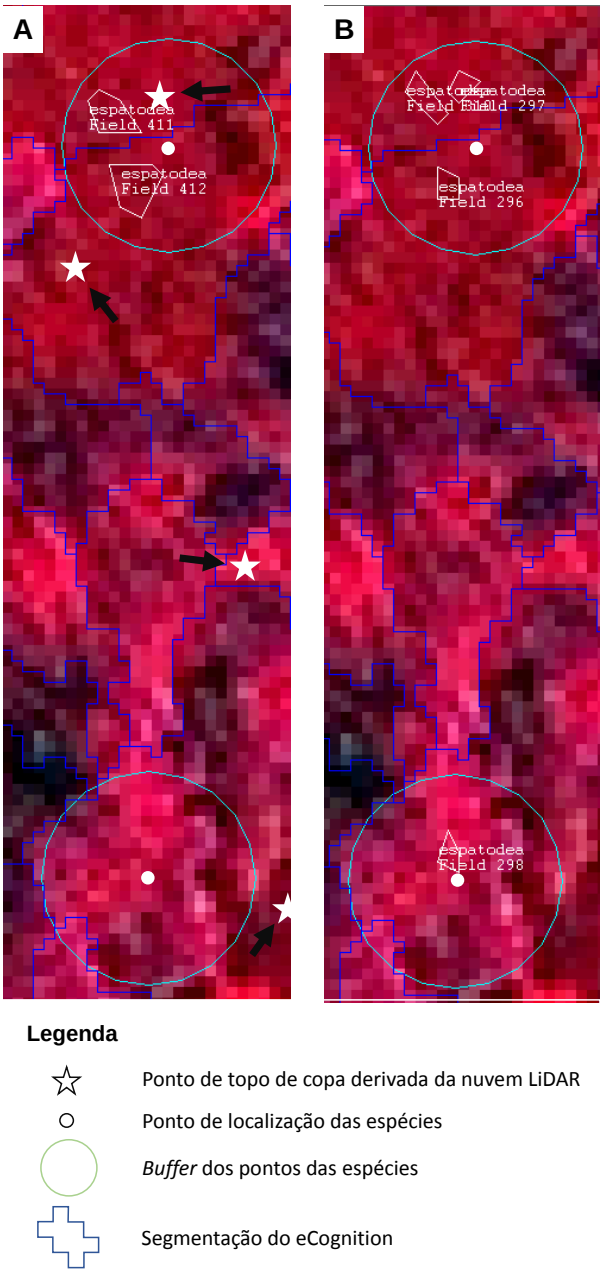

Figura 32 – Comparação do lançamento de amostras de treinamento e teste nas classificações com os pontos de topo de copa derivados da nuvem LiDAR (A) e sem os pontos LiDAR (B).

Ao todo foram lançadas 10 amostras de treinamento e 10 amostras teste para cada uma das classes e executou-se a classificação.

4.3.3 Análise estatística

Para a verificação da acurácia na classificação supervisionada por objeto, foram geradas matrizes de erro. Classificadores (algoritmos) que retornassem um índice Kappa por classe inferior a 70% precisaram ser refeitos até que os valores melhorassem ou se estabilizassem.

5 RESULTADOS

5.1 Diversidade florística

De acordo com o levantamento de campo fornecido pela prefeitura de Belo Horizonte, foi possível elaborar um quadro da diversidade florística do parque. O gráfico da figura 33 mostra a proporção de indivíduos nativos e exóticos presentes no parque, enquanto que o gráfico da figura 34 traz a relação de espécies nativas e exóticas presentes no parque. Este gráfico traz, ainda, a proporção de espécies nativas brasileiras que de ocorrência local (nativas locais) e que não ocorrem na região de Belo Horizonte (exóticas locais), além daquelas cuja origem no Brasil não foi identificada.

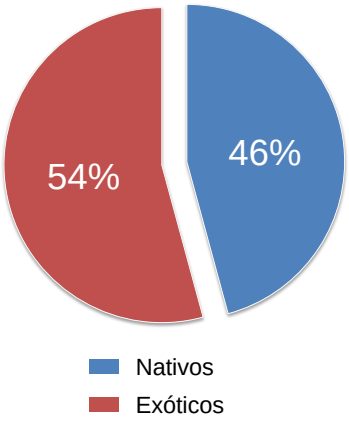

Figura 33 – Total de indivíduos nativos e exóticos do Brasil encontrados no parque municipal Américo Renné Giannetti em Belo Horizonte, MG. Dos 2904 indivíduos levantados, 54% (1557) são exóticos e 46% (1315) são nativos.

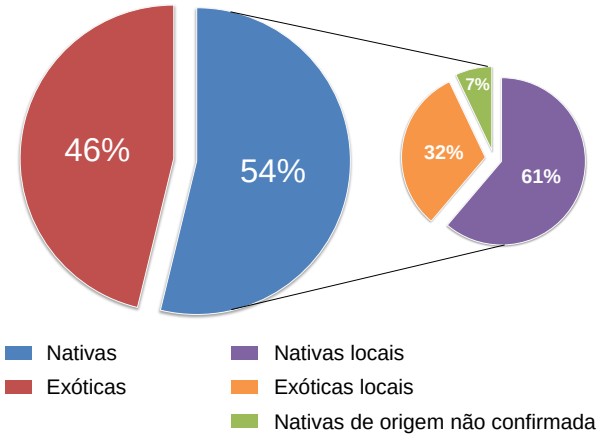

Figura 34 – O gráfico da esquerda traz o total de espécies nativas e exóticas do Brasil encontradas no parque municipal Américo Renné Giannetti em Belo Horizonte, MG. Das 164 espécies encontradas, 46% (73) são exóticas e 54% (85) são nativas. O gráfico da direita traz a

proporção de espécies nativas brasileiras de ocorrência local (nativas locais (52), que não ocorrem na região de BH (exóticas locais (27) e de origem desconhecida (6).

A partir dos gráficos das figuras 33 e 34, é possível verificar que, embora a maioria das espécies encontradas seja nativa, a maioria dos indivíduos é exótico. Isto acontece, pois há um grande número de indivíduos de uma mesma espécie, como por exemplo, *Latania sp.*, *Dypsis lutescens* e *Caryota urens*, que possuem mais de 120 indivíduos cada.

É indiscutível o papel de uma árvore para o ambiente urbano e para o equilíbrio psicológico e social de uma comunidade. No entanto, a escolha de uma espécie exótica para ser inserida em uma área verde urbana deve ser acompanhada de perto por profissionais. A ausência de predadores naturais e a presença de dispersores generalistas, como o pombo e o pardal, por exemplo, podem ampliar o potencial invasor da espécie, tornando-a uma ameaça ao ecossistema local. A exemplo tem-se a *Leucaena leucocephala* que, devido a sua baixa exigência nutricional, alta capacidade de colonizar e adaptar-se a um novo ambiente, se alastrou por áreas degradadas e marginais de corpos d'água, impedindo o desenvolvimento de plântulas de espécies nativas devido ao efeito alelopático de suas folhas e sementes (CHATURVEDI; JHA, 1992; SCHERER et al., 2005; SANTANA; ENCINAS, 2008; ARAÚJO SILVA, 2009).

Não se deve evitar por completo inserir espécies exóticas em parques e praças. Muitas são extremamente belas, frondosas, perfumadas e atraem com facilidade a avifauna. No entanto, a predileção por espécies nativas, e ainda, nativas locais, ou seja, de ocorrência natural conhecida na cidade ou região, deve ser maior do que espécies exóticas. A biodiversidade local deve ser promovida com espécies que ocorram naturalmente na área e que possuam dispersores também nativos, incentivando o aparecimento de novas espécies de animais e de plantas.

Seguindo este pensamento, o total de espécies nativas foi dividido, ainda, em espécies nativas locais e exóticas locais, como no gráfico da direita da figura 34. A divisão das espécies nativas em três categorias foi possível analisando-se a as áreas de ocorrência natural. No caso foram consideradas nativas locais aquelas espécies de ocorrência ou na região de Belo Horizonte, ou no estado de Minas Gerais. Por outro lado, as espécies consideradas exóticas locais foram aquelas de ocorrência em outros estados do país. As espécies nativas cuja origem não foi identificada foram agrupadas como espécies de origem desconhecida.

5.2 Classificação final

As matrizes de erro geradas pelas classificações com e sem os pontos de topo de copa derivados da nuvem LiDAR foram reunidas para comparação das acurácias e exatidões globais (Tabela 13).

Tabela 13 – Matrizes de erro para as classificações com os pontos de topo de copa derivados da nuvem LiDAR (acima), e sem os pontos de topo de copa derivados da nuvem LiDAR (abaixo).

Com pontos de topo de copa LiDAR																	
			Número de Amostras por Classe														
Nome da Classe	Número da Classe	PA (%)	Número Amostras	1 Asfalto	2 Água	3 Fundo	4 Telhado Claro	5 Piso de Cimento	6 Solo Exposto	7 Gramado	8 *Spathodea campanulata*	9 *Ficus benjamina*	10 *Syzygium cumini*	11 *Ceiba speciosa*	12 *Handroanthus impetiginosus*	13 *Eucalyptus sp.*	14 Sombra
Asfalto	1	100,00	139	139	0	0	0	0	0	0	0	0	0	0	0	0	0
Água	2	98,10	789	7	774	0	0	0	0	0	0	0	0	0	0	0	8
Fundo	3	100,00	61477	0	0	61477	0	0	0	0	0	0	0	0	0	0	0
Telhado Claro	4	88,00	192	6	0	0	169	17	0	0	0	0	0	0	0	0	0
Piso de Cimento	5	90,40	83	8	0	0	0	75	0	0	0	0	0	0	0	0	0
Solo Exposto	6	100,00	120	0	0	0	0	0	120	0	0	0	0	0	0	0	0
Gramado	7	94,80	173	0	0	0	0	0	0	164	5	0	0	4	0	0	0
Spathodea campanulata	8	27,70	47	0	0	0	0	0	0	11	13	8	8	0	7	0	0
Ficus benjamina	9	59,40	69	0	0	0	0	0	0	0	0	41	3	6	9	10	0
Syzygium cumini	10	13,40	82	0	0	0	0	0	0	20	8	0	11	42	1	0	0
Ceiba speciosa	11	11,10	90	0	0	0	0	0	0	11	17	1	23	10	13	15	0
Handroanthus impetiginosus	12	10,00	80	0	0	0	0	0	0	3	8	10	16	34	8	1	0
Eucalyptus sp.	13	26,40	129	0	0	0	0	0	0	0	2	12	2	15	64	34	0
Sombra	14	89,50	506	3	22	1	0	0	1	0	6	14	0	0	4	2	453
TOTAL			63976	163	796	61478	169	92	121	209	59	86	63	111	106	62	461
UA (%)				85,30	97,20	100,00	100,00	81,50	99,20	78,50	22,00	47,70	17,50	9,00	7,50	54,80	98,30

