

Universidade Federal de Minas Gerais  
Instituto de Geociências  
Departamento de Geografia

Marília Ferreira Gomes

**DETECÇÃO DE COPAS DE ÁRVORES EM  
IMAGENS DE ALTA RESOLUÇÃO ESPACIAL**

Belo Horizonte  
2016

Marília Ferreira Gomes

# **Detecção de Copas de Árvores em Imagens de Alta Resolução Espacial**

Tese apresentada ao Programa de Pós-Graduação do Departamento de Geografia da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Geografia.

Área de Concentração: Análise Ambiental

Linha de Pesquisa: Geografia aplicada e geotecnologias

Orientador: Prof. Dr. Philippe Maillard

Belo Horizonte

2016

G633d Gomes, Marília Ferreira.  
2016 Detecção de copas de árvores em imagens de alta resolução espacial  
[manuscrito] / Marília Ferreira Gomes. – 2016.  
vii, 227 f., enc.: il. (principalmente color.)

Orientador: Philippe Maillard.  
Tese (doutorado) – Universidade Federal de Minas Gerais,  
Departamento de Geografia, 2016.

Área de concentração: Análise Ambiental.

Inclui bibliografias.

Inclui apêndices.

1. Sensoriamento remoto – Teses. 2. Geoprocessamento – Teses. 3.  
Processamento de imagens – Técnicas digitais – Teses. 4. Árvores –  
Teses. I. Maillard, Philippe. II. Universidade Federal de Minas Gerais.  
Departamento de Geografia. III. Título.

CDU: 528.8



## ATA DA DEFESA DE TESE DA ALUNA MARILIA FERREIRA GOMES

Realizou-se, no dia 14 de dezembro de 2016, às 14:00 horas, Auditório, da Universidade Federal de Minas Gerais, a defesa de tese, intitulada *Detecção de árvores em imagens de alta resolução espacial.*, apresentada por MARILIA FERREIRA GOMES, número de registro 2012662530, graduada no curso de GEOGRAFIA/DIURNO, como requisito parcial para a obtenção do grau de Doutor em GEOGRAFIA, à seguinte Comissão Examinadora: Prof(a). Philippe Maillard - Orientador (Universidade Federal de Minas Gerais), Prof(a). Rodrigo Affonso de Albuquerque Nobrega (UFMG), Prof(a). Jefersson Alex dos Santos (Universidade Federal de Minas Gerais), Prof(a). José Alberto Quintanilha (Universidade de São Paulo), Prof(a). Yosio Edemir Shimabukuro (Instituto Nacional de Pesquisas Espaciais).

A Comissão considerou a tese:

- Aprovada  
 Aprovada condicionalmente, sujeita a alterações conforme folha de modificações anexa  
 Reprovada

Finalizados os trabalhos, lavrei a presente ata que, lida e aprovada, vai assinada por mim e pelos membros da Comissão.

Belo Horizonte, 14 de dezembro de 2016.

Prof(a). Philippe Maillard ( Doutor )

Prof(a). Rodrigo Affonso de Albuquerque Nobrega ( Doutor )

Prof(a). Jefersson Alex dos Santos ( Doutor )

Prof(a). José Alberto Quintanilha ( Doutor )

Prof(a). Yosio Edemir Shimabukuro ( Doutor )

À minha mãe, dedico.

# Agradecimentos

Agradeço pela oportunidade de recomeço, pela vida, pela saúde, pelo amor, pela alegria, pela família, pelas amizades.

Ao Instituto Nacional de Colonização e Reforma Agrária (INCRA) e ao Governo Federal do Brasil pela oportunidade concedida para capacitação em nível de doutorado.

Ao meu orientador, Prof. Dr. Philippe Maillard, pela orientação, por sua competência e dedicação, que sempre me serviu de referencial, por acreditar em meu trabalho e por sua amizade.

À minha família, que sempre me apoia e que está presente nos momentos felizes ou de dificuldades. Agradeço ao meu pai, às minhas irmãs, aos meus primos e às minhas amadas tias. Agradecimento especial à minha mãe, que teria uma alegria imensa com esta conquista.

Aos meus companheiros do laboratório de Sensoriamento Remoto do IGC/UFMG, Eric, Leo, Lilia, Luiza e Evelyn. Agradeço pela amizade, pela troca de ideias, que são oportunidades de aprendizado, e pelos ouvidos, sempre amigos.

Aos meus amigos, que perto ou longe, estão sempre juntos. Existe uma citação que diz que “quem achou um amigo, descobriu um tesouro”. Vocês são os meus tesouros: Itamar, Leonardo, Hulda, Clênia, José Marcelo, Tom, Junio e Quinto. Agradeço especialmente à minha amiga-irmã Conceição, que tanto me auxiliou nas revisões do texto.

Aos professores que, gentilmente, aceitaram participar da minha banca, trazendo valiosas sugestões que auxiliaram a elevar a qualidade do meu trabalho.

À Empresa de Informática e Informação do Município de Belo Horizonte (Prodabel), que gentilmente cedeu os dados do aerolevante realizado no ano de 2008, os quais não foram diretamente utilizados neste trabalho, mas serviram para os primeiros experimentos.

Aos professores e funcionários do IGC/UFMG, que contribuíram com a minha formação, seja através de disciplinas ministradas, de suas sugestões ou da manutenção das condições mínimas para a execução desta pesquisa.

*Digo: o real não está na saída nem na chegada:  
ele se dispõe para a gente é no meio da travessia.*

João Guimarães Rosa

# Resumo

A necessidade de conhecimento sobre a vegetação levou pesquisadores a desenvolverem métodos para fornecer informações detalhadas sobre as árvores. Tradicionalmente, essas informações são obtidas a partir de inventários florestais, que é um procedimento caro, demorado e que não recobre grandes áreas. Desde 1999, o sensoriamento remoto orbital tem fornecido imagens de alta resolução espacial (*very high resolution* - VHR) que permitem a identificação das copas de árvores, individualmente. O aumento na resolução espacial teve um efeito profundo nas técnicas de processamento de imagens e motivou o desenvolvimento de novos procedimentos baseados em objetos para extração dessas informações. A detecção automática de copas de árvores se tornou uma importante área de pesquisa em análise de imagens. No entanto, a maior parte das pesquisas para detecção automática de copas de árvores individuais foi desenvolvida para vegetação situada em florestas de clima temperado. Com base na lacuna existente nessa área do conhecimento, esta tese foi focada no desenvolvimento de um método de detecção automática de árvores individuais para identificar e segmentar as árvores como um único objeto. O método proposto, denominado PPM-TM, integra modelagem ótica geométrica tridimensional (3D), processos pontuais marcados (PPM) e modelo de correspondência (*template matching* ou TM) para detectar as árvores e fornecer um delineamento simplificado de suas copas, a partir de imagens VHR. O algoritmo se baseia na utilização de uma métrica flexível, que permite a detecção das árvores mesmo nos casos em que elas não possuam alta similaridade com o modelo 3D, e de funções de limiares espectrais e intervalos de textura de primeira ordem no processo de decisão para inclusão dos objetos como copas de árvores. Fases de nascimento e de morte são alternadas, nas quais os objetos são criados e destruídos, quando eles não atendem aos critérios estabelecidos para ser uma árvore. Aprimoramentos foram acrescentados permitindo o refinamento do resultado, que incluem a redefinição do diâmetro e a realocação precisa do centro da copa. O PPM-TM foi testado em diversos ambientes de árvores fora de florestas (*trees outside forests* - TOF), especificamente em áreas urbanas, pomares, cerrado *sensu stricto* e em remanescentes de mata seca. A acurácia média da detecção das árvores foi de 91,9% e de 67,61% para o delineamento de suas copas, com melhores resultados para árvores isoladas.

Palavras-chave: Detecção de copas de árvores individuais. Imagens de alta resolução espacial. Processos pontuais marcados. Template matching. Árvores fora de florestas. Sensoriamento remoto. Processamento digital de imagens.



# Abstract

The requirements for advanced knowledge on forest resources have led researchers to develop efficient methods to provide detailed information about trees. Traditionally, this information is obtained from forest inventories, which are expensive and time-consuming procedures that do not usually cover large areas. Since 1999, orbital remote sensing has been providing very high resolution (VHR) image data, which allows the identification of individual tree crowns. The increase in spatial resolution has had a profound effect in image processing techniques and has motivated the development of new object-based procedures to extract information. Tree crown detection has become a major area of research in image analysis considering the complex nature of trees in an uncontrolled environment. However, most of the research for automatic detection of individual tree crowns has been developed for temperate forests. Considering this lag, this thesis undertook the task of developing an automatic method to detect individual tree crowns that is adaptable to different environments and capable of delineating their crown as single objects. The approach, named PPM-TM, integrates geometrical-optical modeling, marked point processes (MPP), and template matching (TM) to individually detect and provide a simplified delineation of tree crowns in VHR images. The algorithm is based on the use of an adaptive metric, which allows the detection of trees, even if they do not have high similarity with the 3D model. It also incorporates functions of spectral thresholds and first-order texture to aid the decision process in the inclusion of objects as individual tree crowns. Phases of birth and death are alternated, in which objects are created and destroyed if they do not meet the criteria determined to be recognized as a tree. A series of post-processing refinements was also incorporated including the redefinition of the tree crown diameter and the relocating of the tree crown center. The PPM-TM was tested in different tree outside environments (TOF) as urban environments, orchards and in natural vegetation of savanna (*cerrado sensu stricto*) and deciduous tropical forest (*mata seca*). The mean accuracy of detection was 91.9% and the mean accuracy of the delineation was 67.61%, with best results for isolated trees.

Keywords: Individual tree crown detection. High-resolution satellite imagery. Marked point processes. Template matching. Trees outside forests. Remote sensing. Digital image processing.

# Résumé

La nécessité d'obtenir des connaissances détaillées sur les forêts a amené les chercheurs à développer des méthodes propres à fournir ces informations sur les arbres. Traditionnellement, ce niveau d'information est obtenu par des inventaires qui sont coûteux et longs et qui ne recouvrent que de petites zones. Depuis 1999, la télédétection orbitale fournit des images de très haute résolution spatiale (very high resolution - VHR) qui permettent l'identification des couronnes d'arbres individuellement. Le raffinement de la résolution spatiale a provoqué des changements profonds dans les techniques de traitement d'image et a motivé le développement de nouvelles procédures d'extraction d'information basées sur des objets plutôt que des pixels. La détection des couronnes d'arbres est devenue un important axe de recherche en analyse d'images considérant la nature complexe des arbres dans un environnement non contrôlé. Il reste que la majeure partie des recherches sur ce thème s'est concentrée sur les forêts tempérées des hautes latitudes. C'est en tenant compte de cette lacune que cette thèse s'est concentrée sur le développement d'une méthode de détection automatique des couronnes d'arbres adaptable à divers environnements et capable de délimiter les couronnes comme des objets uniques. L'approche, intitulée PPM-TM intègre des éléments de modélisation géométrique optique, de processus ponctuels marqués (PPM) et de modèle de correspondance (*template matching* ou TM) pour détecter et délimiter sommairement les contours des couronnes d'arbre à partir d'images VHR. L'algorithme utilise une mesure adaptative qui permet que les arbres soient détectés même quand leur mesure de similitude avec le modèle 3D n'est pas très élevée. Il incorpore également des fonctions de seuil spectral et de mesure de texture de premier ordre pour assister le processus de décision dans la recherche des arbres comme objets. Des phases de naissance et mort s'alternent et se suivent au cours desquelles les objets sont créés et détruits quand ils ne rencontrent pas les critères d'inclusion au moment de l'itération. De plus, une série d'améliorations fut ajoutée qui permettent le raffinement du résultat en post-traitement. Ceux-ci incluent la redéfinition du diamètre de la couronne et la relocalisation de son centre. Le PPM-TM est testé dans divers environnements des arbres hors forêt (*trees outside forests - TOF*): urbains, de vergers et de forêt savannique (*cerrado sensu stricto*) et vestiges de forêt tropicale décidue (*mata seca*). Le taux de succès moyen pour la détection est de 91.9% et de 67.61% pour la délimitation des contours. Les meilleurs résultats sont généralement obtenus pour les arbres isolés.

Mots-clés: Détection des couronnes d'arbres individuellement. Images satellites à haute résolution. Processus ponctuels marqués. Modèle de correspondance. Arbres hors forêt. Télédétection. Traitement numérique des images.

# Lista de Figuras

1.1	Algumas informações e medidas levantadas para cada árvore durante o inventário florestal: altura total (AT), altura de fuste (AF), altura da copa (AC), diâmetro da copa (DC), diâmetro à altura do peito (DAP) e localização da árvore (xy). Fonte: figura adaptada pela autora a partir da imagem disponível em <a href="https://3dprint.com/wp-content/uploads/2014/02/tree.png">https://3dprint.com/wp-content/uploads/2014/02/tree.png</a> . . . . .	28
1.2	Linha do tempo e escala espacial dos principais satélites de sensoriamento remoto úteis para a coleta de informações sobre os recursos florestais até o ano de 2015. Fonte: adaptado de Shao e Reynolds (2006). . . . .	29
1.3	Comparativo do efeito da escala de aquisição de dois diferentes satélites sobre a mesma área: (a) subimagem Landsat 8 OLI com 30 m de resolução espacial; (b) subimagem WorldView-2 com bandas multiespectrais fusionadas com 50 cm de resolução espacial; (c) detalhe da mesma imagem WorldView-2, na qual as árvores são objetos visualmente identificáveis (as imagens são representadas em falsa cor). . . . .	31
2.1	Exemplos de superfície obtida pela utilização do filtro LM: (a) imagem original; (b) os máximos locais aparecem na terceira dimensão e são associados à presença de árvores; (c-f) aplicação do LM em quatro filtros lineares cumulativos ( $0^\circ$ , $45^\circ$ , $90^\circ$ e $135^\circ$ ). . . . .	36
2.2	Em (a) exemplos de modelos de árvores sintéticas para diferentes formas de copa de árvore com a sombra projetada. Em (b) identificação das copas das coníferas. O modelo utilizado encontra-se no canto inferior direito (Fonte: Larsen (1997)). . . . .	38
2.3	Resultados do algoritmo <i>valley-following</i> em uma imagem de floresta no Canadá (Fonte: Gougeon e Leckie (2003)). . . . .	39
2.4	Resultados do algoritmo WS para delineamento das copas de árvores e identificação dos topos das árvores em diferentes porções de uma fotografia aérea, afetadas pelo ângulo de obtenção da imagem. Em (a) a porção esquerda da imagem, em (b) a porção central e em (c) a porção direita da imagem (Fonte: Wang <i>et al.</i> (2004)). . . . .	42

2.5	Exemplo de algoritmos RG para delineamento de árvores em uma floresta Boreal. A imagem original, com resolução espacial de 3 cm, é apresentada em (a), com os resultados das abordagens de movimento browniano (b) e <i>random walk</i> (c) (Fonte: Erickson (2004)). . . . .	43
2.6	Exemplo da aplicação do PPM para reconhecimento de árvores em uma área de floresta plantada. Em (a) a imagem original e em (b) os resultados (Fonte: Perrin (2006)). . . . .	45
2.7	Localização da área de estudo. À direita, a imagem WorldView-2 que serviu para realização dos testes, apresentada em uma composição colorida, falsa cor (7R5G3B). . . . .	50
2.8	Classificação das espécies de árvores avaliadas. Para cada árvore é exibida uma foto tirada ao nível do solo e duas vistas aéreas, primeiro da imagem pancromática do WV-2 e depois uma fotografia aérea com 10 cm de resolução espacial. As imagens com 10 cm de resolução são do ano de 2008 e foram gentilmente cedidas pela Empresa de Informática e Informação do Município de Belo Horizonte (Prodabel). . . . .	52
2.9	Fluxograma com as quatro etapas utilizadas na abordagem crescimento de região multiresolução para detectar e delinear árvores individuais. . . . .	54
2.10	Ilustração da operação de interseção inclusiva. . . . .	55
2.11	Os resultados da detecção de copas individuais com (a) <i>template matching</i> , (b) crescimento de região e (c) <i>watershed</i> . . . . .	58
2.12	Resultados do delineamento de copas de árvores individuais com a abordagem de crescimento de região (a) e <i>watershed</i> (b). Note que apenas as árvores de validação são representadas. . . . .	60
2.13	Os resultados do processo de segmentação com crescimento de região (a e b) e <i>watershed</i> (c e d) . . . . .	61
3.1	Imagens sintéticas com menor densidade (a-c) e com maior densidade de árvores (d-e), nomeadas sequencialmente de 1 a 5. . . . .	64
3.2	Imagens WV-2 de Belo Horizonte, MG, Brasil, em composição colorida falsa cor. Em (a), campus da UFMG, onde são observadas árvores em diversos contextos, além de diversas classes conceituais (edifícios, canteiros, asfalto, etc.). Em (b), Parque Ecológico da Pampulha, um parque urbano em processo de revegetação, e por esse motivo são observadas copas de árvores bem pequenas, oriundas do processo de replantio. . . . .	66

3.3	Em (a) imagem WV-2, em composição colorida falsa cor, do Jardim Botânico Real e seu entorno, localizado na cidade de Sydney, Austrália. Trata-se de um parque urbano circundado por água, prédios e avenidas. Em (b) WV-2 da zona rural de Morro Bay, Califórnia, com árvores em um pomar de abacateiros (imagem em cor natural). . . . .	67
3.4	Imagens extraídas do aplicativo <i>Google Earth</i> . Em (a) imagem <i>Digital-Globe</i> , do ano de 2016, em vegetação de cerrado no Parque Nacional de Brasília, Distrito Federal. Em (b) imagem CNES - Astrium, também do ano de 2016, em um remanescente florestal de mata seca (Floresta Estacional Semidecidual), no município de Itacarambi, Minas Gerais. . . . .	67
4.1	Etapas para geração do modelo geométrico de uma copa de árvore. Em (a) a primeira matriz, na qual são definidas a forma e o tamanho da copa, em (b) a segunda matriz, na qual é realizada a projeção da sombra, e em (c) a terceira e última matriz, na qual o modelo é iluminado. . . . .	71
4.2	Análise do relacionamento dos pixels vizinhos ao pixel Z5 para obtenção das declividades na posição horizontal (a) e vertical (b). . . . .	74
4.3	Exemplos de geometria da copa: à esquerda, a geometria da copa é elíptica horizontal, com valor $\alpha = 0.5$ ; no centro, a geometria de uma meia esfera, com valor $\alpha = 1$ ; e à direita, a geometria da copa é elíptica vertical, com valor $\alpha = 2$ . Para todas os exemplos foram utilizados os mesmos parâmetros de raio e iluminação solar. . . . .	75
4.4	Comparação entre uma árvore isolada em uma imagem <i>WorldView-2</i> (a) e o modelo ótico geométrico 3D, com fator de corte igual a zero, ou seja, toda a sombra incluída (b). Em (c) a mesma árvore na imagem com destaque a somente uma parte de sua sombra, e em (d) o mesmo modelo com um fator de corte de 0.85, que possibilita a utilização de apenas parte da sombra para reconhecimento dos objetos. . . . .	76
4.5	Esquema de divisão do modelo (a) nas porções sombreada (b) e iluminada (c) da copa. . . . .	77
4.6	Exemplo da fases de nascimento (a) e morte (b). Neste exemplo um alto limiar de semelhança ( $Sm = 0.98$ ) é buscado entre o ponto e a marca, e após 175 iterações, um objeto foi reconhecido e preservado. . . . .	81
4.7	Resultados do PPM-TM para detecção das “árvores” na imagem sintética 1: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 1, com 2.200 iterações: $Sm$ , $\mu$ e $\sigma$ , respectivamente (c-e). . . . .	87

4.8	Resultados do PPM-TM para detecção das “árvores” na imagem sintética 2: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 2, com 1.794 iterações: $S_m$ , $\mu$ e $\sigma$ , respectivamente (c-e). . . . .	88
4.9	Resultados do PPM-TM para detecção das “árvores” na imagem sintética 3: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 3, com 1.550 iterações: $S_m$ , $\mu$ e $\sigma$ , respectivamente (c-e). . . . .	89
4.10	Resultados do PPM-TM para detecção das “árvores” na imagem sintética 4: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 4, com 2.600 iterações: $S_m$ , $\mu$ e $\sigma$ , respectivamente (c-e). . . . .	90
4.11	Resultados do PPM-TM para detecção das “árvores” na imagem sintética 5: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 5, com 6.831 iterações: $S_m$ , $\mu$ e $\sigma$ , respectivamente (c-e). . . . .	91
5.1	Recorte de um imagem WV-2 (a) e o NDWI obtido para a mesma imagem (b). As sombras em (b) estão representadas pela cor azul e estão associadas aos mais altos valores. . . . .	97
5.2	Em (a) o ponto e a marca da árvore detectada, com seus vizinhos-8 destacados. Em (b) é ilustrado o processo de expansão e contração da marca. Em (c-f) é ilustrado o processo de translação do ponto e de sua marca com base no relacionamento com os pixels vizinhos $p_i$ . Se o relacionamento é $N_8(p_i)$ , oito posições serão testadas para o pixel $p_i$ . . . . .	99
5.3	Fluxograma do algoritmo PPM-TM, parte A. Na parte inicial do processo são definidos os parâmetros do processamento e a abordagem a ser utilizada: $P_x$ ou $M_x$ . . . . .	101
5.4	Fluxograma do algoritmo PPM-TM, parte B. Abordagem para $P_x$ para imagem pancromática e RGB. . . . .	102
5.5	Fluxograma do algoritmo PPM-TM, parte C. Abordagem para $M_x$ para imagens multiespectrais. . . . .	103

6.1	Interpretação visual das copas das árvores para geração dos dados de validação. Em (a) círculos serviram de base para expressar a forma das copas. Em (b), quando a forma não podia ser simplificada por um círculo, foi interpretada como um polígono. Em (c) situação em que não era possível interpretar visualmente as copas das árvores. Nesses casos, os indivíduos com dossel proeminente foram interpretados, e o restante não foi avaliado. . . . .	105
6.2	Dados de validação (em preto), sobrepostos às imagens de teste: (a) campus da UFMG, (b) P.E. da Pampulha, (c) Jardim Botânico de Sydney, (d) plantação de abacateiros em Morro Bay, (e) cerrado <i>sensu stricto</i> em Brasília e (f) remanescente de mata seca, em Itacarambi. . . . .	106
6.3	Resultados do PPM-TM* para o reconhecimento das copas de árvores individuais na imagem do campus da UFMG. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (composição colorida em falsa cor). . . . .	111
6.4	Detalhe do resultado do PPM-TM* para a imagem do campus da UFMG (em amarelo). Tanto as árvores grandes, como as pequenas, foram bem detectadas e delineadas pelo método. . . . .	111
6.6	Dificuldade para validação da detecção em um remanescente florestal (a). Exemplo de FP sobre telhado de cerâmica recoberto por musgos (b). Os parâmetros para eliminação de não-vegetação não foram suficientes para excluí-lo do espaço amostral. . . . .	112
6.5	Desafios para a detecção das copas na imagem do campus da UFMG: (a) copas muito pequenas, menores que 2,5 pixels de diâmetro; (b) espécies decíduas, sendo possível observar apenas a sombra de seus galhos. . . . .	112
6.7	Resultados do PPM-TM* para o reconhecimento das copas de árvores individuais na imagem do Parque Ecológico da Pampulha. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (composição colorida em falsa cor). . . . .	113
6.8	Detalhe da imagem do Parque Ecológico da Pampulha, na qual tanto as árvores grandes quanto as pequenas puderam ser detectadas pelo PPM-TM*. . . . .	113
6.9	Exemplo de copas entrelaçadas que formam um dossel contínuo: (a) resultado do PPM-TM*; (b) mesmo grupamento de árvores visto em uma imagem do <i>Google Earth</i> , com 10 cm de resolução espacial; (c) exemplo de falso positivo sobre grama. . . . .	114