Exatidão Global (63488 / 63976) = 99,2%
Índice Kappa = 88,90%. Variancia Kappa = 0,000016

Sem pontos de topo de copa LiDAR																	
			Número de Amostras por Classe														
Nome da Classe	Número da Classe	PA (%)	Número Amostras	1 Asfalto	2 Água	3 Fundo	4 Telhado Claro	5 Piso de Cimento	6 Solo Exposto	7 Gramado	8 *Spathodea campanulata*	9 *Ficus benjamina*	10 *Syzygium cumini*	11 *Ceiba speciosa*	12 *Handroanthus impetiginosus*	13 *Eucalyptus sp.*	14 Sombra
Asfalto	1	100,00	139	139	0	0	0	0	0	0	0	0	0	0	0	0	0
Água	2	98,10	789	7	774	0	0	0	0	0	0	0	0	0	0	0	8
Fundo	3	100,00	61477	0	0	61477	0	0	0	0	0	0	0	0	0	0	0
Telhado Claro	4	88,00	192	6	0	0	169	17	0	0	0	0	0	0	0	0	0
Piso de Cimento	5	90,40	83	8	0	0	0	75	0	0	0	0	0	0	0	0	0
Solo Exposto	6	100,00	120	0	0	0	0	0	120	0	0	0	0	0	0	0	0
Gramado	7	94,20	173	0	0	0	0	0	0	163	2	0	3	5	0	0	0
Spathodea campanulata	8	1,30	77	0	0	0	0	0	0	15	1	25	1	9	10	16	0
Ficus benjamina	9	55,40	74	0	0	0	0	0	0	4	16	41	6	4	0	3	0
Syzygium cumini	10	13,40	119	0	0	0	0	0	0	9	4	16	16	32	20	22	0
Ceiba speciosa	11	24,30	111	0	0	0	0	0	0	33	1	10	26	27	0	14	0
Handroanthus impetiginosus	12	2,80	109	0	0	0	0	0	0	4	1	43	2	29	3	27	0
Eucalyptus sp.	13	55,10	136	0	0	0	0	0	0	1	26	1	1	2	30	75	0
Sombra	14	90,10	506	7	22	1	0	0	2	0	2	0	8	0	0	8	456
TOTAL			64105	167	796	61478	169	92	122	229	53	136	63	108	63	165	464
UA (%)				83,20	97,20	100,00	100,00	81,50	98,40	71,20	1,90	30,10	25,40	25,00	4,80	45,50	98,30

Exatidão Global (63488 / 63976) = 99,1%
Índice Kappa = 88,90%. Variancia Kappa = 0,000017

Analisando-se as tabelas acima, fica evidente que a inclusão dos pontos de topo de copa derivados da nuvem LiDAR aumentam a acurácia na definição das classes das seis espécies mais frequentes no parque. O parâmetro que nos auxilia a confirmar esse fato é a UA Na tabela com os pontos LiDAR, os UAs para a *Spathodea campanulata*, *Ficus benjamina*, *Ceiba speciosa*, *Handroanthus impetiginosus* e *Eucalyptus sp.* são, em média, 250% maiores que o mesmo parâmetro e espécies calculado na classificação sem os pontos de topo de copa do

LiDAR. A capacidade do *ECHO* em classificar corretamente as classes, expressado pelo número total de amostras por classe também foi maior, 97% em média. O índice Kappa, por sua vez, foi ligeiramente maior na tabela de cima, corroborando a contribuição da inclusão dos pontos de topo de copa derivados da nuvem LiDAR no processo de classificação supervisionada. A figura 35 traz um gráfico que mostra a comparação entre o tamanho das áreas definidas para cada classe (em porcentagem do total), resultantes das classificações com e sem os pontos do LiDAR.

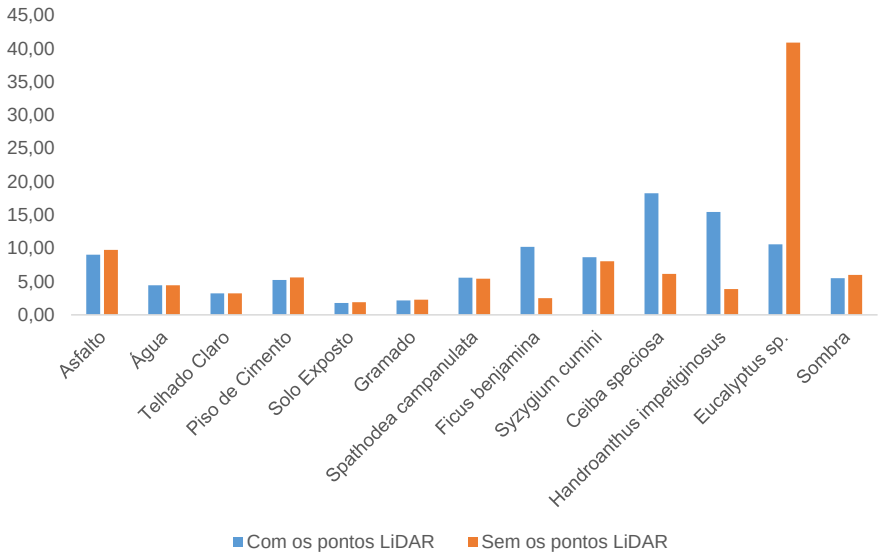

Figura 35 – Comparação das do tamanho das áreas (em porcentagem do total) definidas para cada classe, pelo classificador ECHO, na classificação com os pontos de topo de copa derivados da nuvem LiDAR (azul) e sem os pontos (laranja).

Por meio da figura 35, verifica-se que o desempenho do *ECHO* na classificação das classes que não dependiam de critérios para o lançamento de amostras de treinamento e teste, como mencionado na seção 4.3.2.2.2 (Asfalto, Água, Telhado Claro, Piso de Cimento, Solo Exposto, Gramado e Sombra), foi praticamente o mesmo entre os dois processos distintos. Porém, quando observa-se as classes referentes às espécies, verifica-se a subestimação das classes *Ficus benjamina*, *Ceiba speciosa* e *Handroanthus impetiginosus*, e a superestimação da classe *Eucalyptus sp*., na classificação sem os pontos LiDAR. Esse fato é melhor visualizado na figura 36, que traz uma comparação visual da imagem WV2 classificada com e sem os pontos do LiDAR.

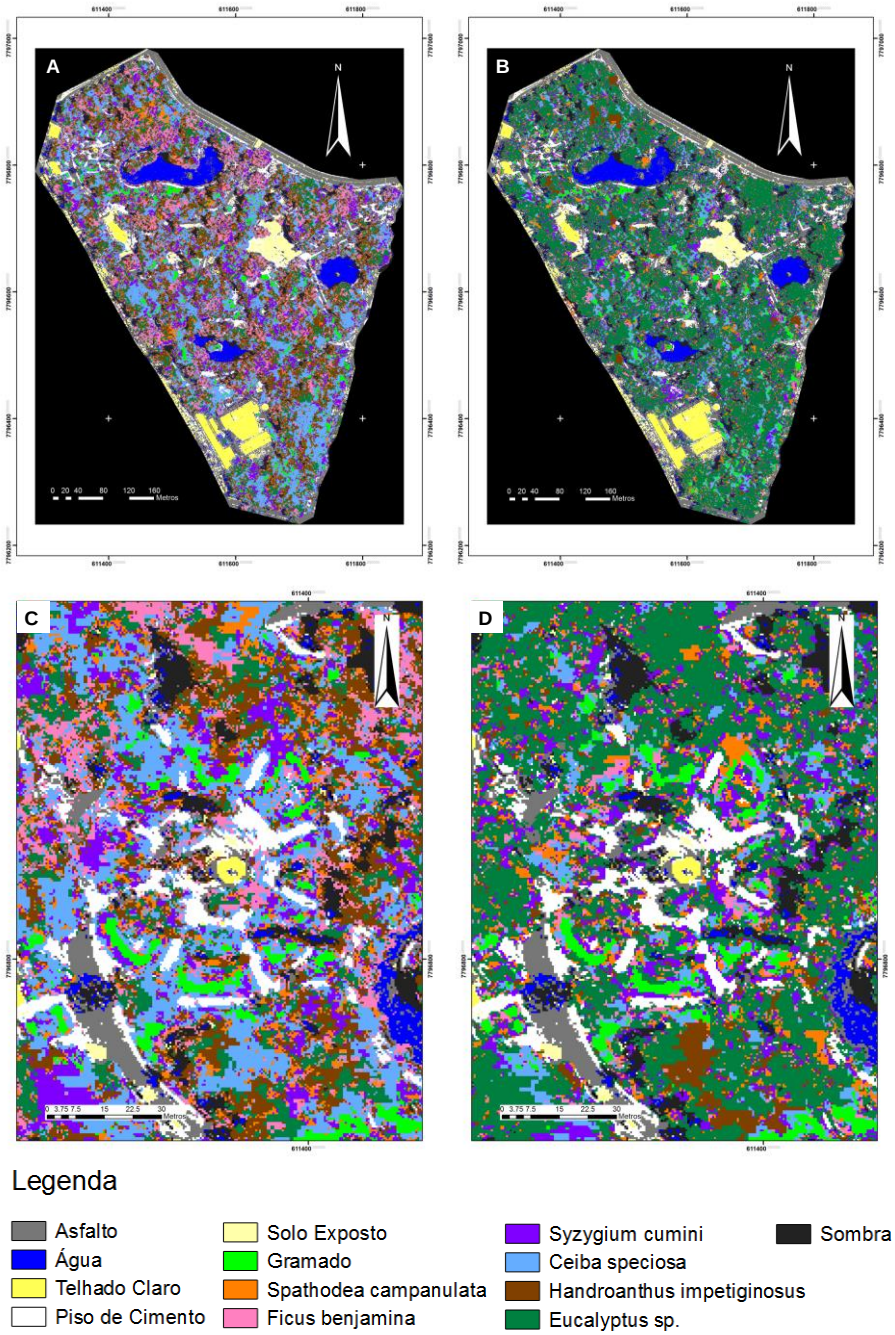

Figura 36 – Classificação supervisionada executada com o auxílio dos pontos de topo de copa derivado da nuvem LiDAR na definição das amostras de treinamento e teste (A), e sem o auxílio dos pontos do LiDAR (B). Detalhe das classificações com e sem os pontos de topo de copa do LiDAR (C e D respectivamente) tomando como referência a região do coreto do parque.

Houve claramente um erro na classificação sem os pontos do LiDAR devido ao excesso de áreas classificadas como *Eucalyptus sp.*, predominando a imagem como visto na figura 36B. Provavelmente, sem os pontos do LiDAR como referência na alocação das amostras, foram escolhidas áreas dentro dos *buffers* de *Eucalyptus sp.*, cujos valores espectrais dos pixels eram muito heterogêneos. Assim, o algoritmo

percorreu a imagem e incluiu todos aqueles pixels que compartilhavam os mesmos padrões espectrais, na classe *Eucalyptus sp.*, em detrimento às outras classes. De acordo com Pu e Landry (2012), os erros na classificação ocorrem, muitas vezes, devido às semelhanças espectrais entre os materiais que compõem os objetos. Esse fato é percebido mais frequentemente em áreas vegetadas devido às curvas espectrais características das espécies. Muitas delas somente são diferenciadas remotamente por meio da análise de suas curvas espectrais, fornecidas por imagens hiperepectrais por exemplo. Se, neste trabalho, nos dispuséssemos de uma imagem desse tipo, e de curvas espectrais prontas de algumas espécies florestais presentes no parque, poder-se-ia melhorar os resultados da classificação supervisionada, como comprovado por Pearlman et al. (2003), Erickson (2004), Buddenbaum et al. (2005), Clarck et al. (2005), Aardt e Wynne (2007), Alonzo et al. (2014) e Fassnacht et al. (2014).

A textura, i.e., os padrões espectrais provocados pelos diversos objetos presentes na imagem, também é um fator que provoca erros na classificação. Gerke e Xiao (2014) e Yan et al. (2015) apontam que texturas de vegetação semelhantes podem influenciar o analista a confundir espécies diferentes como sendo somente uma, fazendo com que os resultados da classificação sejam superestimados. Outros fatores tais como a inclinação da radiação solar incidindo na folha, a própria inclinação da folha, vento, hora do dia, ângulo de visada do sensor etc, diretamente influenciam no padrão espectral verificado pelo classificador, causando interferências na classificação final.

As imagens multi e hiperespectrais possuem muito ruído (*noise*) devido as variações no brilho (variações dos valores espectrais) dos pixels. O ruído, assim como a textura, também atrapalha a classificação, gerando um efeito de “contaminação de pixels” clamado de *salt-and-pepper effect*”, ou efeito sal-e-pimenta (GUO et al., 2011; PARENT et al., 2015). O efeito sal-e-pimenta pode ser melhor verificado na figura 37.

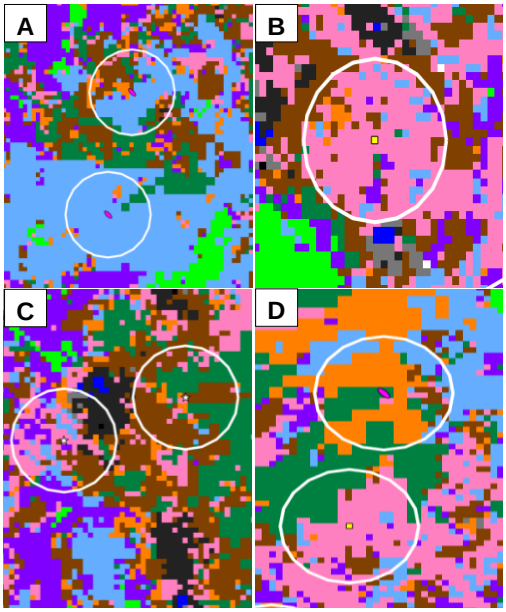

Figura 37 – Detalhes do efeito sal-e-pimenta na classificação. Em A, nota-se o predomínio da classe Ceiba speciosa (azul claro) na classe *Spathodea campanulata*; em B, pixels de diversas classes (ruído) erroneamente classificados como *Ficus benjamina* (rósea); em C, ruído na classe *Eucalyptus sp.* (verde); em D, classe *Eucalyptus sp.* erroneamente associada a indivíduos de *Spathodea campanulata* (acima) e *Ficus benjamina* (abaixo).

A aplicação de filtros de suavização, ou filtros passa-baixa (*low pass filters*), pode retirar o ruído das imagens digitais, reduzindo, assim, o efeito sal-e-pimenta e melhorando os parâmetros de avaliação da classificação, como o EG e o índice Kappa. Porém, um lado negativo desses filtros é a perda da resolução da imagem filtrada. Desse modo, não se optou por aplicar filtros à imagem WV2 utilizada neste trabalho, para que não se perdesse o contorno visível das copas, que dificultaria as análises visuais na etapa de escolha da melhor segmentação.

6 CONCLUSÃO

O trabalho buscou verificar a contribuição do uso de informações derivadas da nuvem de pontos LiDAR, na identificação e classificação das seis espécies florestais mais frequentes do Parque Municipal Américo Renné Giannetti em Belo Horizonte, Minas Gerais, Brasil, por meio do cruzamento de informações de levantamento de campo, segmentação de copas, pontos de topo de copa extraídos da nuvem LiDAR, e uma imagem multiespectral WordlView-2. A partir dos resultados apresentados, pode-se afirmar que o uso combinado de pontos de topo de copa do LiDAR, melhora a identificação e classificação das classes referentes às espécies. Os valores encontrados da exatidão global e do índice Kappa da matriz de erro, corroboram essa afirmação.

O programa eCognition executou a segmentação que melhor definiu as copas na imagem WV2. A imagem segmentada, aliada aos pontos do levantamento de campo e aos pontos do LiDAR, foram essenciais para auxiliar o lançamento das amostras de treinamento e teste da classificação.

O algoritmo que apresentou melhor desempenho na classificação foi o *ECHO Spectral-spatial*. Muito disso se deveu à alta resolução espacial da imagem WV2, que contribuiu para a identificação das feições, sugerindo-se, assim, seu emprego em estudos semelhantes.

As informações fornecidas pela nuvem LiDAR demonstraram a grande potencialidade desta tecnologia para incrementar o manejo das florestas urbanas. Estes dados, aliados a um levantamento de campo completo e preciso, possibilitariam a quantificação da biomassa florestal, por meio do ajuste de modelos matemáticos. Esta informação contribuiria para medir a contribuição das florestas urbanas no sequestro do dióxido de carbono das cidades. O uso de MDEs derivados do LiDAR na identificação e segmentação das copas das árvores, mostrou resultados positivos, sugerindo seu emprego em outras áreas urbanas, a fim de que se obtenha resultados semelhantes àqueles encontrados nesse trabalho.

Como considerações finais, aponta-se a necessidade de aplicar a metodologia empregada neste trabalho em imagens de altíssima resolução espectral, como as imagens hiperespectrais, para se obter valores mais acurados das curvas espectrais das espécies e, assim, melhorar a acurácia geral da classificação final. Ressalta-se a importância da realização de um levantamento de

campo completo e preciso, para que a validação dos dados remotos se aproxime o máximo possível do verificado em campo. É preciso testar diferentes intensidades de pulso de laser, para encontrar os valores que melhor retratem a realidade das cidades brasileiras. Espera-se que aos poucos a tecnologia de escaneamento a laser se torne uma realidade das prefeituras – muito embora o custo de aquisição ainda seja um impedimento real, servindo como ferramenta para auxiliar o manejo das florestas urbanas no Brasil.

REFERÊNCIAS

AARDT, J.A.N. van; WYNNE, R.H. Examining pine spectral separability using hyperspectral data from an airborne sensor: An extension of field-based results. **International Journal of Remote Sensing**, London, v. 28, n. 2, p. 431-436, January 2007.

ALONZO, M.; BOOKHAGEN, B.; ROBERTS, D.A. Urban tree species mapping using hyperspectral and lidar data fusion. **Remote Sensing of Environment**, New York, v. 148, p. 70-83, 2014.

ANDERSEN, H.-E. **Estimation of critical forest structure metrics through the special analysis of airborne laser scanner data.** 2003. 199 p. Thesis (PhD) - College of Forest Resources, University of Washington, Seattle, 2003.

ANTONARAKIS, A.S.; RICHARDS, K.S.; BRASINGTON, J. Object-based land cover classification using airborne LiDAR. **Remote Sensing of Environment**, New York, v. 112, p. 2988-2998, 2008.

ARAÚJO SILVA, A.C. **Avaliação de técnicas de restauração florestal de área dominada por *Leucaena leucocephala* (Lam.) de Wit. em Ipatinga, MG.** 2009. 86 p. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2009.

ARDILA, J.P.; BIJKER, W.; TOLPEKIN, V.A.; STEIN, A. Context-sensitive extraction of tree crown objects in urban areas using VHR satellite images. **International Journal of Applied Earth Observation and Geoinformation**, London, v. 15, p. 57-69, 2012a.

_____. Multitemporal changes detection of urban trees using localized region-based active contours in VHR images. **Remote Sensing of Environment**, New York, v. 124, p. 413-426, 2012b.

ARDILA, J.P.; TOLPEKIN, V.A.; BIJKER, W.; STEIN, A. Markov-random-field-base super-resolution mapping for identification of urban trees in VHR images. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 66, p. 762-775, 2011

ARROYO, L.A.; JOHANSEN, K.; ARMSTON, J.; PHINN, S. Integration of LiDAR and QuickBird imagery for mapping riparian biophysical parameters and land cover types in Australian tropical savannas. **Forest Ecology and Management**, Amsterdam, v. 259, p. 598-606, 2010.

ASNER, G.P.; NEPSTAD, D.; CARDINOT, G.; RAY, D. Drought stress and carbon uptake in an Amazon forest measured with spaceborne imaging spectroscopy. **Proceedings of the National Academy of Sciences**, Washington, v. 101, n. 16, p. 6039-6044, 2004.

BARBIER, N.; PROISY, C.; VÉGA, C.; SABATIER, D.; COUTERON, P. Bidirectional texture function of high resolution optical images of tropical forest: an approach using LiDAR hillshade simulations. **Remote Sensing of Environment**, New York, v. 115, p. 167-179, 2011.

BEGUET, B.; GUYON, D.; BOUKIR, S.; CHEHATA, N. Automated retrieval of forest structure variables based on multi-scale texture analysis of VHR satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 96, p. 164-178, 2014.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 65, p. 2-16, 2010.

BOSCHETTI, M.; BOSCHETTI, L.; OLIVERI, S.; CASATI, L.; CANOVA, I. Tree species mapping with airborne hyper-spectral MIVIS data: the Ticino Park study case. **International Journal of Remote Sensing**, London, v. 28, n. 6, p. 1251-1261, 2007.

BRANDTBERG, T.; WARNER, T.A.; LANDENBERGER R.E.; McGRAW, J.B. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density LiDAR data from the eastern deciduous forest in North America. **Remote Sensing of Environment**, New York, v. 85, p. 290-303, 2003.

BUDDENBAUM, H.; SCHLERF, M.; HILL, J. Classification of coniferous tree species and age classes using hyperspectral data and geostatistical methods. **International Journal of Remote Sensing**, London, v. 26, n. 24, p. 5453-5465, 2005.