6.10	Resultados do PPM-TM* para o reconhecimento das copas de árvores individuais na imagem do Jardim Botânico Real de Sydney e entorno. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (composição colorida em falsa cor). . . . .	115
6.11	Detecção das copas na imagem de Sydney, árvores grandes e pequenas (a), pequenas (b) e mesmo com forma diferenciada, a copa pôde ser corretamente detectada e delineada (c). . . . .	115
6.12	Resultados do PPM-TM* para o reconhecimento das copas de árvores individuais na imagem de uma plantação de abacateiros na cidade de Morro Bay, Califórnia. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (cor natural). . . . .	116
6.13	Em (a) detalhe do resultado do PPM-TM* para a detecção de copas de árvores em um pomar de abacateiros. Até as menores árvores puderam ser identificadas. Em (b) detalhe do resultado em cerrado no Parque Nacional de Brasília. . . . .	117
6.14	Resultados do PPM-TM* para o reconhecimento das copas de árvores individuais na imagem sobre cerrado, no Parque Nacional de Brasília. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem extraída do aplicativo <i>Google Earth</i> (cor natural). . . . .	117
6.15	Resultados do PPM-TM* para o reconhecimento das copas de árvores individuais na imagem sobre mata seca, em um remanescente florestal na cidade de Itacarambi, Minas Gerais. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem extraída do aplicativo <i>Google Earth</i> (cor natural). . . . .	118
6.16	Detalhe da imagem sobre vegetação de mata seca, na qual observamos a detecção e o delineamento das copas proeminentes. . . . .	118
6.17	Em (a) detalhe do delineamento obtido para a imagem de Sydney. As copas de validação são representadas em um tom mais claro e o resultado do PPM-TM* em vermelho. Em (b) detalhe do delineamento para mata seca, com os dados de validação em amarelo, e o resultado do reconhecimento das árvores em vermelho. . . . .	120



6.18	Copas de validação (amarelo) sobrepostas ao resultado do PPM-TM* (a) na imagem de cerrado, no qual observamos uma tendência a superestimação das copas das árvores. Em (b) detalhe do resultado do PPM-TM* para a detecção de copas de árvores em um pomar de abacateiros (amarelo), sobrepostas às copas de validação (vermelho). As copas foram bem delineadas, com tendência à subestimação. . . . .	121
6.19	Detalhe da análise dos erros para as imagens (a) do campus da UFMG e (b) do Parque Ecológico da Pampulha (roxo = acerto, amarelo = comissão e azul = omissão). . . . .	121
6.20	Erros que interferem na qualidade das árvores bem detectadas. Divisão da copa em dois objetos distintos (a), com as copas de validação (em amarelo) sobrepostas ao resultado da detecção (em azul). Detecção de vários objetos em copas entrelaçadas (b). . . . .	125
6.21	Histogramas gerados no processamento da imagem de Morro Bay com o total de objetos detectados em cada divisão do processamento (a), e o total de árvores detectadas pelo tamanho do raio, em pixels (b). . . . .	126
C.1	Estatísticas globais para a imagem do Campus da UFMG, Belo Horizonte, Minas Gerais: divisões 1 a 3. . . . .	220
C.2	Estatísticas globais para a imagem do Campus da UFMG, Belo Horizonte, Minas Gerais: divisões 4 e 5. . . . .	221
C.3	Estatísticas globais para a imagem do Parque Ecológico da Pampulha, Belo Horizonte, Minas Gerais: divisões 1 e 2. . . . .	222
C.4	Estatísticas globais para a imagem do Jardim Botânico Real de Sydney, Austrália: divisões 1 a 3. . . . .	223
C.5	Estatísticas globais para a imagem do Jardim Botânico Real de Sydney, Austrália: divisões 4 a 6. . . . .	224
C.6	Estatísticas globais para a imagem da plantação de abacateiros em Morro Bay, Califórnia: divisões 1 a 3. . . . .	225
C.7	Estatísticas globais para a imagem em vegetação de cerrado <i>sensu stricto</i> no Parque Nacional de Brasília, Distrito Federal: divisões 1 e 2. . . . .	226
C.8	Estatísticas globais para a imagem em vegetação de cerrado <i>sensu stricto</i> no Parque Nacional de Brasília, Distrito Federal: divisões 3 e 4. . . . .	227
C.9	Estatísticas globais para a imagem em remanescente florestal de mata seca, Itacarambi, Minas Gerais. . . . .	227

# Lista de Tabelas

1.1	Exemplos da utilidade das informações básicas sobre a localização e tamanho da copa das TOF. . . . .	27
1.2	Satélites de alta resolução espacial ( <i>Very High Resolution satellites - VHR</i> ) lançados entre os anos de 1999 e 2016, com suas resoluções espaciais e bandas multiespectrais. Note que nenhum dos satélites possui bandas multiespectrais VHR. . . . .	30
2.1	Resumo dos algoritmos filtragem de máximas locais , <i>template matching</i> , <i>valley following</i> , <i>watershed</i> , <i>region growing</i> e processos pontuais marcados utilizados para a detecção de árvores individuais. São apresentados os seus princípios, pesquisas de destaque e principais características e limitações. . . . .	47
2.2	Método para o cálculo do sucesso do delineamento das copas obtido a partir da multiplicação entre a matriz de amostras de validação e os resultados das abordagens RG e WS. . . . .	56
2.3	Resultados da abordagem Template Matching para detecção de copas de árvores individuais. . . . .	57
2.4	Resultados das abordagens crescimento de região e <i>watershed</i> para identificação de copas de árvores. . . . .	57
2.5	Resultados das abordagens de crescimento de região e <i>watershed</i> para delineamento das copas de árvores individuais. . . . .	59
3.1	Parâmetros utilizados para criação das imagens sintéticas. Os mesmos ângulos de elevação e azimute solar ( $\theta = 45.1$ , $\phi = 32.0$ ) foram utilizados para todas as imagens . . . . .	63
3.2	Imagens selecionadas, sua localização, resoluções espectrais e radiométricas, e contexto. . . . .	65
3.3	Bandas espectrais e resolução espacial das imagens WorldView-2 (Digital-Globe, 2010). . . . .	66
4.1	Método para o cálculo do sucesso do delineamento dos objetos nas imagens sintéticas. O resultado foi obtido a partir da soma entre as imagens de validação e de resultados obtidos pelo PPM-TM. . . . .	84

4.2	Resultados do algoritmo PPM-TM para detecção de árvores em imagens sintéticas. . . . .	85
4.3	Resultados do delineamento das copas de árvores em imagens sintéticas com o método PPM-TM. . . . .	86
6.1	Parâmetros de iluminação do modelo 3D para as imagens de teste. . . . .	107
6.2	Parâmetros com critérios para reconhecimento dos objetos, limiares para modificação do espaço amostral e critérios de divisão do processamento para cada uma das imagens testadas. . . . .	109
6.3	Resultados obtidos pelo PPM-TM* para a detecção de copas de árvores individuais. . . . .	110
6.4	Resultados obtidos pelo PPM-TM* para o delineamento de copas de árvores individuais. . . . .	119

# Abreviaturas e Siglas

- 3D: Tridimensional
- AB: Área Basal
- AC: Área da copa
- AF: Altura de fuste
- AT: Altura total
- CA: Califórnia
- CIE: Comissão Internacional de Iluminação
- CNES: Centro Nacional de Estudos Espaciais da França
- $CO_2$ : dióxido de carbono
- DAP: Diâmetro à Altura do Peito
- DC: Diâmetro da copa
- DF: Distrito Federal
- DLF: Filtragem local direcional
- DPI: Divisão de Processamento de Imagens
- EUA: Estados Unidos da América
- EPSG: *European Petroleum Survey Group*
- FIH/UFVJM: Faculdade Interdisciplinar em Humanidades da Universidade Federal dos Vales do Jequitinhonha e Mucuri
- FP: Funções de pertinência
- GEOBIA: *Geographic Object Based Image Analysis* ou Análise de imagens baseada em objetos geográficos

- GLCM: Matriz de co-ocorrência dos níveis de cinza
- INPE: Instituto Nacional de Pesquisas Espaciais
- INRIA: *Institut National de Recherche en Informatique et en Automatique*
- IVP: Infravermelho próximo
- Lidar: *Light Detection and Ranging*
- LM: Filtragem de máximas locais
- MDE: Modelo digital de elevação
- MG: Minas Gerais
- Mx: Multiespectral
- ND: Número digital
- NDVI: Índice de vegetação da diferença normalizada
- NDWI: Índice de diferença normalizada da água
- OBIA: Object Based Image Analysis
- OLI: Operational Land Imager
- PE: Parque Ecológico
- PPM: Processo Pontual Marcado
- Px: Pancromático
- RG: Region Growing
- RGB: vermelho, verde e azul (*red, green and blue*)
- SIG: Sistemas de Informações Geográficas
- TM: *Template matching*
- TOF: *Tree Outside Forests*
- UAV: Veículo aéreo não tripulado
- UFMG: Universidade Federal de Minas Gerais
- UNFCCC: *United Nations Framework Convention on Climate Change*

- UTM: Universal Transversa de Mercator
- VF: *Valley-following*
- VHR: *Very High Resolution*
- WS: Watershed
- WV-1: *WorldView-1*
- WV-2: *WorldView-2*

# Notações ou Símbolos

- $\theta$ : ângulo de elevação
- $\phi$ : azimute solar
- $\mu$ : média
- $\sigma$ : desvio padrão
- $amb$ : iluminação difusa
- $L_M$ : máxima radiância do modelo
- $Sm$ : semelhança, medida que define a correlação entre marcas e pontos
- $Dif$ : diferença entre o modelo e a imagem
- $I$ : índice de identificação

# Sumário

<b>Introdução</b>	<b>25</b>
1.1 As Árvores em Florestas e as Fora de Florestas . . . . .	25
1.2 O Inventário da Vegetação . . . . .	26
1.3 O Sensoriamento Remoto da Vegetação e Dados de Alta Resolução Espacial: Mudança na Escala de Análise . . . . .	27
1.4 Motivações . . . . .	32
1.5 Objetivos . . . . .	33
1.6 Organização do Manuscrito . . . . .	34
<b>2 Referencial Teórico</b>	<b>35</b>
2.1 Algoritmos para Detecção e Delineamento de Copas de Árvores . . . . .	35
2.1.1 Filtro de Máximos Locais . . . . .	35
2.1.2 Template Matching . . . . .	37
2.1.3 <i>Valley-following</i> . . . . .	39
2.1.4 <i>Watershed</i> . . . . .	40
2.1.5 Crescimento de Região . . . . .	41
2.1.6 Processos Pontuais Marcados . . . . .	42
2.1.7 Discussão . . . . .	44
2.2 Avaliação de abordagens existentes . . . . .	49
2.2.1 Materiais e Métodos . . . . .	49
2.2.2 Resultados . . . . .	56
2.2.3 Discussão . . . . .	61
<b>3 Imagens Sensoriamento Remoto e Imagens Sintéticas</b>	<b>63</b>
3.1 Imagens Sintéticas . . . . .	63
3.2 Imagens de Sensoriamento Remoto . . . . .	64



<b>4</b>	<b>Algoritmo PPM-TM: Abordagem Híbrida para o Reconhecimento de Copas de Árvores em Imagens VHR</b>	<b>68</b>
4.1	Modelagem Geométrica das Copas de Árvores em 3D . . . . .	70
4.1.1	Fonte de Luz . . . . .	70
4.1.2	Geometria da Copa da Árvore . . . . .	70
4.1.3	Projeção da Sombra . . . . .	72
4.1.4	Interação entre Luz e Copa . . . . .	73
4.1.5	Parâmetros de Entrada para Criação do Modelo . . . . .	74
4.2	Algoritmo PPM-TM . . . . .	77
4.2.1	Processo Pontual Marcado . . . . .	77
4.2.2	Alternância das Fases de Nascimento e Morte . . . . .	80
4.3	Validação . . . . .	84
4.3.1	Detecção da Árvore . . . . .	84
4.3.2	Delineamento da Copa . . . . .	84
4.4	Testes em ambientes controlados . . . . .	85
4.4.1	Detecção da Árvore . . . . .	85
4.4.2	Delineamento da Copa . . . . .	86
4.4.3	Parâmetros de Processamento . . . . .	86
<b>5</b>	<b>Refinamento do Algoritmo</b>	<b>93</b>
5.1	Leitura e Processamento das Imagens VHR . . . . .	93
5.2	Divisão do Processamento das Imagens . . . . .	95
5.3	Modificação do Espaço Amostral . . . . .	95
5.4	Variação da Intensidade do Processo . . . . .	98
5.5	Operações de Expansão, Contração e Translação . . . . .	98
5.6	Integração SIG . . . . .	98
5.7	Abordagem Pancromática <i>versus</i> Multiespectral . . . . .	99
<b>6</b>	<b>Resultados do PPM-TM em Imagens VHR</b>	<b>104</b>
6.1	Avaliação da Acurácia . . . . .	104
6.2	Parâmetros do Processamento . . . . .	105
6.3	Identificação das Copas de Árvores . . . . .	110
6.4	Delineamento das Copas de Árvores . . . . .	118

6.5	Discussão . . . . .	121
<b>7</b>	<b>Considerações Finais</b>	<b>127</b>
	<b>Apêndices</b>	<b>138</b>
<b>A</b>	<b>Publicações e Conferências</b>	<b>139</b>
<b>B</b>	<b>Artigos Publicados</b>	<b>141</b>
<b>C</b>	<b>Estatísticas globais do processamento das imagens VHR</b>	<b>219</b>

# Capítulo 1

## Introdução

### 1.1 As Árvores em Florestas e as Fora de Florestas

As florestas desempenham um papel essencial no planeta, com grande importância do ponto de vista ambiental, social e econômico. Elas contribuem para a manutenção de ecossistemas, para conservação dos recursos hídricos, para a estabilidade do clima, auxiliam no controle da erosão, promovem a biodiversidade, servem de abrigo para a fauna, fornecem madeira e outros produtos florestais, além de possuírem uma gama de valores culturais e de servirem como ambientes recreativos (Östeberg *et al.*, 2013; Sander *et al.*, 2010; Brasil, 2009).

Diversos são os conceitos que nos auxiliam a compreender o que é uma floresta, que geralmente envolve a ocorrência de árvores com uma determinada densidade. Uma das definições mais utilizada é a estabelecida na Declaração de Marrakesh pela Convenção-Quadro das Nações Unidas sobre Mudança do Clima (*United Nations Framework Convention on Climate Change - UNFCCC*): “(...) área mínima entre 0,05 e 1,0 ha, com cobertura de copa (ou densidade equivalente) superior a 10-30% de árvores com potencial para atingir uma altura mínima de 2-5 metros na maturidade *in situ*” (UNFCCC, 2001). Esclarece ainda que “uma floresta pode consistir de formações florestais fechadas, nas quais árvores de vários estratos e sub-bosques cobrem uma alta proporção do solo, ou de florestas abertas. Povoa-mentos naturais jovens e todas as plantações que atinjam uma densidade de 10-30% ou uma altura de 2-5 metros são incluídos na rubrica floresta, tal como os terrenos que fazem normalmente parte da área de floresta e que são temporariamente desbastados como resultado da intervenção humana, como a colheita ou causas naturais, mas que sua reversão para floresta é esperada” (UNFCCC, 2001).

Nas últimas décadas os pesquisadores passaram a também reconhecer a importância das árvores inseridas fora das florestas, as quais são denominadas árvores fora de florestas ou *trees outside forests* (TOF), que ocupam quase metade da superfície emersa do planeta (FAO, 2010). São incluídas nessa classificação árvores e arbustos dispersos em áreas urbanas, plantações, sistemas agroflorestais e até em pastos não associados a uma floresta ou a um ecossis-

tema florestal, sendo que as terras agrícolas formam um importante conjunto de áreas TOF (de Foresta *et al.*, 2013). As únicas situações em que não existem árvores isoladas são em desertos ou em áreas de agricultura que são manejadas para não terem árvores (de Foresta, 2017).

Mesmo dispersas, essas árvores desempenham um papel importante na economia dos ambientes povoados e sua gestão e monitoramento são representativos dos esforços para tornar essas áreas sustentáveis (De Foresta *et al.*, 2013). As TOF oferecem uma variedade de serviços ecológicos, por exemplo, na melhoria da qualidade do ar e da água, regularizando microclimas, reduzindo a concentração de dióxido de carbono e outros poluentes, reduzindo os custos com energia, ajudando a controlar a erosão do solo através da redução da movimentação do solo e trazendo a biodiversidade para o meio ambiente (Meneguzzo *et al.*, 2013; Andreu *et al.*, 2008). Porém, o papel dessas árvores usualmente não é contabilizado, não sendo incluídas na contagem dos estoques globais de carbono (Zomer *et al.*, 2016).

Em iniciativas ainda recentes, diversos países já têm incluído as TOF em seus inventários florestais. No Brasil, o Inventário Florestal Nacional produz informações sobre as árvores fora de florestas a cada cinco anos, porém o nível de conhecimento sobre elas ainda é muito incipiente, mesmo o país sendo o líder mundial em termos de área recoberta por TOF (Zomer *et al.*, 2016) e a falta de conhecimento sobre essas áreas prejudica ações de manejo para ampliar os benefícios que elas podem trazer.

## 1.2 O Inventário da Vegetação

O estudo da vegetação pode compreender três aspectos: fisionomia (ou aparência da vegetação), estrutura (ou ordenação das formas de vida) e composição (flora envolvida) (Rizzini, 1997). E qualquer dos aspectos que se deseje estudar, inventários são realizados com o intuito de fornecer informações sobre a vegetação.

A informação básica da localização, distribuição, densidade e tamanho da copa é útil para uma variedade de atividades em muitos ambientes. Em ambientes urbanos, é necessária informação de alta qualidade para apoiar programas de gestão (Östeberg *et al.*, 2013; Schipperijn *et al.*, 2005) e muitas administrações municipais estão realizando inventários extensivos de suas árvores em ruas e parques (Schipperijn *et al.*, 2005). Em pomares e áreas de silvicultura, o monitoramento da vegetação permite o controle de pragas, informações indiretas sobre a falta de nutrientes no solo, estimativas de produtividade, entre outros. Sob linhas de transmissão realiza-se a remoção das árvores, a fim de evitar interrupções na distribuição de energia (Tabela 1.1). Na Tabela 1.1, são apresentadas algumas utilizações das informações obtidas das TOF conforme o ambiente em que elas ocorrem.

O método tradicional para obter informações sobre a vegetação é o uso de amostras sistemáticas em parcelas ou transectos (Pollock, 1994; Avery e Berlin, 1992). Usualmente, as seguintes informações e parâmetros são determinados para cada árvore incluída na amostra-

<b>Ambiente</b>	<b>Importância da Informação TOF</b>
Áreas urbanas	Inventários, monitoramento de crescimento, planejamento de plantio e poda
Áreas rurais	Subsistência sustentável para comunidades rurais (lenha, colheita de frutos)
Florestas plantadas	Monitoramento do crescimento e da ocorrência de pragas, planejamento de operações de corte
Pastagens	Monitoramento de ambientes de sombras para os animais
Pomares	Contagem de árvores, planejamento para poda, detecção de pragas, monitoramento do crescimento
Linhas de energia	Monitoramento do crescimento de árvores sob linhas de energia
Oleodutos subterrâneos	Planejamento de corte de árvores sobre os oleodutos

Tabela 1.1: Exemplos da utilidade das informações básicas sobre a localização e tamanho da copa das TOF.

gem: localização, diâmetro à altura do peito (DAP), área basal (AB), altura total (AT), altura de fuste (AF), identificação da espécie, tamanho e porcentagem de abertura da copa (Figura 1.1). Outros parâmetros podem ser derivados para a comunidade amostrada, como o volume de madeira<sup>1</sup> e a biomassa<sup>2</sup>, parâmetros imprescindíveis para compreensão dos processos envolvidos nas mudanças climáticas globais e para os cálculos da quantidade de dióxido de carbono ( $CO_2$ ) que é liberada para a atmosfera durante o processo de queima da biomassa (Brasil, 2009). Os parâmetros finais para a população são obtidos por extrapolação estatística. Isso torna as técnicas de levantamento de campo para inventários florestais caras, demoradas, e inadequadas para grandes áreas.

O sensoriamento remoto se destaca como uma forma econômica e confiável para extrair informações sobre a vegetação. Ademais, pode ser o único caminho prático para prover o manejo sustentável de florestas com os dados requeridos, como dados bioquímicos e biofísicos da vegetação de forma sinóptica e repetitiva para grandes áreas de cobertura e sobre longos períodos de tempo (Shao e Reynolds, 2006).

### **1.3 O Sensoriamento Remoto da Vegetação e Dados de Alta Resolução Espacial: Mudança na Escala de Análise**

Os estudos de coberturas vegetadas a partir de dados de sensoriamento remoto iniciaram no princípio do século XX, com a utilização de fotografias aéreas, primeiramente em comprimentos de onda do visível e, posteriormente, com a utilização de filmes infra-vermelhos.

<sup>1</sup>O volume de madeira, geralmente obtido a partir do diâmetro e da altura das árvores, é uma variável importante para a estimativa da biomassa (Brasil, 2009).

<sup>2</sup>A estimativa de biomassa geralmente é feita a partir de estudos que determinam o volume de madeira por unidade de área e o Fator de Expansão de Biomassa (Brasil, 2009).

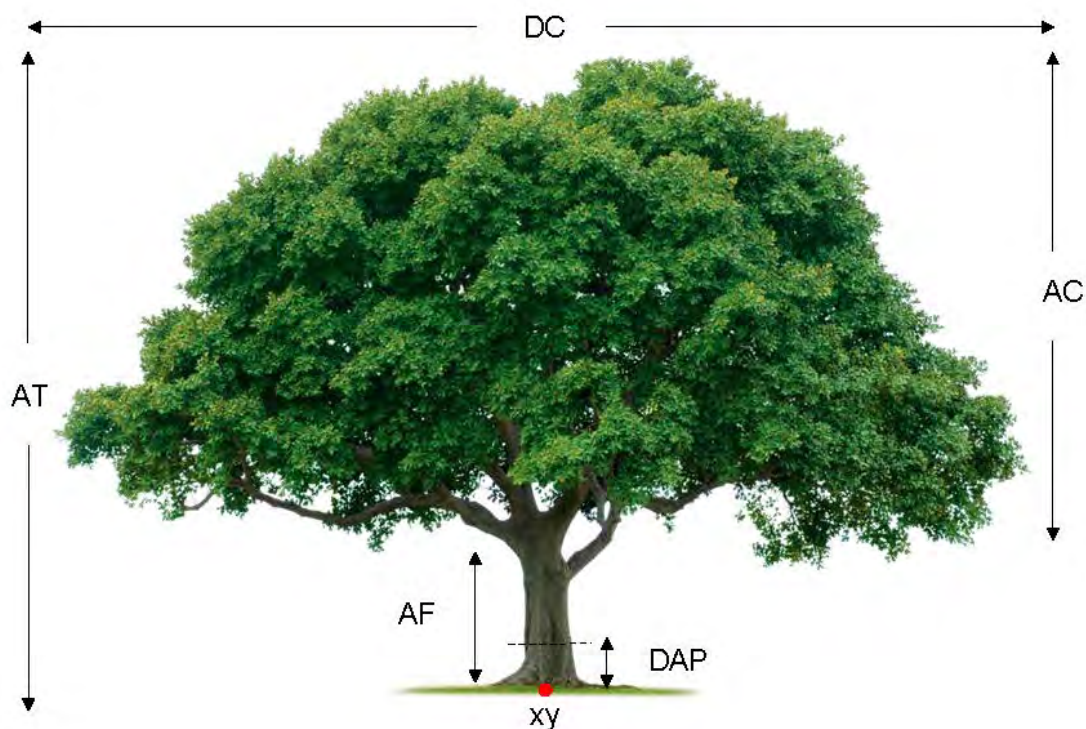


Figura 1.1: Algumas informações e medidas levantadas para cada árvore durante o inventário florestal: altura total (AT), altura de fuste (AF), altura da copa (AC), diâmetro da copa (DC), diâmetro à altura do peito (DAP) e localização da árvore (xy). Fonte: figura adaptada pela autora a partir da imagem disponível em <https://3dprint.com/wp-content/uploads/2014/02/tree.png>.

O estudo de copas de árvores individuais a partir de dados de sensoriamento remoto iniciou com o uso de fotografias aéreas de alta resolução espacial (escala maior que 1:10.000), impulsionado com a utilização de técnicas de estereoscopia. Havia fotointerpretores preparados para reconhecerem espécies de árvores individualmente e realizarem avaliação de danos diversos (doenças, insetos, queimadas). Avery e Berlin (1992) pontuaram que era possível a extração de medidas e informações das árvores a partir das fotografias aéreas, tais como: identificação da espécie, contagem das árvores, cálculo do volume, área e densidade de cobertura da copa e altura da árvore.

O estudo da vegetação a partir de dados de sensoriamento remoto óptico orbital iniciou entre os anos 1970 e 1980, com o desenvolvimento de técnicas, métodos e processos para separar áreas florestadas de áreas não-florestadas (Gougeon e Leckie, 2003). A partir do lançamento do satélite Landsat 5, em 1984, com seu sensor TM (*Thematic Mapper*), houve incremento nas resoluções espaciais e espectrais obtidas a partir de dados de sensoriamento remoto orbital. Os estudos da vegetação passaram também a focar nas perturbações que afetavam as florestas (ex.: desmatamento e queimadas) e nas estimativas de parâmetros biofísicos da vegetação (Shao e Reynolds, 2006; Franklin, 2001). Porém, a resolução espacial das imagens orbitais ainda era o principal fator limitante para estudos mais detalhados sobre




Figura 1.2: Linha do tempo e escala espacial dos principais satélites de sensoriamento remoto úteis para a coleta de informações sobre os recursos florestais até o ano de 2015. Fonte: adaptado de Shao e Reynolds (2006).

as florestas.

Somente no ano de 1999, com o lançamento do satélite Ikonos II, de resolução espacial de 1 m na banda pancromática, a comunidade científica passou a dispor de dados óticos orbitais de alta resolução espacial (*Very High Resolution* - VHR<sup>3</sup>), permitindo o estudo de árvores individuais (Figura 1.2). Nos anos posteriores, uma série de outros satélites de dados VHR foram lançados (QuickBird, WorldView-1, Geoeeye, WorldView-2, entre outros), consolidando o uso de dados orbitais para o estudo de árvores individuais. Porém, o aumento na resolução espacial não foi acompanhado pela resolução espectral para dados VHR, os quais ficaram restritos a uma única banda pancromática (Tabela 1.2).

O efeito da escala de aquisição dos dados de sensoriamento remoto para o estudo de coberturas florestais teve um impacto importante nas técnicas de sensoriamento remoto, pois em dados de resolução espacial moderada (ex.: MODIS) ou média (ex.: Landsat), a copa de uma árvore é um objeto muito pequeno para ser identificado, já que a resposta espectral de um pixel contém a de vários outros objetos. Já em dados VHR, é necessário um conjunto de pixels para formar um único objeto, o que permite a identificação visual das copas das árvores. Para ilustrar esse efeito, um recorte de uma imagem Landsat 8 OLI (*Operational Land Imager*) e um recorte de uma imagem WorldView-2 são comparados na Figura 1.3.

<sup>3</sup>Dados VHR são aqueles com resolução espacial menor ou igual a 1 m em ao menos uma das bandas espectrais.

Tabela 1.2: Satélites de alta resolução espacial (*Very High Resolution satellites* - VHR) lançados entre os anos de 1999 e 2016, com suas resoluções espaciais e bandas multiespectrais. Note que nenhum dos satélites possui bandas multiespectrais VHR.

<b>Satélite</b>	<b>Ano de Lançamento</b>	<b>Resolução Px*</b> <b>(m)</b>	<b>Resolução Mx*</b> <b>(m)</b>	<b>Bandas Multiespectrais</b>
Ikonos II	1999	0.82	3.2	Azul, Verde, Vermelho, IVP (4)
QuickBird	2001	0.65	2.62	Azul, Verde, Vermelho, IVP (4)
WorldView-1	2007	0.46	-	-
Geoeye-1	2008	0.46	1.84	Azul, Verde, Vermelho, IVP (4)
WorldView-2	2009	0.46	1.85	Costal, Azul, Verde, Amarelo, Vermelho, Red Edge, IVP, IVP 2 (8)
Pleiades 1A	2011	0.5	2.0	Azul, Verde, Vermelho, IVP (4)
Pleiades 1B	2012	0.5	2.0	Azul, Verde, Vermelho, IVP (4)
Kompsat-3	2012	0.7	2.8	Azul, Verde, Vermelho, IVP (4)
SkySat-1	2013	0.9	2.0	Azul, Verde, Vermelho, IVP (4)
WorldView-3	2014	0.31	1.24	Costal, Azul, Verde, Amarelo, Vermelho, Red Edge, IVP, IVP 2 (8)
SkySat-2	2014	0.9	2.0	Azul, Verde, Vermelho, IVP (4)
Kompsat-3A	2015	0.55	2.2	Azul, Verde, Vermelho, IVP (4)
WorldView-4	2016	0.31	1.24	Azul, Verde, Vermelho, IVP (4)

\* Resolução espacial no nadir para bandas Pancromática (Px) e Multiespectral (Mx)  
IVP: Infravermelho Próximo






Figura 1.3: Comparativo do efeito da escala de aquisição de dois diferentes satélites sobre a mesma área: (a) subimagem Landsat 8 OLI com 30 m de resolução espacial; (b) subimagem WorldView-2 com bandas multiespectrais fusionadas com 50 cm de resolução espacial; (c) detalhe da mesma imagem WorldView-2, na qual as árvores são objetos visualmente identificáveis (as imagens são representadas em falsa cor).

Ambas as imagens foram adquiridas sobre o mesmo local, em mesma época. Na imagem (a), que possui pixels de 30 m de resolução espacial, é possível diferenciar áreas vegetadas das não vegetadas, visualizar as grandes avenidas e grandes áreas de solo exposto. Em (b) é possível observar vários objetos bem menores, como casas, edifícios, árvores e canteiros. Em (c) é apresentado um detalhe da imagem (b), na qual as árvores podem ser visualmente identificadas.

A partir de dados VHR, os galhos e as irregularidades dentro das copas podem ser visíveis, e a resposta espectral de uma árvore passa a ser influenciada pela variação na forma da copa (iluminação diferencial) e pelos efeitos da superfície (*background*). Outros fatores trazem complexidade a essa análise, por exemplo, imagens com árvores de tamanho de dossel variado configuram um desafio particular para sua identificação, porque uma única forma semelhante a uma copa poderia representar um galho, uma única árvore ou um grupo de árvores (Shao e Reynolds, 2006). Essa complexidade é uma fonte de erros, em especial quando surgem fatores como a proximidade de árvores vizinhas, ou localizadas sob outras árvores, árvores encontradas nas sombras ou ainda as que possuem baixo contraste espectral em relação ao sub-bosque (Wulder *et al.*, 2000).

Outro aspecto importante é o aumento da variância intraclasse em imagens VHR. Quando as árvores são imageadas em resoluções finas, um grande número de pixels corresponde à resposta da mistura espectral do dossel e dos elementos estruturais, como galhos, folhas e troncos (Ardila, 2012). Isso conduz à redução da acurácia para utilização de classificações convencionais baseadas em pixels (Pu e Landry, 2012), uma vez que existe uma grande diferença espectral em porções distintas de uma mesma árvore e entre elas (espécies, estrutura da copa, *background*), afetando o sucesso da detecção e do delineamento.

O aumento da disponibilidade de dados de alta resolução espacial e do poder computa-

cional para processá-los fez com que pesquisas em florestas passassem a ser mais focadas na identificação e delineamento de copas de árvores individuais (Larsen *et al.*, 2011; Ke e Quackenbush, 2011). A partir de dados VHR, os estudos não se mantiveram mais limitados à geração de dados por extrapolação estatística para todo o povoamento, mas permitiram a obtenção de dados precisos, consistentes e confiáveis sobre cada indivíduo da floresta.

A partir dos dados de sensoriamento remoto é possível a obtenção de parâmetros significativos, tais como a localização das árvores, a densidade da população, a composição de espécies (em algumas situações) e a análise de estado de saúde e cobertura da copa. Permitem ainda o estabelecimento de relações para determinar o volume, a biomassa e taxas de seqüestro de carbono (Ke e Quackenbush, 2011; Shao e Reynolds, 2006; Perrin, 2006; Erickson, 2004). Os dados fornecidos são precisos, consistentes e confiáveis e facilitam a eficiência no manejo florestal.

Esse objeto de pesquisa tem ganhado atenção extensiva dos pesquisadores das áreas de florestas e visão computacional (Ke e Quackenbush, 2011; Gougeon e Leckie, 2003). Isto porque, dados de alta resolução espacial permitem um foco sobre o objeto de interesse, como por exemplo, uma árvore, em vez de pixels arbitrários. As análises desses dados incorporam elementos de visão computacional, e não apenas técnicas tradicionais de sensoriamento remoto (Shao e Reynolds, 2006). Para Pollock (1996), a identificação automática de árvores requer algoritmos de alto nível para explorar essa informação complexa, e pode ser menos acurado que intérpretes humanos.

Detecção e delineamento de árvores individuais em imagens de alta resolução espacial varia de muito simples para altamente complexo, dependendo da estrutura, da composição e do contexto no qual elas estão inseridas. Por exemplo, plantações de mesma idade e de única espécie são usualmente caracterizadas por imagens com árvores individuais distintas e relativamente uniformes. Por outro lado, em florestas de regeneração natural, ou com espécies de diferentes idades, ou em florestas mistas, ou ainda em áreas urbanas, as árvores possuem alta variação no tamanho, forma e propriedades espectrais, aumentando o grau de complexidade nas análises. Se uma floresta possui povoamentos de vários dosséis, por exemplo, com copas de dossel emergente, são observadas dificuldades particulares (Shao e Reynolds, 2006).

## 1.4 Motivações

Pesquisadores têm desenvolvido diversos métodos automáticos ou semiautomáticos para a extração de árvores individuais e de suas características, utilizando fotografias aéreas digitais de vários tipos e imagens de satélite de alta resolução espacial (Larsen *et al.*, 2011). As abordagens vão desde algoritmos para identificação da copa da árvore (máximas locais, binarização da imagem, análises de escala e modelos de correspondência) até aplicações para o delineamento dos objetos, muitas delas baseadas na segmentação das imagens - *valley-*

*following, region-growing* e *watershed* - (Blaschke, 2010) e na utilização de técnicas avançadas de processamento e análise de imagens (Hay e Castilla, 2008).

Os esforços da comunidade científica contemplam tanto a utilização de imagens óticas VHR, como a de dados Lidar (*light detection and ranging*) ou sistema de varredura à laser aerotransportado. Dados Lidar possuem alto potencial para aplicações florestais, pois fornecem grande quantidade de pontos com alta precisão e possibilidade de aquisição de informação horizontal e vertical da vegetação. Porém, o alto custo para aquisição desses dados para grandes áreas ainda limita a sua utilização.

Com foco exclusivo na utilização de imagens VHR orbitais monoscópicas, poucos são os estudos desenvolvidos nessa área do conhecimento, sendo a maior parte realizada no Hemisfério Norte. Ke e Quackenbush (2011) realizaram uma revisão sobre o estado da arte para identificação e delineamento de copas de árvores individuais e concluíram que, embora os algoritmos sejam diferentes, os métodos foram desenvolvidos baseados nas características de florestas de ambientes temperados. Assim, geralmente é assumido o pressuposto que as árvores possuem forma cônica e aparência circular em imagens bidimensionais, sendo o topo o local de maior refletância dentro da área da copa. Esses pressupostos não podem ser assumidos para outros ambientes, como o tropical, em virtude da diversidade de espécies e da complexidade de formas das copas. O mesmo é válido para ambientes urbanos, nos quais as árvores exibem uma grande variedade de tamanhos e heterogeneidade física em um curto intervalo no espaço, somada à alta variedade da resposta espectral das árvores, influenciada pela infraestrutura física, tais como estacionamentos, edifícios ou gramados (Ardila, 2012).

Ke e Quackenbush (2011) identificaram apenas dois estudos em ambientes tropicais, ambos conduzidos na Austrália. No Brasil, poucos foram os trabalhos desenvolvidos a fim de produzir mapeamentos automatizados ou semiautomatizados sobre a detecção e o delineamento de árvores individuais, independente do contexto no qual as árvores estão inseridas. Parte dos trabalhos é focada em ambientes homogêneos (mesma espécie, altura e idade) e são baseados na utilização de dados Lidar (Venâncio, 2009; Cunha e Centeno, 2005). Com foco em dados de sensoriamento remoto ótico, orbital ou aéreo, foram identificados apenas os estudos de: 1) Gomes *et al.* (2008), que conduziram um estudo de segmentação e classificação de dossel florestal utilizando imagens *Quickbird* em uma estação ecológica no Estado de São Paulo; e 2) Arasato *et al.* (2011) que desenvolveram uma pesquisa utilizando dados de videografia e técnicas de segmentação e classificação para identificação de palmeiras na Amazônia brasileira.

## 1.5 Objetivos

O objetivo principal desta pesquisa é, a partir da integração entre processo pontual marcado, modelagem ótica geométrica tridimensional e *template matching*, desenvolver um método para a detecção e o delineamento de copas de árvores individuais, especialmente as locali-

zadas fora de florestas, com base na utilização de dados monoscópicos de sensores orbitais óticos de alta resolução espacial (VHR). A partir da identificação e delineamento da copa da árvore é possível obter a contagem do número de árvores, o conhecimento sobre a localização de cada indivíduo, além da estimativa de parâmetros que podem ser derivados a partir das copas das árvores, fornecendo informações consistentes para decisões de manejo, monitoramento e implementação de políticas públicas.

Considerando a lacuna existente no inventário florestal automatizado para árvores fora de florestas, os **objetivos específicos** desta pesquisa são:

- 1) Propor e implementar um método automático de análise de imagens VHR para a detecção e o delineamento de copas de árvores individuais, que seja abrangente e de fácil utilização para o usuário;
- 2) Testar e avaliar os resultados obtidos pelo método proposto em diferentes imagens e contextos em que as TOF ocorrem;
- 3) A partir dos resultados preliminares, propor aprimoramentos na abordagem desenvolvida.

Expostos os objetivos, é importante esclarecer o que não nos propomos a fazer nesta pesquisa: a) identificar e delinear as árvores que não são distinguíveis visualmente, isto porque os dados de referência para avaliação de erros nas análises são obtidos usualmente a partir de interpretação visual e se as árvores não podem ser extraídas visualmente com precisão, as chances para extraí-las de forma automática são drasticamente reduzidas; b) detectar árvores em florestas estratificadas, sendo a busca limitada às copas emergentes ou dominantes; c) atingir taxa de sucesso de 100%, mas sim alcançar um nível que possa contribuir com o manejo de alguns tipos de florestas ou para árvores fora de florestas, a fim de contribuir com a automatização dos procedimentos de mapeamento de árvores individuais.

## 1.6 Organização do Manuscrito

Esta tese é dividida em sete capítulos. O Capítulo 2 é dedicado à revisão teórica sobre o problema da identificação e delineamento de copas de árvores, no qual os principais algoritmos desenvolvidos para a tarefa são apresentados e discutidos. Ainda, o problema da detecção de copas de árvores é inicialmente tratado. Diferentes algoritmos consagrados foram testados, a fim de trazer os primeiros entendimentos acerca desse problema, especialmente para TOF. No Capítulo 3 é apresentado o conjunto de dados que serviu para realização dos experimentos. No Capítulo 4 é apresentado, implementado e testado um algoritmo original para detecção de copas de árvores em imagens VHR. No Capítulo 5, com base nos resultados preliminares, são propostos e implementados aprimoramentos no algoritmo. O Capítulo 6 é dedicado a testar e avaliar os resultados obtidos pelo método proposto. O Capítulo 7 traz as conclusões e considerações acerca desta pesquisa. E finalmente na Seção Apêndices são apresentados os resultados do processamento das imagens com o algoritmo aprimorado, os artigos publicados, além da relação de eventos nos quais a autora participou.

## Capítulo 2

### Referencial Teórico

#### 2.1 Algoritmos para Detecção e Delineamento de Copas de Árvores

As pesquisas para identificação de árvores individuais a partir de dados de sensoriamento remoto VHR podem ser divididas em duas vertentes: a localização da árvore e o delineamento da copa. A seguir apresentamos os principais algoritmos desenvolvidos para essas vertentes, com o objetivo de gerar um panorama dos métodos existentes. As abordagens são apresentadas separadamente, mas muitas pesquisas utilizam abordagens híbridas para a detecção da árvore e o completo delineamento da copa.

##### 2.1.1 Filtro de Máximos Locais

Filtro de máximos locais (*local maximum filtering* - LM) é uma técnica utilizada para detecção de copas de árvores em imagens de alta resolução espacial, que se baseia na identificação dos pontos de maior brilho dentro de uma janela de busca que percorre toda a imagem (Ke e Quackenbush, 2011; Pouliot *et al.*, 2002). A janela de busca, de tamanho fixo, define qual pixel é o de maior refletância comparado com todos os outros pixels no interior da janela. Os pixels de maior número digital são identificados como possíveis localizações das árvores. Esse método é bastante adequado para árvores que possuem o ponto máximo de refletância em seu topo, rodeado por pixels de menor intensidade, sendo por concepção, muito utilizado para detecção de coníferas.

Quando uma janela de tamanho fixo passa sobre a imagem, não leva em consideração a presença de árvores com diferentes tamanhos de copa e o sucesso do reconhecimento das árvores com LM depende da cuidadosa seleção do tamanho da janela de busca. Se a janela for muito pequena, erros de comissão ocorrem através da seleção de árvores inexistentes ou múltiplos picos de radiância para uma copa de árvore individual, e se for muito grande, os erros de omissão aumentam (Wulder *et al.*, 2000).




Figura 2.1: Exemplos de superfície obtida pela utilização do filtro LM: (a) imagem original; (b) os máximos locais aparecem na terceira dimensão e são associados à presença de árvores; (c-f) aplicação do LM em quatro filtros lineares cumulativos ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ).

A identificação de árvores pela busca do máximo local é afetada por falsos pixels brilhantes, que não são parte da porção mais brilhante da copa. Um método efetivo para lidar com o problema é aplicar na imagem um filtro gaussiano. Assim, a função de suavização fornece maior peso para pixels próximos comparados com aqueles que estão distantes do centro da máscara, afetando diretamente o número de máximos locais identificados e também causando o arredondamento de valores de brilho das bordas das copas das árvores (Brandtberg e Warner, 2006).

Para minimizar o problema do tamanho da janela com LM, Wulder *et al.* (2000) utilizaram janelas de tamanhos variados, baseadas em resultados da estrutura espacial da imagem, obtidas através do uso de semivariograma com diferentes distâncias de pixels em diferentes janelas. Isso resultou em uma janela personalizada para cada pixel, o que produziu maior acurácia quando comparada com a utilização de uma janela fixa.

Culvenor (2002) utilizou filtragem LM para identificar o centroide de eucaliptos na Austrália. A pesquisa das árvores foi realizada com base nos máximos obtidos por quatro filtros lineares pertencentes às quatro direções principais ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) da imagem e pela soma dos máximos encontrados em cada uma das passagens (Figura 2.1).

Van Coillie *et al.* (2012) propuseram o refinamento da filtragem LM através do que denominaram filtragem local direcional (DLF), buscando não apenas os máximos locais, mas também os mínimos para a detecção de copas de árvores individuais. Os resultados demonstraram que o método permitiu a identificação de cada árvore das imagens sintéticas VHR e

em modelos digitais de altura das árvores, gerados a partir de dados Lidar. Os autores concluíram que a técnica foi útil para a detecção da copa, servindo como um pré-processamento para seu delineamento. É comum a utilização de filtragem LM como uma etapa intermediária para o processo de delineamento das copas.

## 2.1.2 Template Matching

O Modelo de correspondência ou *template matching* (TM) é uma técnica de reconhecimento de objetos consagrada na literatura, sendo incluída na área de decisão teórica, que utiliza descritores quantitativos, como o comprimento, área e textura, para descrever padrões (Gonzales e Woods, 2008; Caves *et al.*, 1992). Técnicas de reconhecimento baseadas em correspondência representam cada classe por um vetor protótipo padrão. Um padrão desconhecido é atribuído à classe para a qual ele é mais próximo em termos de uma métrica pré-definida.

Segundo Gonzales e Woods (2008), em um modelo mais simples de correlação utiliza-se uma máscara de correlação  $\omega(x, y)$  de tamanho  $m \times n$ , com uma imagem  $f(x, y)$ , que pode ser expressa na forma da Equação 2.1:

$$c(x, y) = \sum \sum \omega(s, t) f(x + s, y + t) \quad (2.1)$$

onde  $c(x, y)$  é a correlação e os limites do somatório são feitos sobre a região compartilhada entre  $\omega$  e  $f$ , sendo realizado para todos os valores das variáveis de deslocamento  $x$  e  $y$ , de tal forma que todos os pixels de  $\omega$  visitam cada pixel de  $f$ .