CAMPBELL, J.B. **Introduction to remote sensing**. 2nd Ed. New York: The Guilford Press, 1996. 662 p.

CHATURVEDI, O.P.; JHA, A.N. Studies on allelopathic potential of an important agroforestry species. **Forest Ecology and Management**, Amsterdam, v. 53, n. 1/4, p. 91-98, Oct. 1992.

CHEN, Q.; BALDOCCHI, D.; GONG, P.; KELLY, M. Isolating individual trees in a Savanna woodland using small footprint LiDAR data. **Photogrammetric Engineering & Remote Sensing,** Bethesda, v. 72, n. 8, p. 923-932, Aug. 2006.

CHEN, X.; WANG, L.; TONG, L.; SUN, S.; YUE, X.; YIN, S.; ZHENG, L. Energy saving and emission reduction of China's urban district heating. **Energy Policy**, Oxford, v. 55, p. 677-682, 2013.

CHEN, Y.; SU, W.; LI, J.; SUN, Z. Hierarchical object oriented classification using very high resolution imagery and LiDAR data over urban areas. **Advances in Space Research**, London, v. 43, p. 1101-1110, 2009.

CHO, M.A.; MALAHLELA, O.; RAMOELO, A. Assessing the utility WorldView-2 imagery for tree species mapping in South African subtropical humid forests and the conservation implications: Dukuduku forest patch as case study. **International Journal of Applied Earth Observation and Geoinformation**, London, v. 38, p. 349-357, 2015.

CHO, M.A.; MATHIEU, R.; ASNER, G.P.; NAIDOO, L.; van AARDT, J.; RAMOELO, A.; DEBBA, P.; WESSELS, K.; MAIN, R.; SMIT, I.P.J.; ERASMUS, B. Mapping tree species composition in South African savannas using an integrated airborne spectral and LiDAR system. **Remote Sensing of Environment**, New York, v. 125, p. 214-226, 2012.

CLARCK, M.L.; CLARCK, D.B.; ROBERTS, D.A. Small-footprint lidar estimation of sub-canopy elevation and tree height in a tropical rain forest landscape. **Remote Sensing of Environment**, New York, v. 91, p. 68-89, 2004.

CLARCK, M.L.; ROBERTS, D.A.; CLARCK, D.B. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. **Remote Sensing of Environment**, New York, v. 96, p. 375-398, 2005.

CLARCK LABS. **IDRISI focus paper**. 2009. Disponível em: <http://www.clarklabs.org/applications/upload/Segmentation-IDRISI-Focus-Paper.pdf>. Acesso em: 05 abr. 2015.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data:** principles and practices. New York: Lewis Publ., 2009. 183 p.

CONWAY, T.M.; URBANI, L. Variations in municipal urban forestry policies: a case study of Toronto, Canada. **Urban Forestry & Urban Greening**, Dragger, v. 6, p. 181-192, 2007.

COSTA, J.A.; SILVA FILHO, D.F. da; POLIZEL, J.L. The use of high-resolution imaging to evaluate green areas in the city of Sao Paulo – Brazil. **Revista da Sociedade Brasileira de Arborização Urbana,** Piracicaba, v. 7, n. 1, p. 96-109, 2012.

DALPONTE, M.; BRUZZONE, L.; GIANELLE, D. Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas. **IEEE Transactions on Geoscience and Remote Sensing,** Piscataway, v. 46, n. 5, p. 1416-1427, May 2008.

DALPONTE, M.; BRUZZONE, L.; GIANELLE, D. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. **Remote Sensing of Environment**, New York, v. 123, p. 258-270, 2012.

DALPONTE, M.; ØRKA, H.O.; ENE, L.T.; GOBAKKEN, T.; NÆSSET, E. Tree crown delineation and tree species classification in boreal forests using hyperspectral and ALS data. **Remote Sensing of Environment**, New York, v. 140, p. 306-317, 2014.

DRAKE, J.B.; DUBAYAH, R.O.; CLARK, D.B.; KNOX, R.G.; BLAIR, B.; HOFTON, M.A.; CHAZDON, R.L.; WEISHAMPEL, J.F.; PRINCE, S. Estimation of tropical forest structural characteristics using large-footprint LiDAR. **Remote Sensing of Environment**, New York, v. 79, n. 2/3, p. 305-319, 2002.

DUPUY, S.; LAINÉ, G.; TASSIN, J.; SARRAILH, J-M. Characterization of the horizontal structure of the tropical forest canopy using object-based LiDAR and multispectral image analysis. **International Journal of Applied Earth Observation and Geoinformation**, London, v. 25, p. 76-86, 2013.

ERICKSON, M. Species classification of individually segmented tree crowns in high-resolution aerial images using radiometric and morphologic image measures. **Remote Sensing of Environment**, New York, v. 91, p. 469-477, 2004.

ESTORNELL, J.; RUIZ, L.A.; VELÁZQUEZ-MARTÍ, B.; FERNANDEZ-SARRÍA, A. Estimation of shrub biomass by airborne LiDAR data in small forest stands. **Forest Ecology and Management**, Amsterdam, v. 262, p. 1697-1703, 2011.

FASSNACHT, F.E.; NEUMANN, C.; FÖRSTER, M.; BUDDENBAUM, H.; GHOSH, A.; CLASEN, A.; JOSHI, P.K.; KOCH, B. Comparison of feature reduction algorithms for classifying tree species with hyperspectral data on three central european test sites. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 7, n. 6, p. 2547-2561, 2014.

FERREIRA, F. Cidades coloniais brasileiras e espanholas na América: Uma abordagem comparativa. **Seminário de História da Cidade e do Urbanismo**, São Paulo, v. 4, n. 3, p. 557-562, 1996.

FIGLIOZZI, M.A. The impacts of congestion on time-definitive urban freight distribution networks CO_2 emission levels: results from a case study in Portland, Oregon. **Transportation Research Part C**, Cologne, v. 19, p. 766-778, 2011.

GABRIEL, C.G.F. **Análise comparada de segmentação e classificação orientada por objetos de uma imagem *WORLDVIEW-2*.** 2013. 163 p. Dissertação (Mestrado em Detecção Remota e Sistema de Informação Geográfica) – Faculdade de Ciências Sociais e Humanas, Universidade Nova de Lisboa, Lisboa, 2013.

GERKE, M.; XIAO, J. Fusion of airborne laser scanning point clouds and images for supervised and unsupervised scene classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 87, p. 78-92, Jan. 2014.

GIONGO, M.; KOEHLER, H.S.; MACHADO, S.A.; KIRCHNER, F.F.; MARCHETTI, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, Colombo, v. 30, n. 63, p. 231-244, ago./out. 2010.

GONZALES, R.C.; WOODS, R.E. **Digital image processing**. 2nd ed. Upper Saddle River: Prentice Hall, 2002. 793 p.

GUO, L.; CHEHATA, N.; MALLET, C.; BOUKIR, S. Relevance of airborne LiDAR and multispectral image data for urban scene classification using random forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 66, n. 1, p. 56-66, January 2011.

HAMEDIANFAR, A.; SHAFRI, H.Z.M.; MANSOR, S.; AHMAD, N. Combining data mining algorithm and object-based image analysis for detailed urban mapping of hyperspectral images. **Journal of Applied Remote Sensing**, Bellingham, v. 8, 2014. 15p.

HERBERT, M. Keynote speech: climate changing and urban environment. In: INTERNATIONAL CONGRESS ON ENVIRONMENTAL PLANNING AND MANAGEMENT, 3., 2009, Seoul. **Proceedings…** Seoul: University of Seoul, 2009. p. 6-8.

HOLANDA, S.B. do. **Raízes do Brasil**. 26 ed. São Paulo: Companhia das Letras, 1995. 220 p.

HOLMGREN, J.; PERSSON, A. Identifying species of individual trees using airborne laser scanner. **Remote Sensing of Environment**, New York, v. 90, n. 4, p. 415-423, 2004.

HU, B.; LI, J.; JING, L.; JUDAH, A. Improving the efficiency and accuracy of individual tree crown delineation from high-density LiDAR data. **International Journal of Applied Earth Observation and Geoinformation**, London, v. 26, p. 145-155, 2014.

HUANG, B.; MENG, L. Convergence of per capta carbon dioxide emissions in urban China: a spatio-temporal perspective. **Applied Geography**, Oxford, v. 40, p. 21-29, 2013.

HUANG, Y.; YU, B.; ZHOU, J.; HU, C.; TAN, W.; HU, Z.; WU, J. Toward automatic estimation of urban green volume using airborne LiDAR data and high resolution remote sensing images. **Frontiers of Earth Science,** Beijing, v. 7, n. 1, p. 43-54, 2013.

HUDAK, A.T.; LEFSKY, M.A.; COHEN, W.B.; BERTERRETCHE, M. Integration of LiDAR and Landsat ETM+ data for estimating and mapping forest canopy height. **Remote Sensing of Environment**, New York, v. 82, n. 2/3, p. 397-416, 2002.

HYYPPÄ, J.; HYYPPÄ, H.; LECKIE, D.; GOUGEON, F.; YU, X.; MALTAMO, M. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. **International Journal of Remote Sensing**, London, v. 29, n. 5, p. 1339-1366, 2008.

IM, J.; LU, Z.; RHEE, J.; JENSEN, J.R. Fusion of feature selection and optimized immune networks for hyperspectral image classification of urban landscapes. **Geocarto International**, Hong Kong, v. 27, n. 5, p. 373-393, 2012.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual técnico da vegetação brasileira**. 2. ed. Rio de Janeiro, 2012. 271 p

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Climate change 2007:** synthesis report contribution on working group I, II and III to the four assessment report. Geneva, 2007. 104 p.

JENSEN, J.R. **Remote sensing of the environment.** An earth resource perspective. Upper Saddle River: Prentice Hall, 2000. 550 p.

JENSEN, R.R.; HARDIN, P.J.; HARDIN, A.J. Classification of urban tree species using hyperspectral imagery. **Geocarto International**, Hong Kong, v. 27, n. 5, p. 443-458, 2012.

JONES, T.G.; COOPS, N.C.; SHARMA, T. Assessing the utility of airborne hyperspectral and LiDAR data for species distribution mapping in the coastal Pacific Northwest, Canada. **Remote Sensing of Environment**, New York, v. 114, P. 2841-2852, 2010.

KARNA, Y.K.; HUSSIN, Y.A.; GILANI, H.; BRONSVELD, M.C.; MURTHY, M.S.R.; QAMER, F.M.; KARKY, B.S.; BHATTARAI, T.; AIGONG, X.; BANIYA, C.B. Integration of WorldViwe-2 and airborne LiDAR data for tree species level carbon stock mapping in Kayar Khola watershed, Nepal. **International Journal of Applied Earth Observation and Geoinformation**, London, v. 38, p. 280-291, 2015.