Gonzales e Woods (2008) ainda expõem que ao utilizar a correlação na forma da equação 2.1 haverá sensibilidade às mudanças de escala, tanto no modelo ou *template* ( $\omega$ ) quanto na imagem ( $f$ ). Para evitar esse problema faz-se necessária a utilização de um coeficiente de correlação normalizado (Equação 2.2), denominado modelo de correspondência (ou *template matching*).

$$\gamma(x, y) = \frac{\sum_s \sum_t [\omega(s, t) - \bar{\omega}] \sum_s \sum_t [f(x + s, y + t) - \bar{f}(x + s, y + t)]}{\{\sum_s \sum_t [\omega(s, t) - \bar{\omega}]^2 \sum_s \sum_t [f(x + s, y + t) - \bar{f}(x + s, y + t)]^2\}^{1/2}} \quad (2.2)$$

onde os limites do somatório são feitos sobre a região compartilhada por  $\omega$  e  $f$ ,  $\bar{\omega}$  é a média dos valores da máscara (computados apenas uma vez), e  $\bar{f}(x + s, y + t)$  é o valor médio de  $f$  na região coincidente com  $\omega$ .

Os valores de  $\gamma(x, y)$  variam entre -1 e 1, sendo portanto normalizados para mudanças de amplitude de  $\omega$  e  $f$ . Dessa forma, uma medida de força da correspondência entre o modelo e a imagem de entrada é computada em diferentes deslocamentos relativos para as duas matrizes (Pollock, 1996).




Figura 2.2: Em (a) exemplos de modelos de árvores sintéticas para diferentes formas de copa de árvore com a sombra projetada. Em (b) identificação das copas das coníferas. O modelo utilizado encontra-se no canto inferior direito (Fonte: Larsen (1997)).

Os modelos podem ser gerados sinteticamente ou serem oriundos de uma amostra da imagem. Em termos formais, quando uma porção da imagem é calculada sobre ela mesma, denominamos autocorrelação, e quando as funções são diferentes, denominamos correlação cruzada ou *cross-correlation* (Szeliski, 2010; Gonzales e Woods, 2008).

No campo da detecção de copas de árvores, o estudo de Pollock (1996) foi o primeiro a propor um modelo tridimensional elíptico de copa de árvore como um elipsóide de revolução generalizado (Equação 2.3).

$$\frac{z^n}{a^n} + \frac{(x^2 + y^2)^{n/2}}{b^n} = 1 \quad (2.3)$$

onde  $z$  é o eixo vertical,  $a$  é a metade da altura do elipsóide,  $b$  é metade da largura e  $n$  é o parâmetro de forma da copa da árvore. Em seguida o modelo é iluminado em função das características de absorção e reflexão da copa e das informações de aquisição das imagens.

Por ser baseado em um modelo físico, ao invés de um complexo conceito matemático, TM é considerado um método amigável. Sua limitação se deve principalmente à necessidade de utilização de uma biblioteca de modelos quando muitos tipos de árvores estão presentes na imagem, o que pode envolver uma fase complexa para geração dos modelos. A Figura 2.2 mostra exemplos de modelos de árvores sintéticas e uma aplicação em coníferas.

Larsen e Rudemo (1998) e Larsen (1997) utilizaram essa técnica para identificar copas de árvores em imagens aéreas. Outros pesquisadores utilizaram TM para reconhecimento de copas de árvores individuais com modelos extraídos da própria cena (Quackenbush *et al.*, 2000), ou integrando outras técnicas, como a de máximos locais, para melhorar a performance do método (Larsen, 1997).

Hung *et al.* (2012) propuseram uma versão melhorada através da geração de modelos






Figura 2.3: Resultados do algoritmo *valley-following* em uma imagem de floresta no Canadá (Fonte: Gougeon e Leckie (2003)).

separados para árvores e sua sombra em imagens VHR de veículos aéreos não tripulados (UAV). Os autores exploraram a relação entre os modelos de árvore e a sombra, separadamente, e depois os juntaram para gerar um detector de objetos mais poderoso.

### 2.1.3 *Valley-following*

*Valley-following* (VF) é um método de delineamento da copa que identifica as partes sombreadas entre as árvores. Essa metodologia é inicialmente descrita em Gougeon *et al.* (1995) e faz uma analogia da imagem com dados topográficos, sendo os níveis de cinza dos pixels a terceira dimensão. Nessa analogia, as copas brilhantes das árvores seriam as montanhas e as zonas mais escuras em torno das árvores seriam os vales entre as montanhas. Essa zona mais escura é que tipicamente auxilia interpretadores humanos a separarem as copas das árvores. Primeiramente, as áreas sombreadas sob a vegetação são eliminadas, sendo possível separar as copas das árvores na imagem. Isso não foi suficiente para separar a maioria das copas, então os autores desenvolveram uma abordagem baseada em regras (ex.: continuidade, verificação das direções, contexto, preenchimento de lacunas), que descreve com precisão os limites de cada copa, uma por vez (Gougeon e Leckie, 2003) (Figura 2.3).

Essa abordagem apresenta boa performance para imagens com ângulo de elevação solar baixo e com árvores que possuem forma cônica, que criam zonas de sombra entre os galhos. As limitações estão vinculadas à existência de copas de tamanhos diversos e de grandes copas, em virtude da variação de iluminação no interior das copas maiores pelas sombras delas mesmas, conduzindo à sua subdivisão. As árvores menores, ao contrário, tendem a ser agrupadas. Leckie *et al.* (1999) identificaram que essa abordagem provoca muitos falso positivos em áreas abertas. E como solução, sugeriram a exclusão dessas áreas através da

retenção apenas dos pixels de valor elevado no índice de vegetação da diferença normalizada (NDVI).

Gougeon e Leckie (2006) utilizaram imagens IKONOS para identificar e delinear as copas de árvores em uma plantação de coníferas no Canadá. Para extrair os topos das árvores, os autores utilizaram LM, e para o delineamento utilizaram o algoritmo VF. Concluíram visualmente que não houve um bom delineamento das árvores, havendo a junção de duas ou três árvores em um mesmo objeto. Pontuaram que os resultados são melhores para plantações de mesma espécie e idade.

#### 2.1.4 *Watershed*

O conceito de *watersheds* é baseado na visualização da imagem em três dimensões, na qual a terceira dimensão é dada pela intensidade dos níveis de cinza. Nessa interpretação “topográfica”, três tipos de pontos são considerados: 1) pontos pertencentes a um mínimo regional; 2) pontos em que se uma gota de água fosse colocada em qualquer um desses pontos irá certamente cair para um mínimo; 3) pontos nos quais a água pode cair para mais de um mínimo. Assim, os pontos inseridos em mínimo regional são chamados de bacia de captação ou bacia hidrográfica (*watershed*) do mínimo. Já os pontos para os quais a água pode cair para mais de um mínimo formam linhas de crista na superfície topográfica e são chamados de linhas divisórias ou linhas das bacias hidrográficas (linhas *watershed*) (Gonzales e Woods, 2008).

O objetivo principal do algoritmo *watershed* é encontrar as linhas “divisoras de bacia” ou linhas *watershed*. O “relevo” na imagem é preenchido por água, e quando a mesma está quase transbordando de uma bacia para outra, é construída uma barragem, que seriam as linhas *watershed*. Essas linhas são consideradas o limite de cada segmento. O caminho mais simples para a construção da barragem é o uso da dilatação morfológica, havendo dilatação dos mínimos, sem que haja a mistura de regiões.

O pré-processamento das imagens é usual antes da aplicação da segmentação *watershed*. De fato, essa segmentação é frequentemente aplicada sobre o gradiente de uma imagem, e não para ela mesma, em virtude da homogeneidade dos valores de cinza dos objetos presentes na imagem. Nessa formulação, o mínimo regional das bacias de captação correlacionam satisfatoriamente com o menor valor de gradiente, correspondendo aos objetos de interesse (Szeliski, 2010; Gonzales e Woods, 2008; Beucher, 1992).

A aplicação direta do algoritmo de segmentação *watershed* geralmente leva à supersegmentação em virtude do ruído ou de outras irregularidades locais do gradiente. Uma das abordagens utilizadas para limitar o número de regiões é o uso de marcadores. A seleção dos marcadores pode ser baseada em procedimentos simples com base em valores de intensidade e conectividade ou até em descrições complexas, que envolvem tamanho, formato, localização, distâncias relativas, conteúdo de textura e outras. A utilização de marcadores traz um conhecimento *a priori* para apoiar o problema da segmentação (Gonzales e Woods, 2008).

As abordagens utilizadas para o delineamento de copas de árvores com *watershed* normalmente utilizam marcadores, que representam o centro da copa da árvore, para auxiliar no processo de segmentação. Ou utilizam abordagens híbridas em alguma etapa do processo de delineamento das copas.

Wang *et al.* (2004) utilizaram uma abordagem dividida em duas fases para detectar e delinear copas de árvore em uma imagem VHR sobre uma floresta no Canadá: uma para a detecção da copa utilizando LM e outra para o delineamento. A imagem com as copas detectadas foi produzida a partir da aplicação de um filtro de detecção de bordas laplaciano do gaussiano<sup>1</sup>. As copas das árvores foram modeladas com base em sua geometria e radiometria, resultando em uma imagem de marcadores. Essa imagem serviu para orientar o segmentador *watershed* para o delineamento das copas. Lamar *et al.* (2005) desenvolveram um procedimento bitemporal para a segmentação automática e reconciliação de grupos de pixels (chamados *blobs*) dentro da floresta usando WS. A partir de duas datas, eles foram capazes de aumentar a probabilidade de definir corretamente os contornos da árvore. Porém, muitos problemas foram encontrados no processo de segmentação das árvores individuais. Por exemplo, aquelas com galhos espalhados foram, por vezes, divididas em dois ou mais segmentos ou, ao contrário, várias copas foram incluídas no mesmo segmento quando as árvores não estavam suficientemente separadas.

## 2.1.5 Crescimento de Região

A abordagem de segmentação baseada no crescimento de região (*region growing* - RG) agrupa os pixels ou sub-regiões com base em critérios pré-definidos para o crescimento, a fim de separar regiões e reconhecer objetos na imagem. A partir de alguns pixels “semente” (que podem ser aleatórios, caso os pixels semente não sejam fornecidos), os pixels vizinhos são examinados um a um e adicionados à região de crescimento, se eles têm propriedades predefinidas semelhantes às das sementes (como intervalos específicos de intensidade ou cor) (Gonzales e Woods, 2008). Quando um limite significativo é encontrado, esses pixels são rotulados como pertencendo à região específica do pixel semente.

Critérios adicionais que aumentam o poder de um algoritmo de crescimento de região utilizam o conceito de tamanho, semelhança entre um pixel candidato e os pixels selecionados até o momento (como uma comparação entre a intensidade de um candidato e a intensidade média da região crescida) e o formato da região que está sofrendo o crescimento (Gonzales e Woods, 2008; Bunting e Lucas, 2006).

Culvenor (2002) utilizou a abordagem de crescimento de região integrado com LM para identificação e delineamento das copas de árvores na Austrália. A abordagem LM serviu para

<sup>1</sup>O filtro de detecção de bordas laplaciano do gaussiano foi inicialmente proposto por Marr e Hildreth (1980). Os autores mostraram que se as variações da intensidade local próximas a zero podem ser assumidas como lineares, então é possível empregar o operador Laplaciano no kernel do filtro e depois na imagem (Levine, 1985)




Figura 2.4: Resultados do algoritmo WS para delineamento das copas de árvores e identificação dos topos das árvores em diferentes porções de uma fotografia aérea, afetadas pelo ângulo de obtenção da imagem. Em (a) a porção esquerda da imagem, em (b) a porção central e em (c) a porção direita da imagem (Fonte: Wang *et al.* (2004)).

indicar o centro das árvores, que depois eram utilizados como semente para o crescimento de região. Erickson (2004) utilizou duas abordagens de crescimento de região para segmentar árvores individuais em fotografias aéreas de uma floresta mista na Suécia, uma baseada em movimento browniano e outra em passeios aleatórios - *random walk* - (Figura 2.5). Os métodos foram capazes de detectar cerca de 80% da porção iluminada das copas, sendo identificada melhor performance em copas de maior tamanho.

### 2.1.6 Processos Pontuais Marcados

Um processo pontual (PP) pode ser definido em qualquer número de dimensões no espaço. Pode até ser definido no tempo ou em uma combinação de ambos. Em um espaço multidimensional, um PP é realizado por um conjunto aleatório de locais  $P \{p_i, \dots, p_n\}$  em uma região limitada  $R$  de  $d$  dimensões,  $P \in R^d$ . Se associarmos uma forma específica a cada localização, precisamos considerar que esses objetos também têm uma certa relação uns com os outros. Por exemplo, eles não podem ocupar o mesmo espaço ou, no caso de árvores, só podem se sobrepôr até certo ponto. Nesses casos, um PP pode ser melhor modelado usando um Processo Pontual Marcado (PPM) (M.C.Lieshout (van), 2010), que é um PP acoplado a um segundo processo definido em um espaço de “marcas”  $M$ . O PPM pode ser definido como  $\chi = P \times M$ . Portanto, uma configuração de um PPM pode ser descrita como




Figura 2.5: Exemplo de algoritmos RG para delineamento de árvores em uma floresta Boreal. A imagem original, com resolução espacial de 3 cm, é apresentada em (a), com os resultados das abordagens de movimento browniano (b) e *random walk* (c) (Fonte: Erickson (2004)).

$$\chi = \{(\mathbf{p}_i, m_i) : i = 1, \dots, n\}, p_i \in R^d, m_i \in M \quad (2.4)$$

onde  $\mathbf{p}_i$  são as localizações em  $R^d$  e  $m_i$  são as marcas associadas.

Uma realização de um PPM é então um conjunto de localizações aleatórias em um espaço topológico, juntamente com uma marca predefinida separável, como um ponto, um círculo, um retângulo ou qualquer forma. Considerando que uma imagem pode ser vista como um conjunto de pixels para os quais o nível de cinza é uma realização de uma versão de modelo aleatório desta imagem (Ortner, 2004), o valor ou propriedade dos pixels pode ser modelado usando formas geométricas (ex.: elipses, círculos, retângulos, linhas), sendo respeitadas certas propriedades geométricas (natureza dos objetos) e radiométricas (tipo de imagem).

Segundo Daley e Vere-Jones (2003), em muitos modelos de processos estocásticos, um processo pontual surge não como o objeto primário do estudo, mas como um componente de um modelo mais complexo; freqüentemente, o processo pontual é um componente que carrega a informação sobre as localizações dos objetos no tempo ou espaço que podem eles mesmos ter uma estrutura estocástica e relações de dependência estocástica. Para esses autores, do ponto de vista da teoria dos processos pontuais, muitos desses modelos podem ser classificados sob o título de PPM.

Os PPM vêm sendo recentemente utilizados para o reconhecimento de objetos em imagens de alta resolução espacial (Zhou, 2012; Larsen *et al.*, 2011; Perrin, 2006; Descombes, 2004; Ortner, 2004; Baddeley e Lieshout, 1993). Para tais aplicações, a abordagem PPM tem alguma semelhança com *template matching*. No caso do reconhecimento de copa de árvores, a localização das árvores é governada por múltiplos fatores, um dos quais é a presença de outras árvores (M.C.Lieshout (van), 2010). Como tal, a “marca” da árvore pode

ser simplesmente modelada por um disco ou uma elipse de tamanho variável.

A densidade do PPM também é um fator crítico, especialmente quando se considera o espaço de marcas e as regras que se aplicam a ele. Sua densidade pode ser definida por diferentes funções de distribuição de pontos, como as de Poisson, Strauss, Gibbs ou Markov. Para o reconhecimento de copa de árvores autores utilizaram campos aleatórios Gibbs e Markov (Zhou, 2012; Perrin, 2006; Descombes, 2004). Outros autores utilizaram uma abordagem PPM no processamento de imagens para contagem pessoas em multidões (Ge e Collins, 2009), identificação de edifícios em modelos de superfícies digitais (Ortner, 2004), contagem de pássaros grandes em imagens de alta resolução (Descamps *et al.*, 2011) e detecção e mapeamento de árvores inseridas em vários contextos (Perrin, 2006; Zhou *et al.*, 2011, 2013).

Perrin (2006) propôs dois diferentes modelos com o uso de PPM, um em 2D para a detecção de árvores em zonas densas e outro em 3D para zonas dispersas ou isoladas, a partir de fotografias aéreas de alta resolução espacial na banda do infravermelho. A abordagem é baseada no problema da minimização da energia, onde a energia é composta por um termo de densidade *a priori*, que introduz algumas restrições sobre os objetos e suas interações. Também envolve a ligação dos objetos com as feições a serem extraídas. Uma vez que o objeto de referência foi escolhido, o processo consiste em extrair a melhor configuração dos objetos em relação à energia, utilizando Campo de Markov Monte Carlo com saltos reversíveis, em um método de recozimento simulado (Figura 2.6).

Zhou (2012) utilizou PPM para detectar automaticamente as copas de árvores em imagens de alta resolução espacial, a partir da modelagem das copas como círculos de 2D. Para otimizar a detecção dentro do problema da minimização da energia, a autora utilizou um método de recozimento simulado integrado em um algoritmo de nascimentos e mortes múltiplos. O método foi testado em florestas de mangue e em uma plantação de eucaliptos. Em florestas de mangue o método foi capaz de reconhecer as copas dominantes, mas a resolução espacial de 1 m da imagem Ikonos trouxe maiores dificuldades para detecção, quando comparada às imagens simuladas com resolução de 50 cm. Os resultados em plantações de eucalipto foram encorajadores, permitindo a detecção de árvores no estágio inicial da plantação, a partir da utilização de imagens WorldView-2 com resolução espacial de 50 cm.

Larsen *et al.* (2011) compararam diversos métodos para detecção de copas de árvores individuais em diferentes contextos de floresta e concluíram que a abordagem com PPM apresentou o melhor desempenho para imagens de áreas plantadas e um bom desempenho para imagens com árvores isoladas.

### 2.1.7 Discussão

Nas subseções anteriores foram apresentados seis dos algoritmos mais utilizados para a detecção de árvores individuais, seja para a identificação, o delineamento ou ambos. A Tabela



(a)



(b)

Figura 2.6: Exemplo da aplicação do PPM para reconhecimento de árvores em uma área de floresta plantada. Em (a) a imagem original e em (b) os resultados (Fonte: Perrin (2006)).

2.1 apresenta um resumo dos princípios e das principais características e limitações de cada um desses métodos.

As árvores podem diferir em forma, tamanho, propriedades espectrais, altura, tipo de folhagem e densidade, e seu contexto espacial varia com a iluminação, tipo de superfície e inclinação. Elas também podem ser cercadas por muitos outros objetos, especialmente em ambientes urbanos. Como tal, a tarefa não é trivial e pode tornar-se altamente complexa, dependendo do número de parâmetros envolvidos. Por outro lado, em florestas plantadas e pomares, onde as árvores têm a mesma idade e as mesmas espécies, a extração da copa de árvore pode tirar vantagem da sua relativa uniformidade.

Larsen *et al.* (2011) compararam seis algoritmos diferentes (*valley-following*, *region growing*, *template matching*, teoria espaço-escala, processos pontuais marcados e campos aleatórios de Markov) em seis imagens aéreas diferentes, variando desde uma plantação homogênea, a uma área com árvores isoladas, até uma de floresta decídua extremamente densa. Os autores concluíram que nenhum dos algoritmos pôde, por si só, atingir uma alta taxa de sucesso em todas as imagens testadas, e concluíram que não existe um algoritmo ideal para todos os tipos de imagens e florestas. Eles também enfatizaram que para tipos complexos de florestas, imagens monoscópicas são insuficientes para uma detecção consistente das copas de árvores, até mesmo para intérpretes humanos.



Tabela 2.1: Resumo dos algoritmos filtragem de máximas locais , *template matching*, *valley following*, *watershed*, *region growing* e processos pontuais marcados utilizados para a detecção de árvores individuais. São apresentados os seus princípios, pesquisas de destaque e principais características e limitações.

Algoritmo	Uso	Princípio	Pesquisadores	Características / Limitações
<b>Filtragem de Máximos Locais</b>	Identificação da copa da árvore	Identificação de pontos de maior brilho, correspondentes ao pico das árvores, dentro de uma janela de busca.	Wulder <i>et al.</i> (2000); Culvenor (2002); Pouliot <i>et al.</i> (2002); Wang <i>et al.</i> (2004).	Apropriado para coníferas, que possuem uma forma cônica e ponto de alta refletância correspondente ao topo de árvore. Resultados são afetados pela distribuição espacial das árvores, pela variação no tamanho da copa e pelo tamanho da janela de busca. Tende a aumentar os erros de omissão em janelas maiores e a aumentar os erros de comissão em janelas menores.
<b>Template Matching</b>	Reconhecimento de Padrões	Descritores quantitativos utilizados para descrever padrões. Calcula a correlação entre a imagem e o modelo. O modelo pode ser uma amostra extraída da imagem ou não.	Pollock (1996); Larsen (1997); Larsen e Rudemo (1998); Quackenbush <i>et al.</i> (2000); Erickson (2004); Hung <i>et al.</i> (2012).	Possibilita analisar a copa da árvore com base em suas características espectrais, texturais e estruturais. Permite análise da vizinhança da copa da árvore, por considerar sua sombra. Método amigável. Necessidade de biblioteca de modelos, tornando o método pouco prático para florestas de grande diversidade. Os erros de reconhecimento são aumentados com copas de árvores irregulares. Mais fácil detectar árvores maiores do que as menores. Performance reduzida em ambientes muito densos.
<b>Valley-following</b>	Delineamento da copa da árvore	Deriva de uma analogia de superfície topográfica, sendo programado para identificar a porção sombreada entre as copas das árvores (vales).	Gougeon <i>et al.</i> (1995); Leckie <i>et al.</i> (1999); Gougeon e Leckie (2003); Erickson (2004); Gougeon e Leckie (2006).	Apropriado para árvores com forma cônica, que criam sombras entre os indivíduos. Maior sucesso para delinear populações de mesma idade sem copas entrelaçadas. Melhor performance para imagens com ângulo de elevação solar médio a baixo. Performance reduzida quando as árvores são assimétricas, de diferentes espécies, com copas de tamanhos diferentes, ou quando as sombras das árvores se projetam sobre outras. Tendência a agrupar árvores menores e separar árvores maiores em múltiplos segmentos.

Continua na próxima página ...

Tabela 2.1 – Continuação da página anterior

Algoritmo	Uso	Princípio	Pesquisadores	Características / Limitações
<b>Watershed</b>	Delineamento da copa da árvore	Realizado a partir do gradiente da imagem. A imagem é vista como uma superfície topográfica inundada e invertida para determinar os divisores de bacia. Comumente utiliza marcadores para limitar o número de segmentos.	Wang <i>et al.</i> (2004); Lamar <i>et al.</i> (2005).	Melhor desempenho quando aplicado depois da seleção de marcadores para controle do processo de segmentação. Mais adequado para coníferas, as quais permitem a pré-seleção dos topos das árvores utilizando outra abordagem (filtragem de máximas locais, por exemplo). Segmentação excessiva ocorre quando aplicado diretamente sobre a imagem ou sem a utilização de marcadores. Pode separar a mesma árvore em segmentos diferentes, quando os galhos são muito espalhados, ou pode incluir várias árvores em um mesmo segmento, quando não existe separação espacial entre elas.
<b>Region Growing</b>	Delineamento da copa da árvore	Pixels agrupados ou sub-regiões baseadas em critérios pré-definidos para o crescimento da região, visando separar e reconhecer objetos na imagem.	Culvenor (2002); Pouliot <i>et al.</i> (2002); Erickson (2004); Bunting e Lucas (2006); Pu e Landry (2012).	Formas mais complexas de árvores são mais bem delineadas. Método mais complexo, pois exige diferentes regras para diferentes ambientes. Tende a criar mais que um segmento quando as árvores possuem galhos com porções sombreadas, e tende a agrupar diferentes árvores se elas são muito similares.
<b>Processos Pontuais Marcados</b>	Reconhecimento de Padrões	Processo estocástico no qual pontos desordenados em um espaço são providos com marcas. Marcas são modeladas pela características radiométricas e geométricas dos objetos.	Perrin (2006); Larsen <i>et al.</i> (2011); Zhou (2012)	Melhor desempenho em plantações com árvores de mesma espécie e idade e em imagens de árvores isoladas. É menos efetivo para detectar árvores em ambientes mais diversos.

## 2.2 Avaliação de abordagens existentes

Em virtude da escassez de pesquisas dedicadas à detecção de copas individuais no Brasil, especialmente em ambientes TOF (árvores fora de florestas), optamos pela realização de experimentos para melhor compreensão do problema. Três algoritmos consagrados para tratar do problema da identificação e do delineamento das copas de árvores individuais foram avaliados: 1) modelo de correspondência (*template matching*); 2) crescimento de região (*region growing*); e 3) *watershed*. A performance para identificação das árvores foi testada com as três abordagens, e com as duas últimas, também foi avaliado o potencial para o delineamento das copas.

### 2.2.1 Materiais e Métodos

#### Área Teste

O campus da Universidade Federal de Minas Gerais (UFMG), localizado na cidade de Belo Horizonte, Minas Gerais, Brasil, foi escolhido como área teste (Figura 2.7). A área está inserida em um clima tropical de altitude, com temperatura média de 20°C e precipitação média em torno de 1.200 mm por ano. Duas estações bem definidas caracterizam o clima: uma seca, durante o outono e inverno, e outra chuvosa, que se estende de outubro a março (Lucio *et al.*, 1999). O campus ocupa uma área de 334 ha, parcialmente coberta por fragmentos florestais de cerrado e de floresta estacional semidecidual, bem como árvores plantadas ao longo de ruas e em estacionamentos (de Melo Franco, 2006).

Lombardi e Morais (2003) realizaram uma extensiva amostragem de árvores cultivadas no campus da UFMG e identificaram uma alta riqueza de espécies, sendo 187, distribuídas em 52 famílias, nativas e exóticas, originárias de diferentes partes do mundo (Ásia, África, América do Norte, América Central, América do Sul e Oceania).

As árvores ocorrem em diferentes contextos: plantadas ao longo das ruas, nos jardins dos edifícios, em estacionamentos e em grupamentos florestais. Dependendo de sua localização, os objetos próximos às árvores podem ser grama, asfalto, concreto, telhado, solo exposto ou outras árvores. Árvores individuais, pares de árvores e grupos de árvores entrelaçadas são todos observados de forma indiscriminada. A variação de espécies e contextos é elevada, assim como o tamanho das árvores e de suas copas, além da distância entre elas. Apenas as árvores plantadas em vias públicas, parques e jardins foram avaliadas, haja vista que a detecção de copas em florestas densas é um problema ainda mais complexo.

#### Imagem VHR

Uma imagem WorldView-2 adquirida sobre a área teste serviu para avaliação dos algoritmos. A banda pancromática foi utilizada como ponto de partida para todos os métodos, a fim de




Figura 2.7: Localização da área de estudo. À direita, a imagem WorldView-2 que serviu para realização dos testes, apresentada em uma composição colorida, falsa cor (7R5G3B).

tirar proveito da sua melhor resolução espacial. Para maiores informações sobre a imagem, vide Capítulo 3.

### Algoritmos avaliados

**Template Matching** A abordagem com o algoritmo modelo de correspondência ou template matching (TM) para a detecção das copas de árvore foi baseada no cálculo de uma medida de correlação entre a imagem e um modelo (Caves *et al.*, 1992). Um programa foi desenvolvido em linguagem de programação Python para efetuar a correspondência entre uma pequena porção da imagem (modelo 2D) e uma imagem em escala de níveis de cinza de qualquer tamanho. Cada modelo é movido seqüencialmente através da imagem, de uma maneira semelhante a um operador focal, e a correlação é calculada em cada pixel (Quackenbush *et al.*, 2000). Diante da impossibilidade de avaliar todas as diferentes espécies contidas no recorte selecionado, sete espécies de árvores, consideradas de maior ocorrência, foram escolhidas para serem analisadas: Mangueira (*Mangifera indica*), Amendoeira (*Terminalia catappa* L.), Bisnagueira (*Spathodea campanulata* P.Beauv.), Oiti (*Licania tomentosa* (Benth.) Fritsch), Sete Cascas (*Samanea tubulosa* (Bentham)), Sibipiruna (*Caesalpinia pluviosa* var. *peltophoroides*) e Munguba (*Pachira aquatica* Aubl.). Dessas, três espécies são exóticas e quatro são nativas. Na Figura 2.8 são apresentadas a classificação das espécies de árvores, além de fotografias com perspectiva solo, e vistas superiores de suas copas na

banda pancromática WV-2 e em uma fotografia aérea com resolução espacial de 10 cm. O tamanho do modelo é variável conforme o tamanho da copa e a espécie escolhida. A autocorrelação entre os modelos e a imagem foi calculada utilizando a Equação 2.2, apresentada na Subseção 2.1.2.

Uma imagem de saída é obtida através do cálculo da correlação entre cada modelo e a imagem. As áreas que têm os maiores valores de correlação também possuem os maiores valores de saída da imagem resultante, e correspondem aos locais com maior probabilidade de ser uma copa de árvore. Os sete modelos utilizados resultaram em sete imagens, para as quais estabelecemos um limiar de correlação superior a 0,9 para preservar apenas as áreas com maior correlação entre o modelo e a imagem. As imagens resultantes foram convertidas para o formato vetorial e o centroide de cada polígono foi extraído, de modo a identificar apenas um ponto por objeto, potencialmente localizado no centro da copa árvore.

**Crescimento de região** A segmentação multiresolução, implementada no *software eCognition Developer 8.7* (Definiens AG, 2010), foi utilizada para criar segmentos ou objetos, a qual é baseada no algoritmo de crescimento de região. Esse algoritmo é baseado em critérios ajustáveis de homogeneidade ou heterogeneidade espacial e espectral (Trimble, 2011). A segmentação multinível foi realizada para considerar os diferentes tamanhos de objetos, tanto das árvores como de outros elementos. Neste esquema, uma série de segmentações são sobrepostas, cada uma com um parâmetro de escala sucessivamente menor para identificar objetos sucessivamente menores (Baatz e Schäpe, 2000). Para melhorar o desempenho do segmentador, utilizamos classificação de imagens orientada a objetos (GEOBIA), com base em regras de: geometria, textura, relações de vizinhança, características espectrais e funções de pertinência *fuzzy*, sendo estas aplicadas à análise de dados com graus de incerteza na classificação.

A definição do conjunto de regras é dividida em quatro etapas, que consistem em quatro níveis hierárquicos da rede do objeto (*image object network*): 1) separação de vegetação e não-vegetação; 2) separação da grama; 3) identificação de árvores isoladas; e 4) separação de grupos de árvores. A escolha das escalas de segmentação e das regras de classificação dos objetos foi empírica, com base no conhecimento sobre a área de estudo e na avaliação dos resultados dos diversos testes realizados.

Três parâmetros controlam o processo de segmentação multiresolução: 1) a escala, que regula a variação espectral dos segmentos, e conseqüentemente, o tamanho deles; 2) a compactidade, que é uma ponderação que controla o quão compactos serão os segmentos criados; e 3) a forma, que pondera o peso dado aos valores espectrais e à forma dos segmentos, podendo aumentar ou diminuir as bordas fractais de cada um deles. Juntos, os parâmetros de forma e compactidade determinam a homogeneidade dos segmentos. Apenas a banda pancromática da imagem WV-2 serviu de base para o processo de segmentação. Para todas as segmentações realizadas, apenas o parâmetro de escala foi alterado, sendo mantidas a forma






















Nome Popular / Família / Espécie / Origem	Foto	Copa na WV-2	Copa em Aerolevanteamento
Mangueira ANACARDIACEAE <i>Mangifera indica</i> Exótica Índia			
Amendoeira COMBRETACEAE <i>Terminalia catappa</i> L. Exótica Malásia			
Bisnagueira BIGNONIACEAE <i>Spathodea campanulata</i> P.Beauv. Exótica África			
Oiti CHRYSOBALANACEAE <i>Licania tomentosa</i> (Benth.) Fritsch Nativa			
Sete cascas MIMOSACEAE <i>Samanea tubulosa</i> (Bentham) Nativa			
Sibipiruna CHRYSOBALANACEAE <i>Caesalpinia pluviosa</i> var. <i>peltophoroides</i> Nativa			
Munguba BOMBACACEAE <i>Pachira aquatica</i> Aubl. Nativa			

Figura 2.8: Classificação das espécies de árvores avaliadas. Para cada árvore é exibida uma foto tirada ao nível do solo e duas vistas aéreas, primeiro da imagem pancromática do WV-2 e depois uma fotografia aérea com 10 cm de resolução espacial. As imagens com 10 cm de resolução são do ano de 2008 e foram gentilmente cedidas pela Empresa de Informática e Informação do Município de Belo Horizonte (Prodabel).

(0,3) e compacidade (0,7).

A primeira segmentação foi realizada para separar não-vegetação (edifícios, água, asfalto, concreto, solo exposto, telhados e algumas sombras), com um parâmetro de escala de 10. Um limiar de Índice de Vegetação da Diferença Normalizada - NDVI - ( $\leq 0,19$ ) foi definido para classificar não-vegetação.

No segundo nível, só objetos não classificados (toda vegetação, teoricamente) são utilizados para separar a grama das árvores, que têm a resposta espectral muito semelhante. Os objetos de grama são encontrados em duas escalas diferentes, de modo que duas segmentações foram realizadas nesta etapa: a primeira com um fator de escala de 80, a fim de separar os gramados de maiores dimensões; e uma segunda com um fator de escala 20, para separar áreas menores. Para a definição da classe foram utilizados limiares de NDVI ( $\leq 0,30$ ) e de homogeneidade da matriz de co-ocorrência dos níveis de cinza - GLCM - ( $\geq 0,62$ ) (Haralick *et al.*, 1973). O uso da textura foi relevante, tendo em vista a homogeneidade desta nos gramados, quando comparada com a das copas das árvores.

O terceiro nível foi usado para classificar as copas das árvores isoladas, cercadas por grama ou por não-vegetação. Áreas pequenas, relativamente circulares e circundadas por não-vegetação, tendem a ser árvores isoladas. Então, pequenas árvores classificadas erroneamente como grama foram classificadas com base nos critérios de borda relativa com não-vegetação ( $\geq 0,3$ ) e de forma elíptica ( $\geq 0,64$ ). Áreas relativamente grandes e alongadas não possuem características de serem copas de árvores, então a área do objeto ( $> 500$  pixels) e a relação comprimento/largura ( $\geq 1,7$ ) foram utilizadas para retornarem esses objetos para a classe grama. Uma nova segmentação foi realizada com parâmetro de escala 15. Novamente, a forma relativamente circular e o tamanho de área foram considerados, e regiões com uma forma mais elíptica ( $\geq 0,6$ ) e de maior área ( $\leq 600$  pixels) foram reclassificadas como árvores. Já os objetos com borda relativa com não-vegetação ( $\geq 0,63$ ) e com áreas menores ( $< 600$  pixels) foram classificados como copas isoladas. Para remover as copas classificadas erroneamente, a relação comprimento/largura ( $\geq 1,7$ ) foi novamente utilizada.

O último nível serviu para separar as copas agrupadas. Objetos não classificados foram segmentados com um parâmetro de escala de 20. Funções de pertinência (FP) *fuzzy* de área ( $\leq 700$  pixels), de forma elíptica ( $\geq 0,6$ ) e de relação comprimento/largura ( $\geq 1,3$ ) foram utilizadas para classificar as copas. Borda relativa com não-vegetação e o tamanho dos objetos ( $\leq 600$  pixels) serviram para selecionar pequenos grupos compostos por duas ou três árvores. Finalmente, os objetos restantes foram classificados como copa de árvore, com base em um limiar de NDVI ( $\geq 0,5$ ).

O conjunto de regras dos quatro níveis hierárquicos é apresentado na Figura 2.9.

**Watershed** Para realizar a segmentação da imagem, utilizamos o algoritmo *watershed* implementado no software SPRING (1991-2011, DPI / INPE), um Sistema de Informação Geográfica (SIG) desenvolvido pela Divisão de Processamento de Imagens do Instituto Nacional

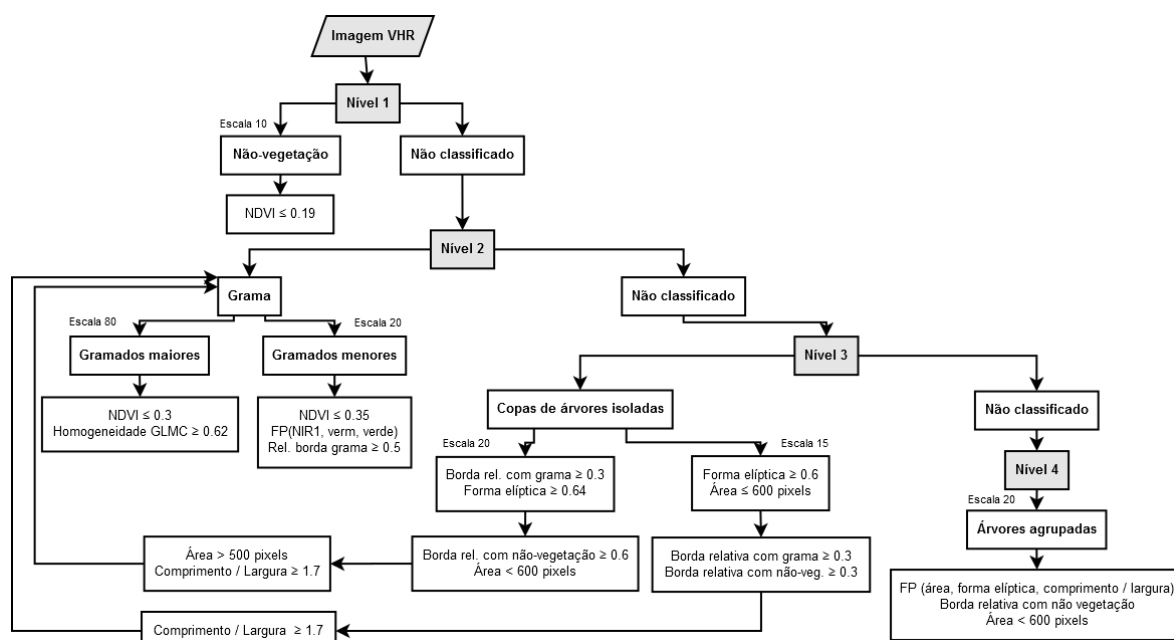


Figura 2.9: Fluxograma com as quatro etapas utilizadas na abordagem crescimento de região multiresolução para detectar e delinear árvores individuais.

de Pesquisas Espaciais do Brasil (INPE). O filtro de extração de bordas de Sobel foi previamente aplicado sobre a banda pancromática para um melhor desempenho da segmentação. Os filtros de Sobel consistem em um operador que calcula as diferenças finitas, dando uma aproximação do gradiente da intensidade dos pixels da imagem. O algoritmo *watershed* implementado no SPRING considera os gradientes de nível de cinza da imagem original para gerar uma imagem de gradiente ou intensidade de borda, resultando em uma imagem segmentada com cada região recebendo um rótulo (Beucher, 1992).

A fim de comparar o desempenho do segmentador, nós realizamos uma classificação supervisionada com o classificador *Bhattacharya* (Richards, 1993). Nesse classificador baseado em objetos, a separabilidade estatística é medida entre um par de classes espectrais e calculada através da distância média entre as distribuições de probabilidades dessas classes. Três classes foram definidas para seleção das amostras de treinamento: não-vegetação, grama e copas de árvores. Todas as bandas WV-2 e o NDVI foram utilizados para a classificação.

## Validação

Para avaliar o desempenho das abordagens TM, RG e *watershed*, uma amostra de 300 copas de árvores foi visualmente interpretada, a partir da banda pancromática do WV-2. Apesar dos modelos serem baseados em sete espécies arbóreas de grande ocorrência, não fizemos distinção entre as diferentes espécies em nossa amostra, mas tentamos escolher uma grande variedade de formas de copa. As árvores amostradas não eram apenas isoladas, mas também



agrupadas, para considerar as situações mais complexas.

Para validar a identificação, uma simples contagem de “certo ou errado” foi realizada. Primeiro contamos quantas das árvores amostradas foram acertadas. Então, utilizamos uma amostra aleatória independente de 114 árvores detectadas pelos três métodos e contamos quantas delas não eram árvores (com base em uma interpretação visual). Esta abordagem permitiu calcular de forma independente a acurácia do produtor e do usuário para cada método, com uma aproximação de acurácia global situada entre os dois.

Como muitas árvores são espacialmente contíguas, a validação da delimitação representava um problema lógico: erros de superestimação de copa (erros de comissão) acabariam por ser subestimados se um segmento estivesse sobreposto a duas copas. Para evitar este problema realizamos uma interseção inclusiva entre os resultados e as amostras de validação (Figura 2.10). Desta forma, asseguramos testar somente a capacidade de segmentação das abordagens para delinear corretamente as árvores.



Figura 2.10: Ilustração da operação de interseção inclusiva.

Para avaliar os resultados para o delineamento das copas, a amostra de validação foi convertida para o formato raster. Para ausência de dados na imagem, foi atribuído número digital igual a um ( $ND = 1$ ) e para a classe copa de árvores, igual a dois ( $ND = 2$ ). Os resultados das abordagens RG e *watershed* também foram convertidos para raster, com valores atribuídos para ausência de dados ( $ND = 3$ ) e copas de árvore ( $ND = 4$ ). As imagens de validação foram então multiplicadas e os valores resultantes foram considerados sucesso para não-árvore ( $ND = 3$ ) e para copa de árvore ( $ND = 8$ ), além dos erros de comissão ( $ND = 4$ ) e omissão ( $ND = 6$ ) (Tabela 2.2). Este método tornou possível produzir uma matriz de contingência para os resultados de delineamento.

Tabela 2.2: Método para o cálculo do sucesso do delineamento das copas obtido a partir da multiplicação entre a matriz de amostras de validação e os resultados das abordagens RG e WS.

Dados	Número Digital	Multiplicação das matrizes
Amostras de Validação	Ausência de dados = 1	Ausência de dados = 3
	Copa de árvore = 2	Erros de comissão = 4
Resultados RG e WS	Ausência de dados = 3	Erros de omissão = 6
	Copa de árvore = 4	Sucesso para copa = 8

## 2.2.2 Resultados

### Identificação das Copas das Árvores

Os resultados da abordagem TM para a detecção de copas de árvores são apresentados na Tabela 2.3. Usando apenas sete espécies foi possível detectar um total de 17.635 copas de árvores. O método foi capaz de identificar 232 das 300 copas de referência com uma acurácia do produtor (1- erro de omissão) de 77,33%. Todos os modelos avaliados foram capazes de detectar um número significativo de copas individuais, mas várias copas estavam presentes em mais de um resultado de modelo avaliado. Por outro lado, vários objetos detectados não eram árvores. Um quadrante da imagem foi separado e selecionamos de forma aleatória 114 objetos detectados pelo método. Desses 114 objetos, 47 não eram árvores, resultando em uma exatidão para o usuário de 58,78% (1- erro de comissão) e produzindo uma precisão global de 68% (média entre as acurácias do produtor e do usuário). A precisão do usuário teve de ser calculada desta forma, por não termos uma amostra de não-árvores. Importante salientar que dentre as espécies analisadas, o modelo da espécie *Licania tomentosa* identificou sozinho 87% das copas de referência. Os resultados obtidos são superiores aos de Quackenbush *et al.* (2000), que utilizaram a mesma técnica na Floresta Huntington, Estado de Nova York, EUA, com oito modelos diferentes e atingiram uma precisão global de 71,2%.

Na Figura 2.11 (a) é apresentada a distribuição das copas detectadas pelos sete modelos utilizados. Nota-se que uma única copa pôde ser identificada por modelos de diferentes espécies, o que significa que, mesmo com diferentes padrões de diversidade florística, forma e textura, os resultados são semelhantes para algumas espécies. As árvores maiores (*Samanea tubulosa* e *Spathodea campanulata*) tiveram a menor pontuação de detecção quando comparadas com as outras espécies avaliadas (Tabela 2.3). Embora tenham sido utilizados sete modelos de sete espécies de árvores, não observamos características específicas (tamanho da copa, altura da árvore, regularidade ou irregularidade da copa) únicas para todas elas e qualquer modelo pôde detectar qualquer espécie.

Tabela 2.3: Resultados da abordagem Template Matching para detecção de copas de árvores individuais.

<b>Modelo</b>	<b>Total de Árvores</b>	<b>Validadas</b>
Mangueira <i>Mangifera indica</i>	2.230	65
Amendoeira <i>Terminalia catappa</i>	2.360	98
Bisnagueira <i>Spathodea campanulata</i>	225	21
Oiti <i>Licania tomentosa</i>	4.607	200
Sete Cascas <i>Samanea tubulosa</i>	1.003	16
Sibipiruna <i>Caesalpinia pluviosa</i>	2.516	153
Munguba <i>Pachira aquatica</i>	3.794	136
<b>TOTAL</b>	<b>17.635</b>	<b>(77,3%) 232</b>

Tabela 2.4: Resultados das abordagens crescimento de região e *watershed* para identificação de copas de árvores.