KE, Y.; QUACKENBUSH, L.J. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. **International Journal of Remote Sensing**, Oxford, v. 32, n. 17, p. 4725-4747, Sept. 2011.

KETTIG, R.L.; LANDGREBE, D.A. Computer classification of remotely sensed multispectral image data by extraction and classification of homogeneous objects. **IEEE Transactions on Geoscience Electronics**, New York, v. 14, n. 1, p. 19-26, 1976.

KIM, S.; MCGAUGHEY, R.J.; ANDERSEM, H.-E.; SCHREUDER, G. Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. **Remote Sensing of Environment**, New York, v. 113, n. 8, p. 1575-1586, 2009.

KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of individual tree crowns in airborne LiDAR data. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 72, n. 4, p. 357-363, Apr. 2006.

KOETZ, B.; SUN, G.; MORSDORF, F.; RANSON, K.J.; KNEUBÜHLER, M.; ITTEN, K.; ALLGÖWER, B. Fusion of imaging spectrometer and LiDAR data over combined radiative transfer models for forest canopy characterization. **Remote Sensing of Environment**, New York, v. 106, n. 4, p. 449-459, Feb. 2007.

KUO, F.E. The role of arboriculture in a healthy social ecology. **Journal of Arboriculture,** Champaign, v. 29, n. 3, p. 158-155, May 2003.

KWAK, D.-A.; LEE, W.-K.; LEE, J.-H.; BIGING, G.S.; GONG, P. Detection of individual trees and estimation of tree height using LiDAR data. **Journal of Forest Research**, Tokyo, v. 12, p. 425-434, 2007.

LAMONACA, A.; CORONA, P.; BARBATI, A. Exploring forest structural complexity by multi-scale segmentation of VHR imagery. **Remote Sensing of Environment**, New York, v. 112, p. 2839-2849, 2008.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, Raleigh, v. 33, p. 159-174, 1977.

LEEUWEN, M. van; NIEUWENHUIS, M. Retrieval of forest structural parameters using LiDAR remote sensing. **European Journal of Forest Research**, Berlin, v. 129, p. 749-770, 2010.

LEFSKY, M.A.; COHEN, W.B.; SPIES, T.A. An evaluation of alternate remote sensing products for forest inventory, monitoring, and mapping of Douglas-fir forests in western Oregon. **Canadian Journal of Forest Research**, Ottawa, v. 31, p. 78-87, 2001.

LI, W.; GUO, Q.; JAKUBOWSKI, M.K.; KELLY, M. A new method for segmenting individual trees from the LiDAR point cloud. **Photogrammetric Engineering & Remote Sensing,** Bethesda, v. 78, n. 1, p. 75-84, 2012.

LILLESAND, T.M.; KIEFER, R.W.; CHIPMAN, J.W. **Remote sensing and image interpretation**. 5th ed. Hoboken: John Wiley, 2004. 763 p.

LOMBARDO, M.A.; SILVA FILHO, D.F. da; FRUEHAUF, A.L.; PAVAN, D.C. O uso de geotecnologias na análise de ilha de calor, índice de vegetação e uso da terra. **Revista Geonorte,** Manaus, v. 2, n. 5, p. 520-529, 2012. Edição especial 2.

LU, Z.; IM, J.; RHEE, J.; HODGSON, M. Building type classification using spatial and landscape attributes derived from LiDAR remote sensing data. **Landscape and Urban Planning**, Amsterdam, v. 130, p. 134-148, 2014.

MAKIDO, Y.; DHAKAL, S.; YAMAGATA, Y. Relationship between urban form and CO_2 emissions: evidence from fifty Japanese cities. **Urban Climate**, Boston, v. 2, p. 55- 67, 2012.

MATHESON, D.S.; DENNISON, P.E. Evaluating the effects of spatial resolution on hyperspectral fire detection and temperature retrieval. **Remote Sensing of Environment**, New York, v. 124, p. 780-792, 2012.

McPHERSON, E.G. Urban forestry in North America. **Renewable Resources Journal**, Bethesda, v. 24, p. 8-12, 2006.

MENESES, P.R.; ALMEIDA, T. de. (Org.). **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB; CNPq, 2012. 266 p.

MILLER, R.W. **Urban forestry:** planning and managing urban greenspaces. 2nd ed. Englewood Cliffs: Prentice-Hall, 1996. 502 p.

MOLENAAR, M. **An introduction to the theory of spatial object modelling for GIS**. London: CRC Press, 1998. 200 p.

MOREIRA, M.A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3. Ed. Atual. Ampl. Viçosa: Editora UFV, 2005. 320 p.

NÆSSET, E.; GOBAKKEN, T.; BOLLANDSÅS, O.M.; GREGOIRE, T.G.; NELSON, R.; STÅHL, G. Comparison of precision of biomass estimates in regional field sample surveys and airborne LiDAR-assisted surveys in Hedmark County, Norway. **Remote Sensing of Environment**, New York, v. 130, p. 108-120, 2013.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. Coastal Services Center. **LiDAR 101:** an introduction to lidar technology, data, and applications. Charleston, 2012. 76 p.

NIMER, E. **Climatologia do Brasil**. Rio de Janeiro: IBGE, 1979. 422 p.

NOVO, E.M.L.M. **Sensoriamento remoto:** princípios e aplicações. 2. ed. São Paulo: Edgard Blücher, 1992. 308 p.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Fato sobre as cidades**: Rio + 20; o futuro que queremos. 2012. Disponível em: <http://www.onu.org.br/rio20/cidades.pdf>. Acesso em: 26 mar. 2013.

OSHIO, H.; ASAWA, T.; HOYANO, A.; MIYASAKA, S. Detailed reproduction of tree-dimensional crown shape and foliage distribution of trees in an urban area using high-resolution airborne LiDAR. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 32., 2012, Munich. **Proceedings…** Munich: IEEE, 2012. p. 6621-6624.

OZDEMIR, I.; DONOGHUE, D.N.M. Modelling tree size diversity from airborn laser scanning using canopy height models with image texture measures. **Forest Ecology and Management**, Amsterdam, v. 295, p. 28-37, 2013.

OZDEMIR, I.; KARNIELI, A. Predicting forest structural parameters using the image texture derived from worldview-2 multispectral imagery in a dryland forest, Israel. **International Journal of Applied Earth Observation and Geoinformation**, London, v. 13, p. 701-710, 2011.

PARENT, J.R.; VOLIN, J.C.; CIVCO, D.L. A fully-automated approach to land cover mapping with airborne LiDAR and high resolution multispectral imagery in a forested suburban landscape. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 104, p. 18-29, June 2015.

PEARLMAN, J.S.; DYK, A.; GOODENOUGH, D.; MA, Z.; CRAWFORD, M.; NEUENSCHWANDER, A.; HAM, J. Analysis of forest environments – Classification as a metric of hyperspectral instrument performance. In: IEEE WORKSHOP ON ADVANCES IN TECHNIQUES FOR ANALYSIS OF REMOTELY SENSED DATA, Greenbelt, 2003. **Anais…**Greenbelt: IEEE, 2003.

PEERBHAY, K.Y.; MUTANGA, O.; ISMAIL, R. Random forests unsupervised classification: The detection and mapping of *Solanum mauritianum* infestations in plantation forestry using hyperspectral data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 8, n. 6, p. 3107-3122, 2015.

PERSSON, A.; HOLMGREN, J.; SÖDERMAN, U. Detecting and measuring individual trees using airborne laser scanner. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 68, n. 9, p. 925-932, Sept. 2002.

PONZONI, F.J. Sensoriamento remoto no estudo da vegetação: Diagnosticando a Mata Atlântica. In: CURSO DE USO E SENSORIAMENTO REMOTO NO ESTUDO DO MEIO AMBIENTE, 5., 2002, São José dos Campos. São José dos Campos: INPE, 2002. cap. 8, p. 8-27.

PONZONI, F.J.; SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese Editora, 2009. 136 p.

POPESCU, S.C.; WYNNE, R.H. Seeing the trees in the forest: using LiDAR and multispectral data fusion with local filtering and variable window size for estimating tree hight. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 70, n. 5, p. 589-604, May 2004.

POPESCU, S.C.; WYNNE, R.H.; SCRIVANI, J.A. Level volume and biomass in deciduous and pine forests in Virginia, USA. **Forest Science**, Bethesda, v. 50, n. 4, p. 551-565, 2004.

PU, R.; LANDRY, S. A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban trees species. **Remote Sensing of Environment**, New York, v. 124, p. 516-533, 2012.

RAHMAN, M.Z.A.; GORTE, B.G.H. Tree crown delineation from high resolution airborne LiDAR based on densities of high points. In: BRETAR, F.; PIERROT-DESEILLIGNY, M.; VOSSELMAN, G. (Ed.). **IAPRS**. Paris: ISPRS, 2009. pt. 3: Laser scanning, p. 123-128.

RÄSÄNEN, A.; KUITUNEN, M.; TOMPPO, E.; LENSU, A. Coupling high-resolution satellite imagery with ALS-based canopy height model and digital elevation model in object-based boreal forest habitat type classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 94, p. 169-182, 2014.

REN, Y.; WEI, X.; WANG, D.; LUO, Y.; SONG, X.; WANG, Y.; YANG, Y. HUA, L. Linking landscape patterns with ecological functions: A case study examining the interaction between landscape heterogeneity and carbon stock of urban forest in Xiamen, China. **Forest Ecology and Management**, Amsterdam, v. 293, p. 122-131, 2013.

REUTEBUCH, S.E.; ANDERSEN, H.-E.; MCGAUGHEY, R.J. Light detection and ranging (lidar): An emerging tool for multiple resource inventory. **Journal of Forestry**, Bethesda, v. 103, n. 6, p. 286-292, Sept. 2005.

RIBAS, R.P.; ELMIRO, M.A.T. Combinação de dados altimétricos extraídos a partir da tecnologia LiDAR com imagens multiespectrais *RapidEye*. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** Curitiba: INPE,-2011. p. 5540-5545.

RICHARDS, J.A.; JIA, X. **Remote sensing digital image analysis.** An introduction. 4th Ed. Berlin: Springer-Verlag, 2006. 439 p.

ROBBA, F.; MACEDO, S.S. **Praças brasileiras**. Public squares in Brazil. 2. ed. São Paulo: Editora da Universidade de São Paulo; Imprensa Oficial do Estado de São Paulo, 2003. 311 p.

RODRIGUEZ, L.C.E.; POLIZE, J.L.; FERRAZ, S.F.B.; ZONETE, M.F.; FERREIRA, M.Z. Inventário florestal com tecnologia laser aerotransportada de plantios de *Eucalyptus spp* no Brasil. **Revista Ambiência**, Guarapuava, v. 6, p. 67-80, 2010.