<b>Abordagem</b>	<b>Árvores Validadas</b>	<b>Acurácia do Produtor</b>	<b>Árvores Invalidadas</b>	<b>Acurácia do Usuário</b>
Crescimento de região	296(/300)	98.66%	103(/114)	90.35%
<i>Watershed</i>	300(/300)	100%	104(/114)	91.22%

As abordagens RG e *watershed* foram altamente eficazes na detecção de copas individuais. A abordagem *watershed* possibilitou detectar todas as 300 amostras dos dados de validação, com uma acurácia do produtor de 100%, e a abordagem de crescimento de região identificou 286 amostras, com uma pontuação de 98,66% (Tabela 2.4). Mais uma vez, a precisão do usuário foi testada pela contagem de quantos objetos eram realmente árvores dentro do quadrante nordeste da área de estudo: *watershed* alcançou uma pontuação de 91,22% (104 corretas de 114) e região de crescimento 90,35% (103 corretos de 114). Nas Figuras 2.11 (b) e (c) são apresentados os resultados para estas duas abordagens. Em ambos os casos, o que define o sucesso ou o insucesso na detecção da copa não é apenas o processo de segmentação, mas também o sucesso da classificação. Se a classificação falhar na identificação dos objetos pertencentes à classe copas de árvores, a precisão global é reduzida drasticamente.

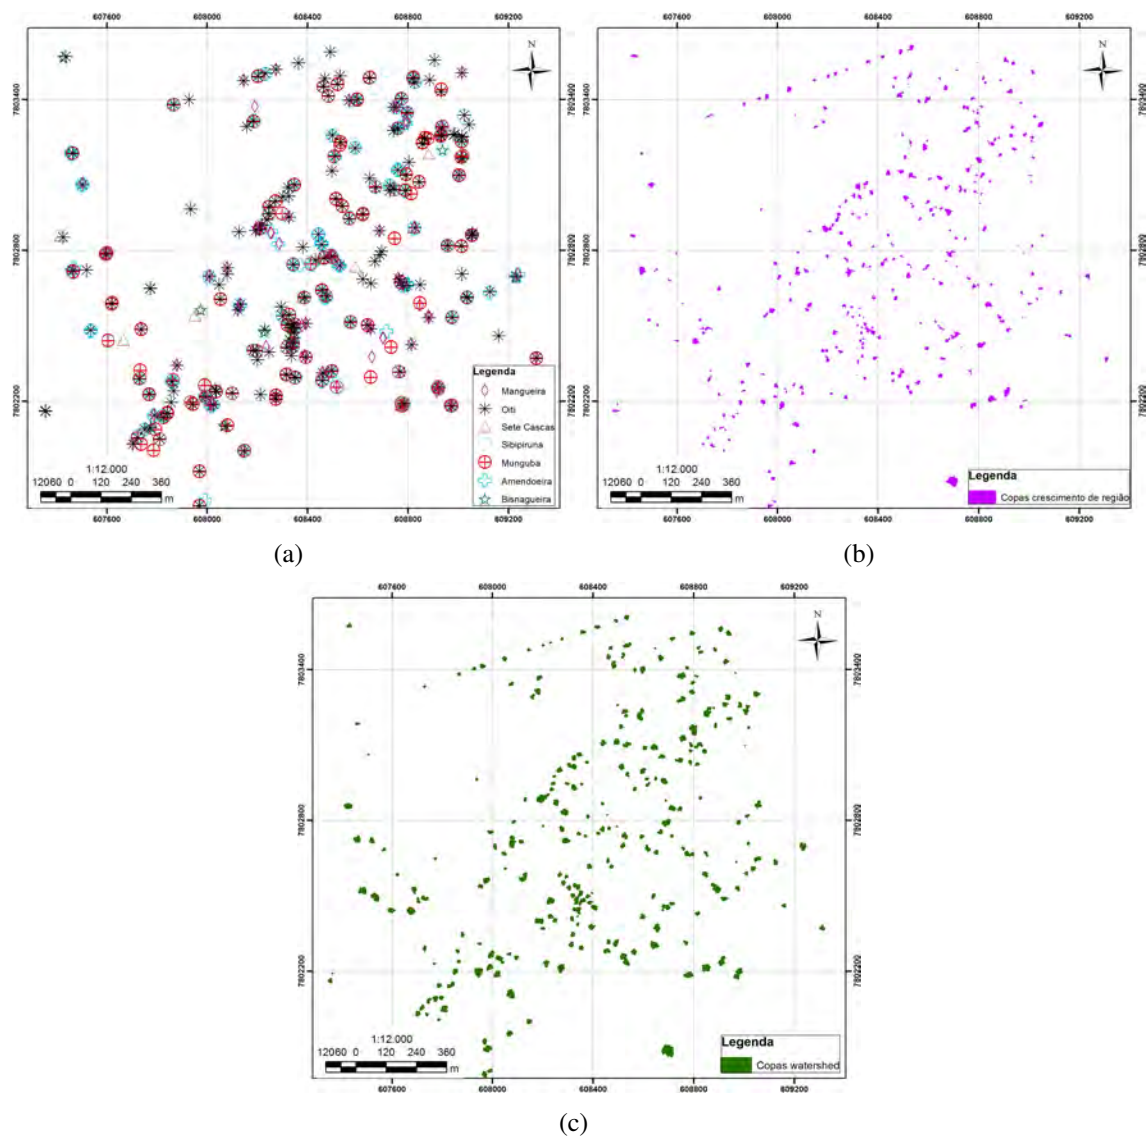


Figura 2.11: Os resultados da detecção de copas individuais com (a) *template matching*, (b) crescimento de região e (c) *watershed*.

Tabela 2.5: Resultados das abordagens de crescimento de região e *watershed* para delimitação das copas de árvores individuais.

Abordagem	Delineamento da copa	Erros de omissão	Erros de comissão
Crescimento de região	106.413 pixels	12.097 pixels	17.394 pixels
	89.79%	10.20%	14.68%
<i>Watershed</i>	99.080 pixels	19.430 pixels	25.405 pixels
	83.60%	16.40%	21.44%

### Delineamento das Copas das Árvores

Erros de comissão ocorrem quando um pixel é classificado como parte da copa, quando na realidade pertence a outra classe. E erros de omissão, quando parte da copa de referência não é detectada. A abordagem com o algoritmo de crescimento de região delimitou corretamente 89,79% dos pixels das copas de validação. Os erros de comissão foram maiores do que os erros de omissão, uma vez que tendem, na maioria dos casos, a superestimar o tamanho dos objetos. O algoritmo *watershed* delimitou corretamente 83,63% das copas, com erros de omissão e de comissão superiores em cerca de 50% quando comparados à abordagem de crescimento de região. Na Figura 2.12 é apresentada uma comparação entre os resultados obtidos pelos dois métodos em uma porção da área de estudo. Os resultados para o delimitamento de copas individuais são apresentados na Tabela 2.5.

A abordagem *watershed* teve problemas com bordas sutis, em virtude da segmentação ser baseada no gradiente da imagem. Isso é notado nos casos em que os galhos da árvore são menos densos e de forma irregular, e que a resposta da superfície abaixo das árvores (sombra e solo) é maior. Como resultado, foram geradas bordas irregulares, muitas vezes incorporadas a segmentos maiores, normalmente correspondentes à grama. Como consequência, houve confusão entre as classes copa de árvore e grama, aumentando erros de omissão, ou erros de comissão, quando porções de grama são classificadas como copa de árvore. Por outro lado, mesmo as menores copas foram identificadas, segmentadas e classificadas corretamente.

Para a abordagem crescimento de região, uma combinação de diferentes níveis e regras foi usada para delimitar as copas. Uma única regra não teria sido capaz de delimitá-las adequadamente sem a contribuição de vários critérios, como geometria, textura, relações de vizinhança e características espectrais. Copas isoladas tendem a ser formadas por apenas um ou dois objetos (porções iluminada pelo sol e sombreada) e essa abordagem obteve maior sucesso em delimitá-las corretamente. Os erros de comissão eram maiores e, geralmente, eram devidos à inclusão de parte da sombra da árvore como copa. O fato das sombras criarem objetos muito compactos no processo de segmentação pode contribuir para este problema. Com a grande diversidade de formas, as áreas iluminadas e sombreadas da copa da árvore




Figura 2.12: Resultados do delineamento de copas de árvores individuais com a abordagem de crescimento de região (a) e *watershed* (b). Note que apenas as árvores de validação são representadas.

muitas vezes criam um padrão complexo que não é facilmente simplificado por um modelo. Pu e Landry (2012) realizaram esta separação, utilizando o NDVI, mas no nosso caso, devido à diversidade florística, os valores de NDVI para a área iluminada de uma árvore eram os mesmos para a área sombreada de outra.

Na Figura 2.13 são comparados os objetos criados pelas duas abordagens. Com o crescimento de região, a forma dos objetos é geralmente bem definida, com uma boa correspondência com a interpretação visual. Já a abordagem *watershed*, como já foi relatado por vários autores na literatura, tende a produzir uma segmentação excessiva dos objetos. Neste caso, pode-se dizer que, sem os dados de validação, seria muito difícil determinar o delineamento de cada uma das copas.

Como a resolução espacial das bandas multiespectrais é mais grosseira (2 m, ao invés de 50 cm), nós não pudemos tirar o máximo proveito dessa informação para a segmentação, e isso foi percebido como um forte fator limitante no processo de classificação.




Figura 2.13: Os resultados do processo de segmentação com crescimento de região (a e b) e *watershed* (c e d)

### 2.2.3 Discussão

Os três métodos testados foram capazes de identificar a maior parte das árvores contidas nas amostras de validação, com taxas de sucesso variando entre 77 e 91%. As abordagens crescimento de região e *watershed* foram superiores à *template matching*, com acurácia do produtor e do usuário superiores a 90%.

Um único modelo (Sibipiruna - *Caesalpinia pluviosa*) foi capaz de identificar cerca de 90% de todas as copas corretamente identificadas pela abordagem TM. Apesar de apresentar

taxas de sucesso ligeiramente inferiores, esse método pode ser considerado atrativo para a identificação das copas das árvores, haja vista a simplicidade de sua implementação.

De maneira geral, os problemas relativos à identificação das árvores residiram, sobretudo, na identificação das espécies decíduas e semidecíduas. Sua avaliação foi prejudicada, seja pelo desafio de incluí-las nos dados de validação, em virtude da dificuldade na interpretação visual, seja por sua alta variância intraclasse. A imagem WV-2 foi obtida na estação seca, e pela fenologia dessas espécies, elas já se encontravam com poucas folhas ou desfolhadas nessa época do ano. Assim, sua resposta espectral é caracterizada pelos troncos e galhos e pela superfície abaixo deles. Isso é um complicador para as análises, tanto para inclusão dessas árvores na classe copa de árvores (já que a copa não possui folhas), como para inclusão dessas árvores em uma mesma classe, pois exemplares de uma mesma espécie localizados em contextos diferentes (ex.: um em calçada de concreto e outro em gramado), possuem respostas espectrais bastante distintas.

Para o delineamento dos objetos, as taxas de sucesso foram de 84 e 90%, com melhor resultado obtido pela combinação de segmentação crescimento de região e de classificação em um ambiente de análise de imagens orientada a objetos geográficos (GEOBIA). Essa abordagem permitiu utilizar não apenas a informação espectral, mas informações sobre a textura, forma, tamanho e relacionamento entre os objetos.

Para o processo de segmentação, apenas a banda pancromática foi utilizada, haja vista sua melhor resolução espacial. Optamos por não utilizar a cena fusionada, em virtude dos ruídos adquiridos no processo de fusão.

A abordagem *watershed*, por ser baseada no gradiente da imagem, atenuou bordas suaves, o que aumentou os erros de comissão pela inclusão de porções de grama nos segmentos de copas de árvore. Porém, o principal ponto a ser observado, foi a supersegmentação, que inviabiliza a correta distinção das copas de árvores individuais, não sendo realística.

A abordagem GEOBIA, embora altamente efetiva, requer a definição de muitos parâmetros, a experiência do usuário, a aquisição de um *software* proprietário de alto custo e ela não é totalmente dedicada ao problema de detecção de copas de árvores individuais. Muitas tentativas foram necessárias até que fosse encontrada a melhor definição dos parâmetros de segmentação e classificação. Incrementar a análise de textura foi relevante para separar os gramados das copas de árvores, porém isso aumentou significativamente o tempo de processamento. Também merece destaque o fato de que, apesar da alta taxa de acerto, os problemas relacionados à inclusão de sombra e grama ao redor das árvores persistiram, o que prejudicou o correto delineamento dos objetos. Soma-se a isso, a divisão das copas em, ao menos, dois segmentos: um correspondente à porção iluminada e outro à sombreada.

Em termos gerais, para aplicação das metodologias testadas em outros contextos e imagens, é necessária a seleção de novos modelos ou amostras, além da atualização, ao menos, dos limiares utilizados no processo de classificação. Porém, se novas classes de objetos forem incluídas (ex.: água, pântano, etc.), novas regras precisarão ser definidas.



## Capítulo 3

# Imagens Sensoriamento Remoto e Imagens Sintéticas

Neste capítulo é apresentado o conjunto de dados de imagens utilizadas para realização dos experimentos. Na primeira seção são apresentadas as imagens sintéticas que foram geradas com o objetivo de criar um ambiente controlado para testes. Na segunda seção são apresentadas as imagens VHR obtidas por sensoriamento remoto orbital.

### 3.1 Imagens Sintéticas

Cinco imagens sintéticas foram geradas com o objetivo de criar um ambiente controlado para realização de testes. Todas elas possuem os mesmos tamanho (300 x 300 pixels), resolução espacial (50 cm) e parâmetros de iluminação, porém, com diferentes densidades e preenchidas por “árvores” de diferentes altura e tamanhos de copa (Tabela 3.1 e Figura 3.1).

A posição das “árvores” foi definida de forma aleatória, a partir do sorteio de coordenadas no espaço amostral da imagem. Caso a coordenada já estivesse ocupada por alguma “árvore”, um novo sorteio era realizado para inserção da copa. Não foi admitida sobreposição entre as “árvores”, mas foi admitida a existência de umas sob a sombra de outras. Para torná-las

Tabela 3.1: Parâmetros utilizados para criação das imagens sintéticas. Os mesmos ângulos de elevação e azimute solar ( $\theta = 45.1$ ,  $\phi = 32.0$ ) foram utilizados para todas as imagens .

Imagem	Raio mínimo (m)	Raio máximo (m)	Densidade/ha	Árvores
1	8.5	10.5	3.88	35
2	5.5	20.5	6.11	55
3	8.5	11.5	6.77	61
4	3.5	15.5	13.88	125
5	4.5	12.5	19.22	173




Figura 3.1: Imagens sintéticas com menor densidade (a-c) e com maior densidade de árvores (d-e), nomeadas sequencialmente de 1 a 5.

um pouco mais próximas da realidade, houve incremento na variância intraclasse através da adição de ruído gaussiano ( $\mu = 0$ ,  $\sigma = 8$ ).

## 3.2 Imagens de Sensoriamento Remoto

Utilizamos seis diferentes conjuntos de dados de imagens de sensoriamento remoto para realização dos experimentos, todas em áreas de árvores fora de florestas (TOF). Das imagens selecionadas, quatro são provenientes do satélite WorldView-2 (Figura 3.2). Apenas a de Belo Horizonte foi adquirida junto ao fornecedor, sendo as outras, amostras de imagens disponíveis na página da *DigitalGlobe* (Figura 3.3), proprietária do satélite WV-2 (<https://www.digitalglobe.com/resources/imagery-product-samples/standard-satellite-imagery>). Outras cenas foram diretamente extraídas do aplicativo *Google Earth* (Figura 3.4). Na Tabela 3.2 é apresentada uma visão geral de cada imagem.

O critério de seleção das imagens óticas orbitais VHR foi, além de sua disponibilidade, a diferença de ambientes TOF (urbanos e rurais) e de características das árvores (naturais, plantadas, isoladas, grupamentos, diferentes espécies e tamanhos de copa). Assim, não há definição de uma área de estudo específica, mas sim a realização de testes em imagens e contextos em áreas TOF.

As imagens WV-2 (DigitalGlobe, Inc., EUA) possuem nove bandas espectrais, uma pancromática, com resolução espacial de 50 cm, e oito bandas multiespectrais, com resolução

Tabela 3.2: Imagens selecionadas, sua localização, resoluções espectrais e radiométricas, e contexto.

Imagem	Satélite	Local	Ano	Bandas	Bits	Contexto TOF
1	WV-2	Campus UFMG, Belo Horizonte, MG	2010	1 px e 8 mx	8	Área urbana
2	WV-2	Parque ecológico da Pampulha, Belo Horizonte, MG	2010	1 px e 8 mx	8	Unidade de conservação em área urbana
3	WV-2	Jardim Botânico Real, Sydney, Austrália	2011	1 px e 8 mx	8	Área urbana
4	WV-2	Plantação de abacateiros, Morro Bay, CA, EUA	2011	RGB	8	Pomares
5	DigitalGlobe	Parque Nacional de Brasília, Brasília, DF	-	RGB	8	Cerrado <i>sensu stricto</i>
6	CNES / Astrium	Remanescente florestal, Itacarambi, MG	-	RGB	8	Mata seca

CNES: Centro Nacional de Estudos Espaciais; CA: Califórnia; EUA: Estados Unidos da América.

espacial de 2 m (Tabela 3.3). A resolução radiométrica é de 8 bits. Não realizamos nenhum pré-processamento nas imagens e as mesmas foram obtidas com correções geométrica (ortorretificada no Datum WGS84, zona Universal Transversa de Mercator - UTMxx) e radiométrica realizadas pela DigitalGlobe.

Quando disponíveis, as bandas multiespectrais foram empilhadas com a banda pancromática. Para isso, foram reamostradas pelo método de interpolação bilinear para a resolução espacial de 50 cm. Novamente, optamos por não realizar a fusão entre as bandas multiespectrais e pancromática, em virtude do ruído resultante desse processamento.

Cinco das imagens selecionadas estão em um contexto de alta diversidade florística, com árvores de tamanhos de copa variados, inseridas em ambientes TOF com diversas classes conceituais. Para verificar o desempenho do método em cenário de plantação, mas com certa heterogeneidade (idades e tamanhos de copa variados), foi selecionada a imagem de Morro Bay, Califórnia, em uma plantação de abacateiros.

Tabela 3.3: Bandas espectrais e resolução espacial das imagens WorldView-2 (DigitalGlobe, 2010).

<b>Banda</b>	<b>Comprimento de Onda (nm)</b>	<b>Resolução Espacial</b>
Pancromática	450-800	50 cm
Costal	400-450	
Azul	450-510	
Verde	510-580	
Amarelo	585-625	2 m
Vermelho	630-690	
<i>Red Edge</i>	705-745	
Infravermelho próximo 1	770-895	
Infravermelho próximo 2	860-1040	



(a)



(b)

Figura 3.2: Imagens WV-2 de Belo Horizonte, MG, Brasil, em composição colorida falsa cor. Em (a), campus da UFMG, onde são observadas árvores em diversos contextos, além de diversas classes conceituais (edifícios, canteiros, asfalto, etc.). Em (b), Parque Ecológico da Pampulha, um parque urbano em processo de revegetação, e por esse motivo são observadas copas de árvores bem pequenas, oriundas do processo de replantio.



Figura 3.3: Em (a) imagem WV-2, em composição colorida falsa cor, do Jardim Botânico Real e seu entorno, localizado na cidade de Sydney, Austrália. Trata-se de um parque urbano circundado por água, prédios e avenidas. Em (b) WV-2 da zona rural de Morro Bay, Califórnia, com árvores em um pomar de abacateiros (imagem em cor natural).




Figura 3.4: Imagens extraídas do aplicativo *Google Earth*. Em (a) imagem *DigitalGlobe*, do ano de 2016, em vegetação de cerrado no Parque Nacional de Brasília, Distrito Federal. Em (b) imagem CNES - Astrium, também do ano de 2016, em um remanescente florestal de mata seca (Floresta Estacional Semidecidual), no município de Itacarambi, Minas Gerais.

## Capítulo 4

# Algoritmo PPM-TM: Abordagem Híbrida para o Reconhecimento de Copas de Árvores em Imagens VHR

No Capítulo 2, Seção 2.2, diferentes algoritmos foram testados em uma cena *WorldView-2* de Belo Horizonte com o objetivo de fornecer um maior entendimento acerca do problema de detecção de árvores fora de florestas (TOF). Dos três algoritmos testados (*region growing*, *watershed* e *template matching*), os melhores resultados foram obtidos pela combinação de segmentação crescimento de região e classificação em um ambiente de análise de imagens orientada a objetos geográficos (GEOBIA). Embora altamente efetiva, a abordagem requer a aquisição de um software proprietário de alto custo, possui certa complexidade para criação das regras de segmentação e classificação, o que requer a definição de muitos parâmetros e experiência, e não é totalmente dedicada ao problema da detecção de copas de árvores individuais.

Os resultados demonstraram que o reconhecimento de TOF em áreas urbanas a partir de imagens VHR é uma tarefa complexa em virtude: 1) da baixa separabilidade espectral existente entre grama e copas de árvores, o que prejudica o correto delineamento dos objetos, uma vez que a sombra é muitas vezes associada como parte do objeto árvore; 2) da diferença na resposta espectral existente entre as diferentes espécies, formas e densidades das copas, reduzindo o sucesso do uso de regras simples para separação de objetos, como por exemplo o uso do NDVI; e, 3) da tendência de divisão das copas em dois objetos distintos, um correspondente à porção iluminada e o outro, à porção sombreada.

Os Processos Pontuais Marcados (PPM) representam uma das abordagens utilizadas para o reconhecimento de objetos em imagens de satélite de alta resolução espacial, como apresentado na Subseção 2.1.6. Podemos destacar os trabalhos desenvolvidos pelo projeto ARIANA (INRIA / *Université Nice - Sophia Antipolis, France*), que utilizaram os PPM para detecção de diferentes objetos em imagens de satélite de alta resolução (ex.: edifícios, pás-

saros, copas de árvores, entre outros). Os testes desses autores foram realizados em imagens “homogêneas” de vegetação, em sua maioria florestas plantadas, à exceção de Zhou (2012), que também testou o método em florestas de mangue. Destaca-se que em plantações as árvores tendem a se desenvolver de maneira semelhante, com disposição e espaçamento conhecidos. O ponto em comum desses trabalhos é a utilização de modelos com um único valor de brilho como marca (círculos ou elipses).

Esses estudos atraíram nossa atenção e nos fizeram considerar que os PPM poderiam se beneficiar com a utilização de modelagem ótica geométrica tridimensional (3D), incorporando métricas de correlação e características radiométricas dos objetos para determinar quais objetos foram corretamente direcionados pelo PPM.

O PPM tirando vantagem do modelo ótico geométrico tridimensional e de medidas de similaridade para buscar copas de árvores pode representar uma melhoria significativa ao invés do uso de marcas mais simples. Considerando essa hipótese, nós desenvolvemos um algoritmo híbrido para detecção de copas de árvores, que combina elementos de PPM, TM e modelagem ótica geométrica da copa para detecção automática de árvores e delineamento (simplificado) de copas de árvores individuais em imagens VHR.