ROJAS, C.; PINO, J.; BASNOU, C.; VIVANCO, M. Assessing land-use and cover changes in relation to geographic factors and urban planning in the metropolitan area of Concepción (Chile): implications for biodiversity conservation. **Applied Geography**, Oxford, v. 39, p. 93-103, 2013.

ROSSATO, D.R.; TSUBOY, M.S.F.; FREI, F. Arborização urbana na cidade de Assis-SP: uma abordagem quantitativa. **Revista da Sociedade Brasileira de Arborização Urbana,** Piracicaba, v. 3, n. 3, p. 1-16, set. 2008.

SANTANA, O.A.; ENCINAS, J.I. Levantamento das espécies exóticas arbóreas e seu impacto nas espécies nativas em áreas adjacentes a depósitos de resíduos domiciliares. **Revista Biotemas**, Florianópolis, v. 21, n. 4, p. 29-38, dez. 2008.

SANTOS, M. **A urbanização brasileira**. São Paulo: Editora da Universidade de São Paulo, 2009. 176 p.

SCHARDT, M.; ZIEGLER, M.; WIMMER, A.; WACK, R.; HYYPPÄ, J. Assessment of forest parameters by means of laser scanning. In: PHOTOGRAMMETRIC COMPUTER VISION - INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, 2002, Graz. **Proceedings…** Graz: ISPRS, 2002. p. 302-309.

SCHERER, L.M.; ZUCARELI, V.; ZUCARELI, C.A.; FORTES, A.M.T. Efeito alelopático do extrato aquoso de folha e de fruto de leucena (*Leucaena leucocephala* Wit) sobre a germinação e crescimento de raiz de canafístula (*Peltophorum dubium* Spreng.). **Semina: Ciências Agrárias**, Londrina, v. 26, n. 2, p. 161-166, abr./jun. 2005.

SCHOWENGERDT, R.A. **Remote sensing: Models and methods for image processing**. 3rd Ed. Burlington: Academic Press, 2007. 560 p.

SEAMANS, G.S. Main streaming the environmental benefits of street trees. **Urban Forestry & Urban Greening**, Dragger, v. 12, p. 2-11, 2013.

SEBARI, I.; HE, D-C. Automatic fuzzy object-based analysis of VHSR images for urban objects extraction. **ISPRS Journal of Photogrammetry and Remote Sensing**, London, v. 79, p. 1717-184, 2013.

SERWAY, R.A.; JEWETT Jr.; J.W. **Princípios de física**. Óptica e física moderna. Vol. 4. São Paulo: Cengage Learning, 2015. 342 p.

SHRESTHA, R.; WYNNE, R.H. Estimating biophysical parameters of individual trees in an urban environment using small footprint discrete-return imaging LiDAR. **Remote Sensing**, Basel, v. 4, p. 484-508, 2012.

SILVA FILHO, D.F. da; PIZZETA, P.U.C.; DE ALMEIDA, J.B.S.A.; PIVETTA, K.F.L.; FERRAUDO, A.S. Banco de dados relacional para cadastro, avaliação e manejo da arborização em vias públicas. **Revista Árvore**, Viçosa, v. 26, n. 5, p. 629-642, 2002.

SILVA, J.B.; PASQUALETTO, A. O caminho dos parques urbanos brasileiros: Da origem ao século XXI. **Estudos**, Goiânia, v. 40, n. 3, p. 287-298, 2013.

SIMIO, L. De; GAMBINO, M.; IANNACCONE, S. Possible transport energy sources for the future. **Transport Policy**, Victoria, v. 27, p. 1-10, 2013.

SONG, C.; WOODCOCK, C.E. Estimating tree crown size from multiresolution remotely sensed imagery. **Photogrammetry Engineering & Remote Sensing**, Bethesda, v. 69, n. 11, p. 1263-1270, 2003.

STRAUB, B-M. A top-down operator for the automatic extraction of trees – concept and performance evaluation. In: INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING. **3-D reconstruction from airborne laser scanner and InSAR data.** Dresden: ISPRS, 2003. 6 p.

SUÁREZ, J.C.; ONTIVEROS, C.; SMITH, S.; SNAPE, S. Use of airborne LiDAR and aerial photography in the estimation of individual tree height in forestry. **Computers & Geosciences**, London, v. 31, p. 253-262, 2005.

SWAMER, M. **Extraction of tree crowns and heights using lidar**. 2012. Disponível em: < http://web.pdx.edu/~jduh/courses/geog493f12/Projects/SwamerHouser.pdf>. Acesso em: 19 out. 2015.

THOMPSON, C.W.; ROE, J.; ASPINALL, P. Woodland improvements in deprived urban communities: what impact do they have on people's activities and quality of life? **Landscape and Urban Planning**, Amsterdam, v. 118, p. 79-89, 2013. Disponível em: <http://dx.doi.org/10.1016/j.landurbplan.2013.02.001>. Acesso em: 03 abr. 2013.

TIAN, X.; SU, Z.; CHEN, E.; LI, Z.; van der TOL, C.; GUO, J.; HE, Q. Estimation of forest above-ground biomass using multi-parameter remote sensing data over a cold and arid area**. International Journal of Applied Earth Observation and Geoinformation**, New York, v. 14, p. 160-168, 2012.

TIEDE, D.; HOCHLEITNER, G.; BLASCHKE, T. A full Gis-based workflow for tree identification and tree crown delineation using laser scanning. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY. **Remote sensing and spatial information sciences.** Vienna: ISPRS, 2005. pt. 3, p. 9-14.

TREITZ, P.M.; HOWARTH, P.J. Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems. **Progress in Physical Geography**, London, v. 23, n. 3, p. 359-390, 1999.

UNITED NATIONS POPULATION FUND. **Linking population, poverty and development.** 2007. Disponível em: <http://www.unfpa.org/pds/urbanization.htm>. Acesso em: 26 mar. 2013.

UNITED STATES GEOLOGICAL SURVEY. **Landsat 8 history**. 2014. Disponível em: < http://landsat.usgs.gov/about_ldcm.php>. Acesso em: 05 out. 2015.

XIAO, Q.; USTIN, L.; McPHERSON, E.G. Using AVIRIS data and multiple-masking techniques to map urban forest tree species. **International Journal of Remote Sensing**, London, v. 25, n. 24, p. 5637-5654, Dec. 2004.

YAN, W.Y.; SHAKER, A.; EL-ASHMAWY, N. Urban land cover classification using airborne LiDAR data: a review. **Remote Sensing of Environment**, New York, v. 158, n. 1, p. 295-310, Mar. 2015.

YIN, J.; WONG, S.C.; SZE, N.N.; HO, H.W. A continuum model for housing allocation and transportation emission problems in a polycentric city. **International Journal of Sustainable Transportation**, Geneva, v. 7, n. 4, p. 275-298, 2013.

ZAWILA-NIEDZWIECKI, T.; STERENCZAK, K.; BALAZY, R.; WENCEL, A; STRZELINSKI, P.; ZASADA, M. The use of terrestrial and airborne LiDAR technology in forest inventory. **Revista Ambiência**, Guarapuava, v. 4, p. 57-68, 2008.

ZHANG, C.; QIU, F. Mapping individual tree species in a urban forest using airborne LiDAR data and hyperspectral imagery. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 78, n. 10, p. 1079-1087, Oct. 2012a.

_____. Hyperspectral image classification using an unsupervised neuro-fuzzy system. **Journal of Applied Remote Sensing**, Bellingham, v. 6, n. 1, p. 1-14, Apr. 2012b.

ZHAO, K.; POPESCU, S.; NELSON, R. Lidar remote sense of forest biomass: A scale-invariant estimation approach using airborne lasers. **Remote Sensing of Environment**, New York, v. 113, n. 1, p. 182-196, 2009.

ZHAO, K.; POPESCU, S.; MENG, X.; PANG, Y.; AGCA, M. Characterizing forest canopy structure with LiDAR composite metrics and machine learning. **Remote Sensing of Environment,** New York, v. 115, p. 1978-1996, 2011.

ZHOU, J.; PROISY, C.; DESCOMBES, X.; HEDHLI, I.; BARBIER, N.; ZERUBIA, J.; GASTELLU-ETCHEGORRY, J.P.; COUTERON, P. Tree crown Detection in high resolution optical and LiDAR images of tropical forest. In: NEALE, C.M.U.; MALTESE, A. (Ed.). **Remote sensing for agriculture, ecosystems and hydrology XII**. Bellingham: SPIE, 2010. 6 p. (SPIE Proceedings, 7824).

ZIMBLE, D.A.; EVANS, D.L.; CARLSON, G.C.; PARKER, R.C.; GRADO, S.C.; GERARD, P.D. Characterizing vertical forest structure using small-footprint airborne LiDAR. **Remote Sensing of Environment**, New York, v. 87, n. 2/3, p. 171-182, 2003.

ANEXOS

Anexo A – Lista de espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti em Belo Horizonte, MG. As espécies foram divididas em Número de identificação, Nome popular, Nome científico, Quantidade, Tipo, Origem e País/Região

(continua)

NÚMERO DE IDENTIFICAÇÃO	NOME POPULAR	NOME CIENTÍFICO	QUANTIDADE	TIPO	ORIGEM	PAÍS/REGIÃO
199	Palmeira	?	1	Palmeira	?	
239	Bordo Vermelho	*Acer rubrum*	1	Árvore	Exótico	América do Norte
137	Sapoti	*Achras sapota*	1	Árvore	Exótico	América Central
96	Macaúba	*Acrocomia aculeata*	70	Palmeira	Nativo	NL
189	Tento Carolina	*Adenanthera pavonina*	1	Árvore	Exótico	Ásia
204	Pinheiro Kauri	*Agathis robusta*	3	Árvore	Exótico	Oceania
62	Farinha Seca	*Albizia niopoides*	1	Árvore	Nativo	NL
110	Nogueira-de-Iguape	*Aleurites moluccana*	7	Árvore	Exótico	Sudeste asiático
16	Angico	*Anadenanthera sp.*	5	Árvore	Nativo	?
18	Araticum	*Annona coriacea*	4	Árvore	Nativo	NL
120	Pau Jangada	*Apeiba tibourbou*	2	Árvore	Nativo	NL
19	Araucária	*Araucaria angustifolia*	6	Árvore	Nativo	EL
21	Árvore de Natal	*Araucaria columnaris*	12	Árvore	Exótico	Ilhas Cook
116	Palmeira Real	*Archontophoenix cunninghamiana*	96	Palmeira	Exótico	Austrália
184	Seafortia	*Archontophoenix cunninghamii*	5	Palmeira	Exótico	Austrália
90	Jaqueira	*Artocarpus heterophyllus*	34	Árvore	Exótico	Sudeste asiático
129	Peroba Rosa	*Aspidosperma polyneuron*	2	Árvore	Nativo	NL
127	Peroba	*Aspidosperma sp.*	1	Árvore	Nativo	NL
36	Carambola	*Averrhoa carambola*	6	Árvore	Exótico	Sudeste asiático
148	Unha de Vaca	*Bauhinia variegata*	7	Árvore	Exótico	Índia e Sudeste asiático
115	Paineira Vermelha	*Bombax malabaricum*	3	Árvore	Exótico	Sudeste asiático
179	Sucupira Preta	*Bowdichia virgilioides*	2	Árvore	Nativo	NL
118	Pau-Brasil	*Caesalpinia echinata*	39	Árvore	Nativo	EL
121	Pau Ferro	*Caesalpinia ferrea*	14	Árvore	Nativo	EL
141	Sibipiruna	*Caesalpinia pluviosa var.peltophoroides*	14	Árvore	Nativo	EL
61	Escova de Garrafa	*Callistemon sp.*	8	Árvore	Exótico	Austrália
123	Pau Mulato	*Calycophyllum spruceanum*	7	Árvore	Nativo	EL
93	Jequitibá	*Cariniana sp.*	2	Árvore	Nativo	NL
37	Cariota	*Caryota urens*	121	Palmeira	Exótico	Sudeste asiático
41	Cássia Chuva-de-Ouro	*Cássia ferruginea*	30	Árvore	Nativo	NL
42	Cássia Imperial	*Cássia fistula*	4	Árvore	Exótico	Índia e Sudeste asiático
40	Cássia	*Cassia sp.*	11	Árvore	?	
43	Cássia Rosa	*Cassia grandis*	16	Árvore	Exótico	América Central
45	Castanheira	*Castanea sativa*	40	Árvore	Exótico	Península Ibérica
46	Casuarina	*Casuarina equisetifolia*	17	Árvore	Exótico	Sudeste asiático e oceania
56	Embaúba	*Cecropia sp.*	39	Árvore	Nativo	NL
48	Cedro Rosa	*Cedrela fissilis*	22	Árvore	Nativo	NL
114	Paineira	*Ceiba speciosa*	82	Árvore	Nativo	NL
124	Cássia Pau Preto	*Cenostigma tocantinum*	1	Árvore	Nativo	EL
17	Araribá	*Centrolobium tomentosum*	10	Árvore	Nativo	NL
225	Mexerica	*Citrus reticulata*	1	Árvore	Exótico	Ásia
169	Limão	*Citrus sp.*	1	Árvore	Exótico	Ásia

Anexo A – Lista de espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti em Belo Horizonte, MG. As espécies foram divididas em Número de identificação, Nome popular, Nome científico, Quantidade, Tipo, Origem e País/Região

(continuação)

NÚMERO DE IDENTIFICAÇÃO	NOME POPULAR	NOME CIENTÍFICO	QUANTIDADE	TIPO	ORIGEM	PAÍS/REGIÃO
126	Pau-D'Óleo	*Copaifera langdsdorffii*	4	Árvore	Nativo	NL
52	Córdia	*Cordia sp.*	12	Árvore	Nativo	NL
166	Louro Pardo	*Cordia trichotoma*	3	Árvore	Nativo	NL
3	Abricó de Macaco	*Couroupita guianensis*	5	Árvore	Nativo	EL
32	Camboatá	*Cupania vernalis*	4	Árvore	Nativo	NL
49	Cipreste	*Cupressus sp.*	10	Árvore	Exótico	Europa
230	Ipê Verde	*Cybistax antisyphilitica*	3	Árvore	Nativo	NL
185	Jacarandá Branco	*Dalbergia brasiliensis*	1	Árvore	Nativo	EL
151	Jacarandá Preto	*Dalbergia nigra*	2	Árvore	Nativo	NL
82	Jacarandá do Amazonas	*Dalbergia spruceana*	2	Árvore	Nativo	EL
69	Flamboyant	*Delonix regia*	40	Árvore	Exótico	Índia e Sudeste asiático
156	Maria Mole	*Dendropanax cuneatus*	12	Árvore	Nativo	NL
167	Flor de Abril	*Dillenia indica*	9	Árvore	Exótico	Índia e Sudeste asiático
181	Caqui Chocolate	*Diospyros kaki*	3	Árvore	Exótico	Japão
201	Cumaru	*Dipteryx sp.*	3	Árvore	Nativo	?
23	Astrapéia Rosa	*Dombeya wallichii*	1	Árvore	Exótico	Índia e Sudeste asiático
20	Areca Bambu	*Dypsis lutescens*	145	Palmeira	Exótico	África e Madagascar
205	Azeitona do Ceilão	*Elaeocarpus serratus*	1	Árvore	Exótico	Índia e Sudeste asiático
53	Corticeira	*Erythrina crista - galli*	3	Árvore	Nativo	NL
164	Suinã	*Erythrina velutina*	3	Árvore	Nativo	NL
60	Eucalipto Argentino	*Eucalyptus cinerea*	7	Árvore	Exótico	Austrália
59	Eucalipto	*Eucalyptus sp.*	48	Árvore	Exótico	Austrália
158	Grumixama	*Eugenia brasiliensis*	3	Árvore	Nativo	NL
177	Guamirim	*Eugenia florida*	10	Árvore	Nativo	NL
157	Cereja do Mato	*Eugenia involucrata*	2	Árvore	Nativo	NL
132	Pitangueira	*Eugenia uniflora*	7	Árvore	Nativo	EL
117	Palmito Doce	*Euterpe edulis*	18	Palmeira	Nativo	EL
64	Ficus Benjamina	*Ficus benjamina*	43	Árvore	Exótico	Ásia
190	Ficus Guapoí	*Ficus citrifolia*	4	Árvore	Nativo	Américas
66	Ficus Italiano	*Ficus elastica*	11	Árvore	Exótico	Índia e Sudeste asiático
11	Belaque	*Ficus lutea*	14	Árvore	Exótico	África
191	Figueira de Mexia	*Ficus petiolaris?*	2	Árvore	Exótico	México
64	Gameleira	*Ficus sp.*	18	Árvore	Nativo	?
170	Ficus	*Ficus sp.*	9	Árvore	Exótico	Ásia
119	Pau D'Alho	*Gallesia integrifolia*	1	Árvore	Nativo	EL
92	Jenipapo	*Genipa americana*	8	Árvore	Nativo	EL
209	Mãe do Cacau	*Gliricidia sepium*	7	Árvore	Exótico	América Central
161	Grevílea Anã	*Grevillea banksii*	6	Árvore	Exótico	Austrália
71	Grevílea	*Grevillea robusta*	3	Árvore	Exótico	Austrália
192	Guaré	*Guarea guidonia*	3	Árvore	Nativo	NL
79	Ipê Rosa	*Handroanthus heptaphyllus*	12	Árvore	Nativo	NL

Anexo A – Lista de espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti em Belo Horizonte, MG. As espécies foram divididas em Número de identificação, Nome popular, Nome científico, Quantidade, Tipo, Origem e País/Região

(continuação)

NÚMERO DE IDENTIFICAÇÃO	NOME POPULAR	NOME CIENTÍFICO	QUANTIDADE	TIPO	ORIGEM	PAÍS/REGIÃO
80	Ipê Roxo	*Handroanthus impetiginosus*	41	Árvore	Nativo	NL
176	Ipê Amarelo do Cerrado	*Handroanthus ochraceus*	1	Árvore	Nativo	NL
77	Ipê Branco	*Handroanthus roseo-albus*	12	Árvore	Nativo	NL
75	Ipê Amarelo	*Handroanthus serratifolius*	33	Árvore	Nativo	NL
78	Ipê Cascudo	*Handroanthus vellosoi*	1	Árvore	Nativo	NL
139	Seringueira	*Hevea brasiliensis ou Ficus elastica*	5	Árvore	?	
12	Algodoeiro-da-Praia	*Hibiscus tiliaceus*	3	Árvore	Exótico	Índia e Sudeste asiático
9	Alecrim de Campinas	*Holocalyx balansae*	9	Árvore	Nativo	NL
4	Assacu	*Hura crepitans*	10	Árvore	Nativo	Amazônia
91	Jatobá	*Hymenaea courbaril*	20	Árvore	Nativo	NL
74	Ingá	*Inga sp.*	1	Árvore	Nativo	?
85	Jacarandá Mimoso	*Jacaranda mimosifolia*	35	Árvore	Exótico	América do Sul
203	Jacarandá	*Jacaranda sp.*	8	Árvore	?	
54	Cutieira	*Joannesia princeps*	21	Árvore	Nativo	NL
109	Nogueira	*Juglans regia*	3	Árvore	Exótico	Ásia
102	Mirindiba	*Lafoensia glyptocarpa*	10	Árvore	Nativo	NL
165	Resedá	*Lagerstroemia indica*	28	Árvore	Exótico	Índia e Sudeste asiático
94	Latânia	*Latania sp.*	159	Palmeira	Exótico	
261	Louro	*Laurus nobilis*	1	Árvore	Exótico	Mediterrâneo
138	Sapucaia	*Lecythis pisonis*	34	Árvore	Nativo	NL
112	Oiti	*Licania tomentosa*	20	Árvore	Nativo	EL
103	Palmeira Leque	*Licuala grandis*	9	Palmeira	Exótico	Vanuatu
95	Ligustro	*Ligustrum lucidum*	62	Árvore	Exótico	China/Japão
5	Açoita Cavalo	*Luehea divaricata*	2	Árvore	Nativo	NL
84	Jacarandá de Espinho	*Machaerium aculeatum*	11	Árvore	Nativo	NL
174	Jacarandá do Campo	*Machaerium acutifolium*	4	Árvore	Nativo	NL
100	Mangueira	*Mangifera indica*	23	Árvore	Exótico	Índia e Sudeste asiático
146	Buriti	*Mauritia flexuosa*	1	Palmeira	Nativo	NL
97	Magnólia Amarela	*Michelia champaca*	28	Árvore	Exótico	Índia e Sudeste asiático
15	Amoreira Negra	*Morus nigra*	41	Árvore	Exótico	Sudeste Asiático
247	Calabura	*Muntingia calabura*	2	Árvore	Exótico	América Central
107	Murta	*Murraya paniculata*	57	Árvore	Exótico	Índia e Sudeste asiático
173	Myrcia	*Myrcia sp.*	4	Árvore	?	
81	Jabuticabeira	*Myrciaria cauliflora*	5	Árvore	Nativo	NL
194	Espirradeira	*Nerium oleander*	1	Árvore	Exótico	Sudeste Asiático
263	Canela de Cheiro	*Ocotea longifolia*	1	Árvore	Exótico	Índia e Sudeste asiático
35	Canela Loura	*Ocotea porosa*	10	Árvore	Nativo	EL
33	Canela	*Ocotea sp.*	3	Árvore	?	
44	Monguba	*Pachira aquatica*	16	Árvore	Nativo	EL
218	Pandano	*Pandanus utilis*	1	Árvore	Exótico	Madagascar