Na nossa abordagem, o modelo não percorre todos os pixels da imagem, forma como o TM foi originalmente concebido, mas sim utiliza uma abordagem PPM para seleção aleatória de coordenadas no espaço da imagem. Isso implica em uma modificação na estratégia de deslocamento da janela de busca do TM, que ao invés de percorrer toda a imagem em busca dos pontos de maior correlação, analisa somente a área e posição direcionadas pelo PPM. Isso soa semelhante a uma abordagem de Monte Carlo, exceto que, no nosso caso, as marcas mantidas após cada iteração limitam o espaço da imagem para a próxima iteração, o que viola levemente a suposição de independência estatística entre os eventos. As marcas 3D recebem um diâmetro aleatório dentro de um intervalo pré-determinado dependendo do ambiente no qual as árvores estão inseridas. O modelo ótico geométrico inclui as porções iluminada e sombreada da copa, além de sua sombra projetada no solo, permitindo assim a inclusão de uma análise de vizinhança e uma melhor correspondência entre o modelo e a imagem.

O algoritmo alterna entre as fases de nascimento e morte, nas quais os objetos são criados (posicionados) e destruídos quando eles não cumprem com as regras de correspondência. Aliado a isso, também propomos a utilização de funções de limiares no processo de decisão de inclusão dos objetos na classe copas de árvores, como o desvio padrão, que adiciona uma análise estatística de textura de primeira ordem.

Diante dessa proposta e com o objetivo de contribuir com esta área do conhecimento, as próximas seções são dedicadas a descrever o processo de construção desse novo algoritmo híbrido desenvolvido especificamente para o problema de detecção de copas de árvores. A abordagem foi desenvolvida em linguagem de programação *Python* com a utilização de diversos módulos e/ou pacotes (*numpy*, *math*, *osgeo*, *shapefile*, *pylab*, *matplotlib*, entre outros).

## 4.1 Modelagem Geométrica das Copas de Árvores em 3D

A primeira etapa da nossa abordagem metodológica é a definição do espaço das marcas que será utilizado pelo PPM. Para Zhou (2012), extrair objetos em uma imagem pelo modelo de processos pontuais marcados consiste em procurar a “melhor” configuração de objetos, ou seja, a que vai respeitar um certo número de propriedades geométricas ligadas à natureza dos objetos (sejam eles pássaros, árvores, carros, edifícios) e radiométricas ligadas ao tipo de imagem (contraste: objeto - meio, vizinhança). Em nossa abordagem, a “melhor” configuração, tanto geométrica quanto radiométrica, é parcialmente fornecida pelo modelo tridimensional da copa da árvore, que indica as instâncias de reconhecimento através da associação de um modelo e de uma localização na imagem.

Vários são os fatores que determinam o padrão de luminância de uma árvore individual: radiação direta e indireta, forma geral da árvore, estrutura de galhos, refletância das folhas, reflexão múltipla no interior da copa, etc. (Pollock, 1996; St-Onge, 1994). Considerando a diversidade de espécies e a variação de formas de árvores existentes em ambientes em diversas áreas TOF, optamos pela utilização de modelos tridimensionais representando as árvores, e simplificamos a forma e o modelo de refletância da copa, a fim de obter um modelo genérico. Nosso modelo pressupõe que o dossel é contínuo e, com base nos princípios da ótica geométrica, a iluminação do modelo varia conforme os parâmetros de iluminação e de forma da copa.

A Subseções 4.1.1 a 4.1.4 são dedicadas à construção do modelo ótico geométrico da copa.

### 4.1.1 Fonte de Luz

A fonte de luz utilizada para a criação do modelo ótico geométrico iluminado é o sol e os parâmetros utilizados são:

- Ângulo de elevação solar ( $\theta$ )
- Azimute solar ( $\phi$ )
- Iluminação difusa ( $amb$ )

Os dois primeiros dados são oriundos dos metadados da imagem VHR e se referem aos parâmetros de iluminação solar no momento da aquisição da imagem. Já a iluminação difusa se refere à componente difusa dos raios solares, que são espalhados pela atmosfera. Esses parâmetros serão utilizados para os procedimentos contidos nas Subseções 4.1.3 e 4.1.4 para geração da sombra da árvore e iluminação do modelo.

### 4.1.2 Geometria da Copa da Árvore

Considerando que a maior parte das árvores possui certa simetria em relação ao seu eixo central, o tronco, isso permite sua modelagem individual como figuras geométricas (cones,






Figura 4.1: Etapas para geração do modelo geométrico de uma copa de árvore. Em (a) a primeira matriz, na qual são definidas a forma e o tamanho da copa, em (b) a segunda matriz, na qual é realizada a projeção da sombra, e em (c) a terceira e última matriz, na qual o modelo é iluminado.

esferas, dentre outras). Com a proposta de construção de um modelo simplificado e abrangente, definimos que o mesmo possui base circular em imagens bidimensionais, sendo a geometria da copa definida por um fator de forma. Nesta fase são utilizados os seguintes parâmetros:

- Raio ( $r$ )
- Diâmetro ( $d$ )
- Parâmetro de forma da copa da árvore ( $\alpha$ )

A distância euclidiana (Equação 4.1) é utilizada para projetar o círculo em uma matriz de tamanho  $r^2 + 1$ , sendo  $r$  o raio e o ponto de origem que simula o centro da árvore.

$$d_{(i,j)} = 1 + \sqrt{(i - r)^2 + (j - r)^2} \quad (4.1)$$

onde  $d$  é o diâmetro da copa,  $r$  é o raio e  $i, j$  corresponde a cada pixel contido na matriz.

Projetado o círculo, a forma ou geometria da copa da árvore é definida com base na Equação 4.2.

$$GC_{(i,j)} = (r \times \rho) + (\sqrt{r^2 - d^2}) \times \alpha \quad (4.2)$$

onde  $GC$  é a geometria da copa da árvore,  $r$  é o raio,  $\rho$  é a altura da árvore, definida como uma proporção do tamanho da copa,  $d$  é o diâmetro,  $i, j$  corresponde a cada pixel contido na matriz e  $\alpha$  é o parâmetro de forma da copa.

Quanto menor o valor  $\alpha$ , mais achatada é a copa da árvore, e quanto maior, mais alongada. O resultado dessa fase é uma matriz sintética de 8 bits *unsigned* (Figura 4.1 a).

A fim de evitar serrilhamento nas bordas do modelo, todas as árvores partem de uma matriz gerada com 100 pixels de raio (muito superior ao de qualquer árvore observada), sendo depois reamostradas para os raios de interesse na imagem a ser analisada.

### 4.1.3 Projeção da Sombra

Optamos por um modelo de copa com sombra projetada, a fim de permitir uma análise dos pixels vizinhos ao objeto árvore. Para projeção da sombra assumimos que a fonte de luz está localizada a uma distância infinita e que todos os raios que atingem o objeto são paralelos entre si, utilizando uma relação geométrica entre a fonte de luz e cada vértice do objeto para calcular a projeção de sua sombra no solo (Figura 4.1 b) (Tso e Mather, 2001; Whitted, 1979).

Os parâmetros utilizados são:

- Ângulo de elevação solar ( $\theta$ )
- Azimute solar ( $\phi$ )
- Matriz resultante da Subseção 4.1.2
- Distância da fonte de luz ( $D$ )
- Altura da árvore ( $h$ )
- Iluminação difusa ( $amb$ )

Atribuímos um valor de 100.000 km para a distância da fonte de luz, uma vez que a fonte de iluminação, o sol, está muito distante dos objetos. Primeiramente, os parâmetros de iluminação foram convertidos para coordenadas cartesianas (Equações 4.3, 4.4 e 4.5):

$$x1 = D \times \sin\left(\frac{\theta * \pi}{180}\right) \times \cos\left(\frac{(\phi - 90) \times \pi}{180}\right) \quad (4.3)$$

$$y1 = D \times \sin\left(\frac{\theta * \pi}{180}\right) \times \sin\left(\frac{(\phi - 90) \times \pi}{180}\right) \quad (4.4)$$

$$z1 = D \times \cos\left(\frac{\theta * \pi}{180}\right) \quad (4.5)$$

onde  $\theta$  é o ângulo de elevação solar,  $\phi$  é o azimute solar e  $D$  é a distância da fonte de luz.

Então, considerando que os raios são paralelos, a partir de dois pontos (ponto de luz ( $x1, y1, z1$ ) e ponto que se deseja iluminar ( $xp, yp, zp$ )), o ponto de sombra ( $xs, ys, zs$ ) é obtido a partir de triângulos similares, equação que pode ser expressa na forma da matriz apresentada na Equação 4.6:

$$M_s = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ -x1/z1 & -y1/z1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.6)$$

onde  $M_s$  é a matriz para projeção da sombra, e  $x1, y1$  e  $z1$  são as coordenadas cartesianas para o ponto de luz.

Então, dadas as coordenadas globais para qualquer ponto da copa da árvore, a coordenada dos pixels de sombra é calculada através da Equação 4.7:

$$P_s = (CA_p + h) \times M_s \quad (4.7)$$

onde  $P_s$  é a posição da sombra projetada para o pixel  $CA_p$  da matriz com a copa da árvore,  $h$  é altura da árvore e  $M_s$  é a matriz para projeção da sombra.

Ao final, os pixels projetados correspondentes à porção de sombra são preenchidos com o valor da iluminação difusa. O *background* e a interreflexão entre as árvores foram ignorados.

Após a projeção da sombra, é possível aplicar um fator de corte na matriz, com valores entre [0,1]. O fator de corte permite a utilização de toda, de parte ou de nenhuma sombra para o processamento das imagens, adequando-se a casos de árvores isoladas ou agrupadas. Portanto, quando se deseja utilizar toda a sombra o valor de corte é igual a zero, podendo ser progressivo até o total corte na sombra, com valor igual a 1.

#### 4.1.4 Interação entre Luz e Copa

A iluminação é adicionada na terceira e última etapa, considerando:

- Ângulo de elevação solar ( $\theta$ )
- Azimute solar ( $\phi$ )
- Iluminação difusa ( $amb$ )
- Máxima radiância do modelo ( $L_M$ )
- Matriz resultante da Subseção 4.1.3.

Assumimos que a superfície da copa possui um comportamento lambertiano ( $L$ ), ou seja, que a superfície reflete a radiação incidente uniformemente em todas as direções (Tso e Mather, 2001). Realizamos uma pequena alteração no modelo de radiância para adicionar a iluminação difusa ao final do processo (Equações 4.8 e 4.9):

$$L = L_M \left( \frac{\cos\theta_s}{\cos\theta_i} \right) + amb \quad (4.8)$$

onde  $L_M$  é a máxima radiância do modelo,  $\theta_s$  é o ângulo de elevação solar,  $\cos\theta_i$  é o ângulo de incidência entre o sol e a normal da superfície da copa e  $amb$  é a iluminação difusa.

Sendo  $\cos\theta_i$  obtido por:

$$\cos(\theta_i)_m = \{ \cos(\theta_s)\cos(\theta_n) + \sin(\theta_s)\sin(\theta_n)\cos(\phi_s - \phi_n) \} \quad (4.9)$$

onde  $\theta_s$  é o ângulo zenital solar,  $\theta_n$  é o ângulo de declividade da superfície do objeto,  $\phi_s$  é o ângulo azimutal solar e  $\phi_n$  é o aspecto da superfície do objeto.

A iluminação de cada pixel se fez pela iluminação direta sobre a camada de inclinação, de orientação e de refletância de cada ponto (Equações 4.10 e 4.11).

$$\arctan \theta_n(rad) = \sqrt{a^2 + b^2} \quad (4.10)$$




Figura 4.2: Análise do relacionamento dos pixels vizinhos ao pixel Z5 para obtenção das declividades na posição horizontal (a) e vertical (b) .

$$\arctan \phi_n(rad) = \frac{a}{b} (-\pi < \phi_n < \pi) \quad (4.11)$$

A declividade e o aspecto podem ser derivados a partir de dois filtros  $3 \times 3$  ponderados, com maior peso nos pixels circundantes ao pixel analisado, sendo um filtro horizontal e outro vertical. Esse processo é ilustrado na Figura 4.2. E as Equações 4.12 e 4.13 foram utilizadas para definir os valores de  $a$  e  $b$ .

$$a = (z3 + 2z6 + z9 - z1 - 2z4 - z7)/8 \quad (4.12)$$

$$b = (z1 + 2z2 + z3 - z7 - 2z8 - z9)/8 \quad (4.13)$$

onde  $a$  é a declividade na posição horizontal ou eixo  $x$ ,  $b$  é a declividade na posição vertical ou eixo  $y$  e  $z$  corresponde ao valores dos pixels nas posições circundantes ao pixel analisado.

Cada pixel da camada de radiância caracteriza a porcentagem de luz que retornou até o observador, segundo o tipo de superfície - árvore ou terreno (Figura 4.1 c). Nessa etapa final atribuímos um valor negativo para o entorno da copa e da sombra, para que somente a copa da árvore e sua sombra fossem consideradas no processamento das imagens.

#### 4.1.5 Parâmetros de Entrada para Criação do Modelo

Como apresentado na Seção 1.2, somente as bandas pancromáticas de sensores óticos orbitais VHR possuem resolução espacial inferior a 1 m, sendo o modelo desenvolvido para ser utilizado em uma única banda espectral.

O modelo ótico geométrico pode ser modificado conforme a imagem a ser processada, com as seguintes variáveis de entrada:

- Raios mínimo e máximo [ $r_{min}, r_{max}$ ]
- Geometria da copa da árvore ( $\alpha$ )
- Parâmetros de iluminação ( $L_M, \theta, \phi, amb$ )




Figura 4.3: Exemplos de geometria da copa: à esquerda, a geometria da copa é elíptica horizontal, com valor  $\alpha = 0.5$ ; no centro, a geometria de uma meia esfera, com valor  $\alpha = 1$ ; e à direita, a geometria da copa é elíptica vertical, com valor  $\alpha = 2$ . Para todas os exemplos foram utilizados os mesmos parâmetros de raio e iluminação solar.

- Fator de corte para eliminação de parte da sombra [0, 1]

Na Figura 4.3 são apresentados três modelos de mesmos raio e parâmetros de iluminação, mas diferentes geometrias de copa. Note que a luminância e a sombra são variáveis conforme a geometria da copa.

A Figura 4.4 ilustra o efeito da utilização de toda a sombra ou de apenas uma parte dela, em comparação com uma árvore extraída de uma imagem WV-2.

Os modelos gerados dentro do intervalo de raios definido são armazenados em uma biblioteca de modelos de copas de árvores que serão utilizadas para o reconhecimento dos objetos. Paralelamente, são também armazenadas máscaras contendo as porções iluminada e sombreada de cada modelo, que serão posteriormente utilizadas para geração das métricas de cada objeto. O Algoritmo 1 apresenta o processo de criação das máscaras.

Sendo  $L_{min}$  dado por:

$$L_{min} = (L_M \times \cos\theta_s) + amb \quad (4.14)$$

onde  $L_{min}$  é a mínima radiância na porção iluminada da copa,  $L_M$  é a máxima radiância do modelo,  $\theta_s$  é o ângulo zenital solar e  $amb$  é a iluminação difusa.

Na Figura 4.5 (a) é apresentado um modelo com geometria de copa  $\alpha = 1.5$  e parâmetros de iluminação  $45^\circ$  e  $32^\circ$  para elevação e azimute solar, respectivamente. E as porções sombreada e iluminada, respectivamente, para mesmo modelo, são apresentadas na Figura 4.5 (b) e (c). Note que a área para cada uma dessas porções irá variar conforme os parâmetros




Figura 4.4: Comparação entre uma árvore isolada em uma imagem *WorldView-2* (a) e o modelo ótico geométrico 3D, com fator de corte igual a zero, ou seja, toda a sombra incluída (b). Em (c) a mesma árvore na imagem com destaque a somente uma parte de sua sombra, e em (d) o mesmo modelo com um fator de corte de 0.85, que possibilita a utilização de apenas parte da sombra para reconhecimento dos objetos.

---

**Algoritmo 1** CRIAÇÃO DAS MÁSCARAS COM AS PORÇÕES SOMBREADA E ILUMINADA DA COPA

---

**Entrada:**  $r_{min}, r_{max}, \theta, \phi, amb, L_M$ ;

**Saída:** Geração dos Modelos 3D e máscaras das porções iluminada e sombreada

**início**

    Gera os modelos 3D e armazena em uma lista

**para cada** *pixel de coordenada  $x,y$  do modelo 3D* **faça**

        A verificação a partir de uma matriz de mesmo tamanho da copa;

**se**  $L < L_{min}$  **então**

            Corresponde à porção sombreada ;

**senão**

            Corresponde à porção iluminada

**fim**

**fim**

**fim**

**retorna** *Máscaras correspondentes às porções iluminada e sombreada da copa*

---




Figura 4.5: Esquema de divisão do modelo (a) nas porções sombreada (b) e iluminada (c) da copa.

de iluminação da cena e de geometria da copa.

## 4.2 Algoritmo PPM-TM

### 4.2.1 Processo Pontual Marcado

Como apresentado na Seção 2.1.6, o PPM visa identificar as características de pontos que possuam relação com suas marcas (características de cada ponto). Sendo uma realização do processo estocástico  $\Psi$ , um conjunto de posições juntamente com as marcas associadas:

$$\Psi = [x_i, m(x_i)] \quad (4.15)$$

onde  $\Psi$  é o processo estocástico que gera os pontos  $x_i$  e as marcas associadas aos eventos no plano, e  $m$  são as marcas associadas a esses pontos.

De acordo com Chiu *et al.* (2013), existem diferentes tipos de PPM, que podem ser definidos pelas seguintes características:

- Padrão espacial
- Tipo de processo estocástico
- Intensidade do processo
- Propriedades estatísticas
- Modelo teórico
- Formas de análise

O **padrão espacial** do PPM se refere à localização dos pontos e a relação entre eles, podendo ser aleatório (árvores em áreas urbanas), regular (árvores em uma plantação) e agrupado (remanescentes florestais).

O **processo estocástico** pode ser de primeira ordem ou global, ou de segunda ordem ou local, também chamado de pequena escala. O primeiro se refere a eventos por unidade de

área e o segundo à dependência espacial do processo, a partir do relacionamento entre pares de eventos no espaço.

A **intensidade do processo** é de primeira ordem quando é considerado o valor limite da quantidade de eventos por área, sendo o conjunto de pontos analisado para todo espaço de configurações  $S_p$  (Equação 4.16). As propriedades de segunda ordem possuem a mesma definição, porém considera-se a intensidade conjunta entre duas regiões  $ds$  que contêm os pontos.

$$\lambda(x) = \lim \frac{E[N(ds)]}{|ds|} \quad (4.16)$$

onde  $\lambda$  é a intensidade do PPM,  $x$  é o ponto,  $E[N(ds)]$  é o valor esperado do número de eventos no espaço de configurações ( $S_p$ ) e  $ds$  é a região em torno do ponto  $x$ .

Os PPM podem ser estacionários e isotrópicos, no que se referem às suas **propriedades estatísticas**. Um processo é estacionário se suas características são invariantes para todo o conjunto (Equação 4.17).

$$\lambda(x) = \lambda \quad (4.17)$$

Quando as características são invariantes sobre a rotação (depende somente da distância euclidiana entre os pontos e não da direção deles), o processo é isotrópico (Equação 4.18).

$$\lambda(x_i, x_j) = \lambda(|h|) \quad (4.18)$$

sendo  $h$  a distância entre dois pontos.

Quando um processo é estacionário e isotrópico ele é chamado de movimento invariante. A maior parte das técnicas de análise de distribuição de pontos supõe um comportamento estacionário e isotrópico do processo aleatório subjacente aos eventos analisados (Guan, 2008; Olinda, 2008; Baddeley *et al.*, 2000).

A análise estatística dos padrões de distribuições de pontos requer um modelo teórico de referência para o desenvolvimento de métodos formais que checam a significância dos resultados exploratórios (Chiu *et al.*, 2013). O **modelo teórico** mais simples é o que assume a completa aleatoriedade espacial, situação em que é provável que um evento aconteça em qualquer local dentro da área de estudo, embora os locais sejam de outros eventos, e são independentes um do outro. No modelo de completa aleatoriedade espacial considera-se que as ocorrências em cada subárea sejam não correlacionadas, estando associadas à mesma distribuição de probabilidade de Poisson (Equação 4.19).

$$P(X = x) = \frac{\lambda^x e^{-\lambda}}{x!} \quad (4.19)$$

onde  $P(X = x)$  é a distribuição de Poisson,  $X$  é a variável aleatória que representa o número de sucessos,  $\lambda$  é a intensidade do processo.



Isso se traduz na afirmação que a posição dos eventos é independente e que os eventos possuem igual probabilidade de ocorrer em todo o espaço  $S_p$  (Equação 4.20).

$$\lambda = \frac{x}{S_p} \quad (4.20)$$

onde  $\lambda$  é a intensidade do processo,  $x$  são os pontos e  $S_p$  é o espaço amostral.

A partir das propriedades de primeira ou de segunda ordem dos PPM, pode-se utilizar alguma medida como **forma de análise** para descrever a variabilidade dos pontos e de suas marcas, sendo possível descrever a correlação entre eles em diferentes escalas.

No algoritmo proposto, assumimos que o PPM possui um padrão espacial aleatório em um processo estocástico de primeiro grau, sendo estabelecido um valor limite da quantidade de eventos possíveis dentro do espaço amostral, ou seja, a imagem analisada. A intensidade do processo é dada pelo número médio de pontos por unidade de área (Equação 4.21):

$$\lambda = A_\chi \times D_{max} \quad (4.21)$$

onde  $A_\chi$  representa a área de pesquisa na imagem (ha) e  $D_{max}$  é a densidade máxima de árvores por hectare.

O modelo é movimento invariante, ou seja, estacionário e isotrópico, e é relacionado aos efeitos de primeira ordem. Isso significa que assumimos que a intensidade do processo que gerou o padrão espacial é constantemente igual a  $\lambda$  em toda a área de estudo e os eventos possuem propriedades semelhantes em todos os locais da imagem e, por ser isotrópico, os pontos são independentes entre si.

Assumimos, ainda, que as ocorrências estão associadas à mesma distribuição de probabilidade de Poisson, sendo a densidade do processo estimada pelo usuário. O fato de que as marcas são *a priori* não-sobrepostas caracteriza um modelo “*germ-grain*” que pode ser visto como um caso especial de PPM (Chiu *et al.*, 2013).

A forma de análise do PPM é dada principalmente pela medida de semelhança ( $Sm$ ), que define a correlação entre marcas e pontos (Equação 4.22).

$$Sm = \gamma - \alpha \times Dif \quad (4.22)$$

onde  $\gamma$  é a correlação cruzada entre os valores de radiância do modelo e os níveis de cinza dos pixels na porção analisada da imagem (Equação 4.23),  $Dif$  é a medida de diferença absoluta normalizada (Equação 4.24) e  $\alpha$  é um fator que pondera  $Dif$ .

$$\gamma = \frac{1}{n} \sum_{x,y} \frac{(f_{(x,y)} - \bar{f})(\omega_{(x,y)} - \bar{\omega})}{s_f s_\omega} \quad (4.23)$$

$$Dif = \left| \frac{\sum_{x,y} f_{(x,y)} - \sum_{x,y} \omega_{(x,y)}}{\sum_{x,y} f_{(x,y)} + \sum_{x,y} \omega_{(x,y)}} \right| \quad (4.24)$$

onde  $\omega$  o valor de radiância do modelo,  $f_{(x,y)}$  são os níveis de cinza dos pixels na porção analisada da imagem,  $S_f$  e  $S_\omega$  são os desvios padrões para  $f_{(x,y)}$  e  $\omega_{(x,y)}$ .