Anexo A – Lista de espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti em Belo Horizonte, MG. As espécies foram divididas em Número de identificação, Nome popular, Nome científico, Quantidade, Tipo, Origem e País/Região

(continuação)

NÚMERO DE IDENTIFICAÇÃO	NOME POPULAR	NOME CIENTÍFICO	QUANTIDADE	TIPO	ORIGEM	PAÍS/REGIÃO
240	Angico Vermelho	*Parapiptadenia rigida*	2	Árvore	Nativo	EL
188	Kiri	*Paulownia imperialis*	10	Árvore	Exótico	Ásia
1	Abacateiro	*Persea americana*	4	Árvore	Exótico	América Central
144	Tamareira	*Phoenix dactylifera*	70	Palmeira	Exótico	Oriente Médio/Iraque
211	Palmeira Phoenix	*Phoenix roebelenii*	7	Palmeira	Exótico	Sudeste Asiático
131	Pinheiro Americano	*Pinus elliottii*	6	Árvore	Exótico	América do Norte
160	Jasmim-manga	*Plumeria rubra*	18	Árvore	Exótico	América Central
2	Abiu Piloso	*Pouteria torta*	4	Árvore	Nativo	NL
13	Ameixeira	*Prunus sp.*	7	Árvore	Exótico	Ásia
70	Goiabeira	*Psidium guajava*	17	Árvore	Nativo	NL
125	Pau Rei	*Pterigota brasiliensis*	23	Árvore	Nativo	EL
8	Aldrago	*Pterocarpus violaceus*	9	Árvore	Nativo	NL
264	Romã	*Punica granatum*	1	Árvore	Exótico	Ásia/Oriente Médio
142	Sobreiro	*Quercus suber*	5	Árvore	Exótico	Península Ibérica
258	Charão	*Rhus succedanea*	2	Árvore	Exótico	Ásia
154	Palmeira Imperial	*Roystonea oleracea*	37	Palmeira	Exótico	América Central
140	Sete Cascas	*Samanea tubulosa*	2	Árvore	Nativo	EL
136	Saboneteira	*Sapindus saponaria*	25	Árvore	Nativo	EL
262	Aroeira Salsa	*Schinus molle*	3	Árvore	Nativo	EL
72	Guapuruvu	*Schizolobium parahyba*	30	Árvore	Nativo	EL
63	Fedegoso	*Senna macranthera*	2	Árvore	Nativo	NL
266	Cássia Siâmica	*Senna siamea*	2	Árvore	Exótico	Sudeste Asiático
58	Espatódea	*Spathodea campanulata*	86	Árvore	Exótico	África
38	Cajá Mirim	*Spondias mombin*	6	Árvore	Nativo	EL
245	Chichá	*Sterculia chicha*	1	Árvore	Nativo	EL
104	Mogno	*Swietenia macrophylla*	12	Árvore	Nativo	EL
182	Guariroba	*Syagrus oleracea*	5	Palmeira	Nativo	NL
51	Jerivá	*Syagrus romanzoffiana*	348	Palmeira	Nativo	NL
87	Jalão	*Syzygium cumini*	68	Árvore	Exótico	Índia e Sudeste asiático
88	Jambo Amarelo	*Syzygium jambos*	5	Árvore	Exótico	Índia e Sudeste asiático
89	Jambo Vermelho	*Syzygium malaccense*	6	Árvore	Exótico	Polinésia
50	Cipreste Calvo	*Taxodium mucronatum*	1	Árvore	Exótico	América do Norte
75	Ipê Mirim	*Tecoma stans*	19	Árvore	Exótico	Austrália
134	Quaresmeira Roxa	*Tibouchina granulosa*	33	Árvore	Nativo	NL
99	Manacá da Serra	*Tibouchina mutabilis*	4	Árvore	Nativo	EL
147	Tipuana	*Tipuana tipu*	4	Árvore	Exótico	América Central
111	Novateiro	*Triplaris americana*	19	Árvore	Nativo	EL
38	Acácia Amarela	*Vachellia farnesiana*	2	Árvore	Exótico	América Central
241	Azeitona do Mato	*Vitex montevidensis*	1	Árvore	Nativo	NL
98	Mamica de Cadela	*Zanthoxylum rhoifolium*	9	Árvore	Nativo	NL

Anexo A – Lista de espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti em Belo Horizonte, MG. As espécies foram divididas em Número de identificação, Nome popular, Nome científico, Quantidade, Tipo, Origem e País/Região

(conclusão)

NÚMERO DE IDENTIFICAÇÃO	NOME POPULAR	NOME CIENTÍFICO	QUANTIDADE	TIPO	ORIGEM	PAÍS/REGIÃO
232	Mamica de Porca	*Zanthoxylum riedelianum*	2	Árvore	Nativo	NL
TOTAL			**2904**			

Legenda: ? - Desconhecido; NL - nativo local; EL - exótico local

Anexo B – Lista de frequência das espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti.

(continua)

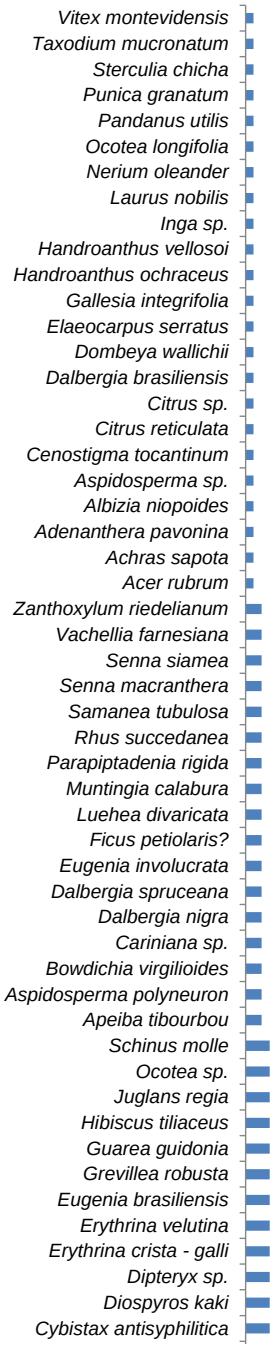

Anexo B – Lista de frequência das espécies arbóreas encontradas no Parque Municipal Américo Renné Giannetti.
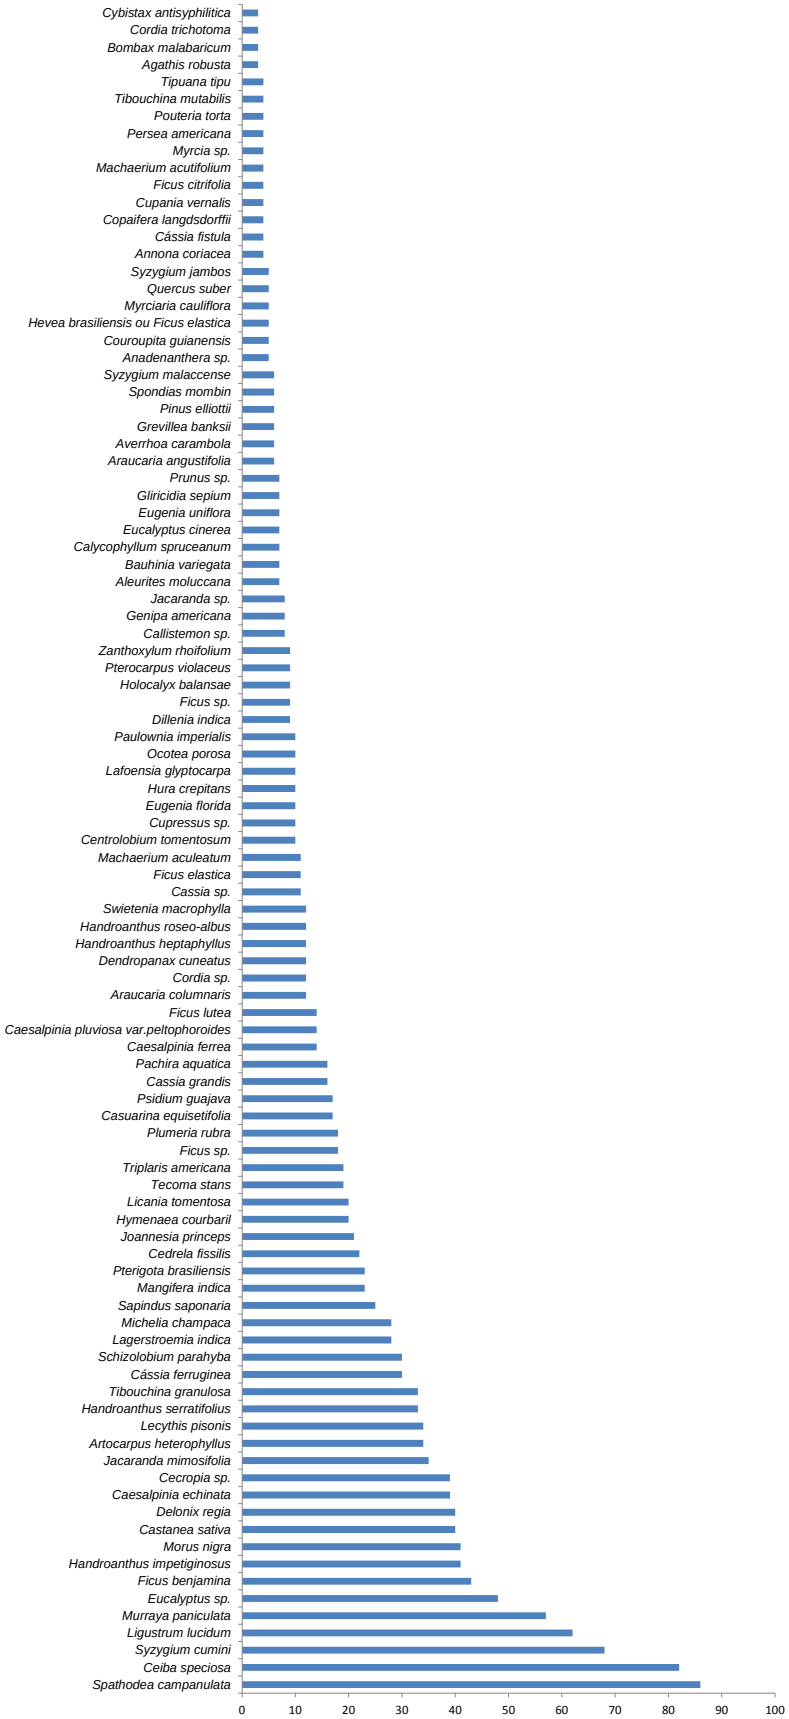
(conclusão)