Os valores de  $Sm$  podem variar entre  $[-1-\alpha, 1]$ , sendo igual a 1 quando a diferença ponderada entre os valores de radiância do modelo e os níveis de cinza da imagem ( $\alpha \times Dif$ ) é igual a 0, e a correlação cruzada é igual a 1.

A proposta atribui flexibilidade na métrica que correlaciona os pontos e suas marcas, na qual não é necessário conhecer o valor exato de  $Sm$  de um ponto para criar a dependência entre os pontos e as marcas, apenas atribuir um intervalo para a métrica ( $[Sm_{min}, Sm_{max}]$ ). O processo de busca das árvores é baseado em sucessivos nascimentos e mortes, e durante um intervalo determinado de iterações ( $Iter_{Sm}$ ) ocorre leve decaimento no valor da semelhança, tornando esse valor temporário ( $Sm_t$ ). Assim, se o valor de semelhança do objeto ( $Sm_i$ ) for menor que o  $Sm_t$ , caracteriza repulsão entre as marcas. Porém, à medida que o processo avança e ocorre a flexibilidade no valor de semelhança ( $Sm_i = Sm_t$ ), marcas antes repulsas passam a se “atrair” nas fases mais avançadas do processo.

## 4.2.2 Alternância das Fases de Nascimento e Morte

### Fase de Nascimento

O PPM começa com uma fase de nascimento, onde as copas de raios aleatórios  $[r_{min}, r_{max}]$  são inseridas em coordenadas aleatórias dentro do espaço  $S_p$  da imagem. À medida que todas as copas forem atribuídas, a semelhança entre o modelo de raio aleatório ( $\omega_i$ ) e a porção correspondente da imagem é calculada. Caso a coordenada gerada aleatoriamente já esteja preenchida por uma copa, uma nova coordenada é sorteada até encontrar um espaço “vazio” e preenchê-lo com um modelo representando uma copa.

Uma vez que todos os círculos ( $\lambda$ ) tenham sido posicionados na imagem, o processo segue para o cálculo e armazenamento das seguintes informações e estatísticas para cada um dos objetos:

- Posição  $(x,y)$
- Correlação entre o modelo e a imagem ( $\gamma$ )
- Diferença entre o modelo e a imagem ( $Dif$ )
- Semelhança entre o modelo e a imagem ( $Sm$ )
- Raio ( $r$ )
- Média ( $\mu$ )
- Desvio padrão ( $\sigma$ )
- Índice de identificação ( $I$ )

A Figura 4.6 (a) apresenta um exemplo da fase de nascimento, evidenciando os círculos de raio aleatório, distribuídos de forma aleatória na imagem ( $\lambda = 163$ ).

Ao fim da fase de nascimento são calculados os valores médios de  $Sm$ ,  $\mu$  e  $\sigma$  para todo o conjunto de objetos criados, com intuito de avaliar a evolução global do processo. Os




Figura 4.6: Exemplo da fases de nascimento (a) e morte (b). Neste exemplo um alto limiar de semelhança ( $Sm = 0.98$ ) é buscado entre o ponto e a marca, e após 175 iterações, um objeto foi reconhecido e preservado.

objetos criados são, então, ordenados em função do valor de  $Sm$  para dar início à fase de morte (Algoritmo 2).

### Fase de Morte

A fase de morte consiste na avaliação da dependência ou repulsão entre os pontos e as marcas (Algoritmo 3). Se o objeto criado possuir um valor de  $Sm$  maior ou igual ao estabelecido, é criada dependência entre o ponto e a marca, e o objeto é preservado. Caso essa condição não seja atendida, há repulsão entre o ponto e a marca, e o objeto é eliminado. A fim de melhor avaliar e caracterizar a dependência entre os pontos e as marcas, foi também inserida uma análise de textura de primeira ordem dos objetos, através de um intervalo de desvio padrão ( $[\sigma_{min}, \sigma_{max}]$ ).

Na Figura 4.6(b) é apresentado o resultado do reconhecimento de um objeto após a fase de morte, no qual foi criada dependência entre o ponto e a marca.

### Recursividade e Flexibilidade da Métrica de Análise

O processo é recursivo, com sucessivos nascimentos e mortes. Os objetos preservados na fase de morte são novamente inseridos no processo de nascimento, e novos objetos são criados até que  $\lambda$  seja atingido. Por exemplo, se  $\lambda$  é igual a 100, e após a fase de morte 10 objetos são preservados, no próximo nascimento os 10 objetos preservados serão mantidos e 90 novos objetos serão criados. Assim, os objetos que possuem a melhor configuração a cada iteração são preservados. Isso conduz a uma melhora progressiva do conjunto à medida que mais árvores são encontradas.

Um dos seguintes critérios é capaz de terminar o processo:

- Se o valor de  $Sm$  alcançar o valor mínimo ( $Sm_{min}$ )
- Se o número máximo de iterações for atingido ( $Iter_{tot}$ )

---

**Algoritmo 2** FASE DE NASCIMENTO

---

**Entrada:** *Imagem.geotiff*,  $\lambda$ , catálogo de modelos ( $\omega [r_{min}, r_{max}]$ );

**Saída:** Imagem preenchida com círculos aleatórios de raio aleatório sobrepostos na imagem;

**início**

**enquanto** contador for menor que  $\lambda$ ;

**faça**

    Sorteio do modelo de raio  $r$  no catálogo de modelos;

    Sorteio de coordenadas aleatórias no espaço da imagem;

    Verifica se o espaço está ocupado por outro objeto;

**se** não há objeto na coordenada sorteada;

**então**

        Define o diâmetro e preenche a área correspondente na imagem resultante;

        Extrai a porção da imagem correspondente ao modelo;

        Compara o modelo com a porção sobreposta na imagem;

        Calcula e armazena informações e estatística do objeto ( $x, y, \gamma, Dif, Sm, \mu, \sigma, r, I$ );

**fim**

**fim**

  Calcula valores médios do conjunto ( $Sm, \mu$  e  $\sigma$ );

  Ordena os objetos em função de  $Sm$ ;

**fim**

---

---

**Algoritmo 3** FASE DE MORTE

---

**Entrada:** imagem resultante do nascimento, estatísticas dos objetos (ordenados em função de  $Sm$ ), limiar de  $Sm, [\sigma_{min}, \sigma_{max}]$  e  $\omega [r_{min}, r_{max}]$ ;

**Saída:** imagem com objetos reconhecidos como copa de árvore (dependência entre ponto e marca);

**se**  $Sm_i < Sm$ ;

**então**

    Zera os valores na imagem resultante do nascimento e as estatísticas do objeto;

**se**  $\sigma_{min} \leq i \leq \sigma_{max}$ ;

**então**

        Zera os valores na imagem resultante do nascimento e nas estatísticas do objeto;

**fim**

**fim**

---

---

**Algoritmo 4** RECURSIVIDADE DO ALGORITMO PPM-TM
 

---

**Entrada:** *Imagem.geotiff*,  $\lambda$ ,  $[Sm_{min}, Sm_{max}]$ ,  $\omega$   $[r_{min}, r_{max}]$ ,  $[\sigma_{min}, \sigma_{max}]$ ;

**Saída:** Segmentação dos objetos reconhecidos na imagem e suas informações e estatísticas;

**início**

Executa a fase de nascimento

**enquanto** não atingir os critérios para terminar o processo ( $Iter_{max}$  ou  $Sm_{min}$  ou  $Iter_{tot}$ );

**faça**

    Fase de morte;

    Ordena os objetos preservados em função de  $Sm$ ;

**se** contador  $\doteq$   $Iter_{Sm}$  ;

**então**

        | Decai  $Sm$  em 0.01 ;

**se**  $i < (Iter_{tot} - 1)$ ;

**então**

        | Executa a fase de nascimento;

**fim**

**fim**

---

- Se todas as árvores forem encontradas ( $\lambda$ )

Atribuir flexibilidade na métrica que correlaciona os pontos e suas marcas, através da definição de semelhanças mínimas e máximas  $[Sm_{min}, Sm_{max}]$ , dispensa a necessidade de conhecimento do valor exato de semelhança para criação da dependência entre os pontos e as marcas.

Inicialmente são buscados os objetos que possuem as mais altas correlações entre pontos e marcas ( $Sm_{max}$ ). À medida que o processo avança e nenhuma nova árvore é identificada na imagem, o valor de  $Sm$  decai em 0.01 (semelhança temporária -  $Sm_t$ ) se um certo número de iterações for atingido (iteraões para mudança no valor de  $Sm$  -  $Iter_{sm}$ ), alterando o critério de avaliação entre pontos e marcas. A lógica desse processo é baseada na busca do melhor delineamento possível a partir de um único modelo genérico. Portanto, as árvores mais parecidas com o modelo são inicialmente identificadas, e as árvores menos parecidas também possuem a chance de serem identificadas e delineadas nas fases mais avançadas do processo, haja vista o decaimento progressivo nos valores de  $Sm$ . Se nenhum dos critérios para terminar o processo forem atingidos ( $Iter_{tot}$  ou  $\lambda$ ), o processo é repetido até que o  $Sm_{min}$  seja atingido. Ao alcançar  $Sm_{min}$ , o processo é terminado após um determinado número de iterações ( $Iter_{max}$ ).

O pseudo-código da recursividade do processo é apresentado no Algoritmo 4.

Tabela 4.1: Método para o cálculo do sucesso do delineamento dos objetos nas imagens sintéticas. O resultado foi obtido a partir da soma entre as imagens de validação e de resultados obtidos pelo PPM-TM.

Dados	ND	Soma das matrizes
Imagens de validação	Não-árvore = 0 Árvore = 1	Não-árvore = 0 Erros de omissão = 1
Resultados PPM-TM	Não-árvore = 0 Árvore = 2	Erros de comissão = 2 Sucesso para árvore = 3

## 4.3 Validação

### 4.3.1 Detecção da Árvore

A contagem do número total de objetos detectados serviu de base para validação. Dentre os objetos reconhecidos, as seguintes situações foram previstas:

1. Verdadeiro positivo (VP), quando a árvore foi corretamente reconhecida;
2. Falso positivo (FP), quando o objeto é reconhecido como árvore, mas não é;
3. Falso negativo (FN), o objeto é uma árvore, mas não foi reconhecido.

A Equação 4.25 é utilizada para determinar a acurácia global da detecção:

$$A_g = \left( \frac{VP}{N + FN} \right) * 100 \quad (4.25)$$

onde  $VP$  é o total de árvores corretamente detectadas,  $FN$  é o total de falsos negativos e  $N$  é o número total de árvores na imagem.

### 4.3.2 Delineamento da Copa

Como cada um dos objetos é formado por um conjunto de pixels, a verificação da acurácia foi baseada na contagem dos pixels que foram corretamente identificados como parte do objeto árvore, os que deixaram de ser identificados (erros de omissão) e os que foram erroneamente incluídos como parte do objeto (erros de comissão).

Para obter as taxas de sucesso do delineamento, realizamos a soma das matrizes de validação e de resultados do PPM-TM. As imagens de validação tiveram seus pixels rotulados com valor zero (0) para não árvore e valor um (1) para árvore. Para as imagens resultantes do processamento do algoritmo PPM-TM, os pixels foram rotulados com valor zero (0) para a classe não árvore e dois (2) para a classe árvore. Na Tabela 4.1 são apresentados os valores resultantes dessa operação, que determinam os erros de omissão (1), de comissão (2) e o sucesso do delineamento (3).

Tabela 4.2: Resultados do algoritmo PPM-TM para detecção de árvores em imagens sintéticas.

Imagem	Árvores	Verdadeiro positivo	Falso positivo	Acerto global
1	35	35	0	100%
2	55	55	0	100%
3	61	61	0	100%
4	125	119	0	95.2%
5	173	165	0	95.37%
<b>Total</b>	<b>449</b>	<b>435</b>	<b>0</b>	<b>96.88%</b>

## 4.4 Testes em ambientes controlados

Para testar o algoritmo PPM-TM, as cinco imagens sintéticas criadas a partir dos modelos ótico geométricos foram processadas. Essas imagens simulam áreas com densidades e tamanhos de copa distintos, para verificar se essas alterações influenciariam na performance do algoritmo. Conceitualmente, as imagens sintéticas são mais simples que imagens reais, pois possuem apenas duas classes, árvore e não-árvore, mas proporcionam um ambiente controlado para verificar as potencialidades e limitações da abordagem desenvolvida.

### 4.4.1 Detecção da Árvore

A abordagem metodológica proposta foi eficiente para definir a correlação entre pontos e marcas, gerando taxas de acerto global superiores a 95% para a detecção das “árvores” em todas as imagens sintéticas, sem a ocorrência de falso positivo (Tabela 4.2).

A performance do algoritmo foi superior nas imagens com menor densidade de árvores (Figuras 4.7 a 4.9), nas quais todos os objetos foram identificados (taxa de acerto global de 100%). Nas imagens com maior densidade e maior intervalo entre os raios mínimo e máximo, o algoritmo obteve resultados ligeiramente inferiores (Figuras 4.10 e 4.11). Nessas duas imagens, apenas árvores de raio inferior a 4.5 pixels não foram detectadas, estando localizadas, ou não, na sombra de outras árvores. Ao observarmos as referidas figuras, é possível notar que ocorreu correlação entre pontos e marcas a partir de modelos menores que as árvores, haja vista que a condição de porção iluminada e sombreada, semelhante ao modelo, foi satisfeita. Isso conduz à redução da probabilidade de detecção das árvores de raio mínimo, uma vez que não existem modelos menores disponíveis no catálogo de modelos ( $\omega [r_{min}, r_{max}]$ ) para igualarem suas chances de detecção com as árvores de raio maior.

Tabela 4.3: Resultados do delineamento das copas de árvores em imagens sintéticas com o método PPM-TM.

<b>Imagem</b>	<b>Acurácia do delineamento</b>	<b>Erros de Comissão</b>	<b>Erros de Omissão</b>
1	<b>82.04%</b>	9.85%	<b>17.96%</b>
2	70.07%	6.89%	29.92%
3	75.91%	<b>3.69%</b>	24.08%
4	69.89%	5.22%	30.10%
5	70.66%	11.7%	29.33%

#### 4.4.2 Delineamento da Copa

A acurácia global do delineamento alcançou percentuais entre 69.9% e 82%. Os melhores resultados foram obtidos para a *imagem 1*, que possui o menor intervalo entre os raios mínimo e máximo, com apenas 2 pixels de diferença, e também a menor densidade de “árvores”. Os maiores erros foram obtidos para a *imagem 4*, que foi o caso considerado mais complexo dentre as imagens analisadas, pois possui alta densidade de “árvores” e variação de 12 pixels entre os raios mínimo e máximo (Tabela 4.3).

Houve clara tendência a erros de omissão maiores, sendo a média desses erros de 26,27%, bem superior à média dos erros de comissão, que foi 7,47%. A possibilidade de atração entre pontos e marcas na imagem a partir de modelos menores conduz ao aumento dos erros de omissão e à consequente redução no sucesso do delineamento das árvores.

#### 4.4.3 Parâmetros de Processamento

Os mesmos parâmetros de iluminação do modelo ( $\theta$ ,  $\phi$ ,  $amb$ ) e de modificação ou finalização do processo ( $Iter_{tot}$ ,  $Iter_{Sm}$ ) foram utilizados para o processamento das imagens. Os critérios para análise dos pontos e marcas também foram os mesmos ( $Sm_{[min,max]}$ ,  $\sigma_{[min,max]}$ ) porém, a intensidade ( $\lambda$ ) e o intervalo de raios ( $r_{[min,max]}$ ) variaram conforme a densidade e tamanho das árvores.

A **abordagem híbrida PPM-TM** se mostrou eficiente para detecção e reconhecimento das copas de árvores nas imagens sintéticas. A proposta de **recursividade e flexibilidade da métrica** foi testada com sucesso. Comparando os valores de  $Sm$  do conjunto entre as imagens, notamos que valores mínimos de  $Sm$  são menores nas imagens de alta densidade. Isso se deve ao maior número de tentativas necessárias para que os objetos sejam encontrados, levando à maior flexibilização dos critérios, em especial quando o intervalo entre os raios mínimos e máximos das árvores é maior (mais modelos devem ser testados até que um “tamanho” adequado seja encontrado).

Para verificar o adequado funcionamento dos **parâmetros de interrupção do processo**,



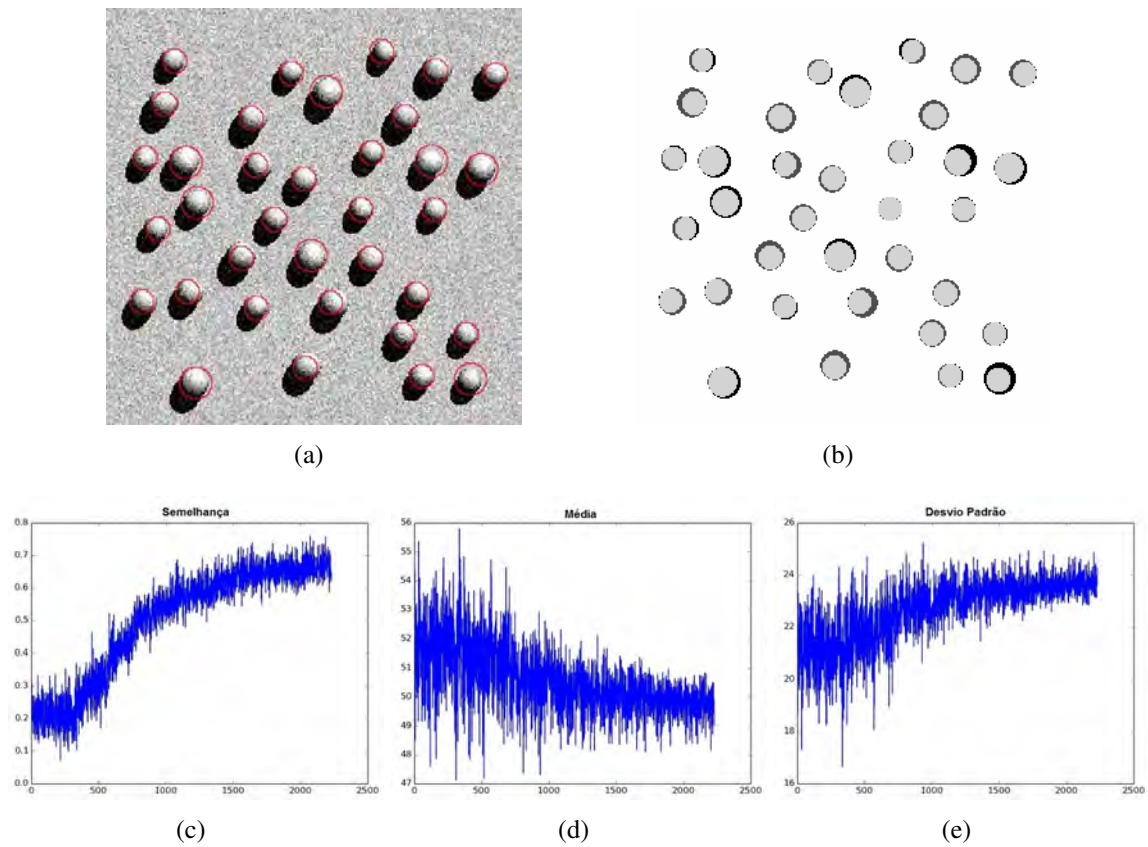


Figura 4.7: Resultados do PPM-TM para detecção das “árvores” na imagem sintética 1: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 1, com 2.200 iterações:  $S_m$ ,  $\mu$  e  $\sigma$ , respectivamente (c-e).

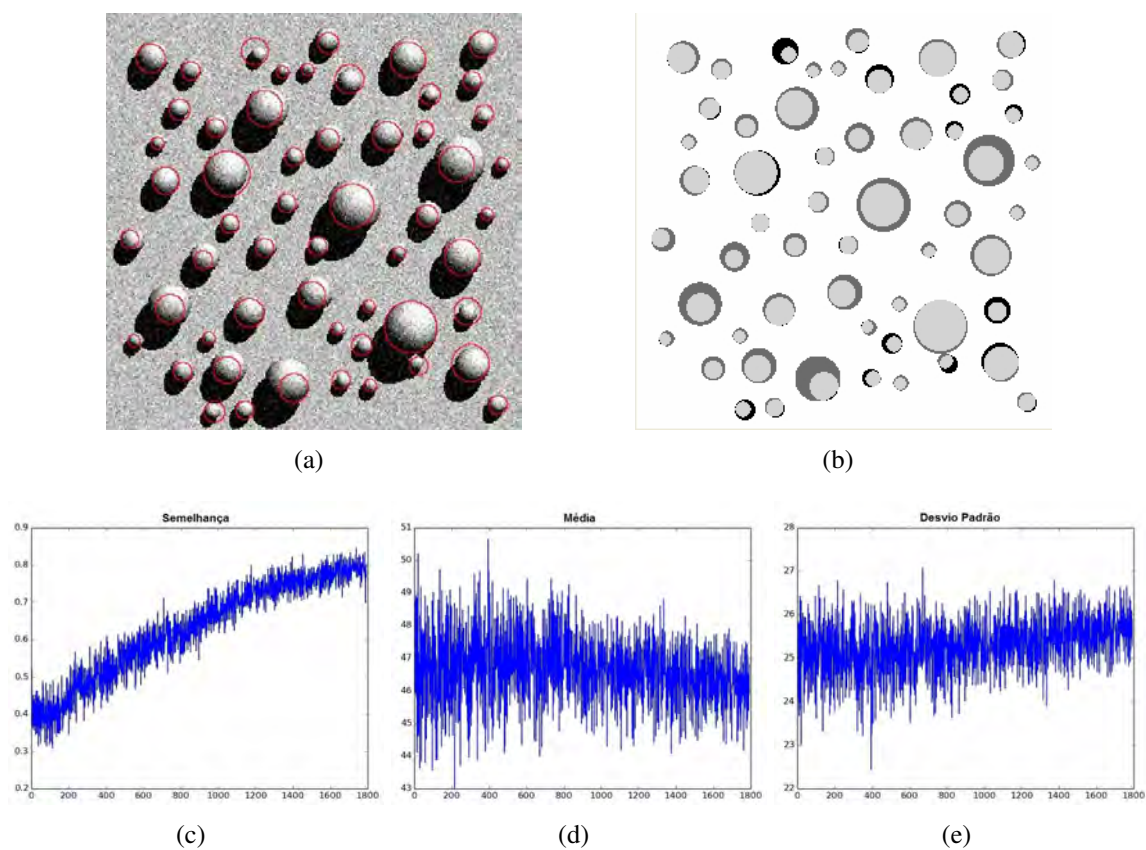


Figura 4.8: Resultados do PPM-TM para detecção das “árvores” na imagem sintética 2: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 2, com 1.794 iterações:  $S_m$ ,  $\mu$  e  $\sigma$ , respectivamente (c-e).

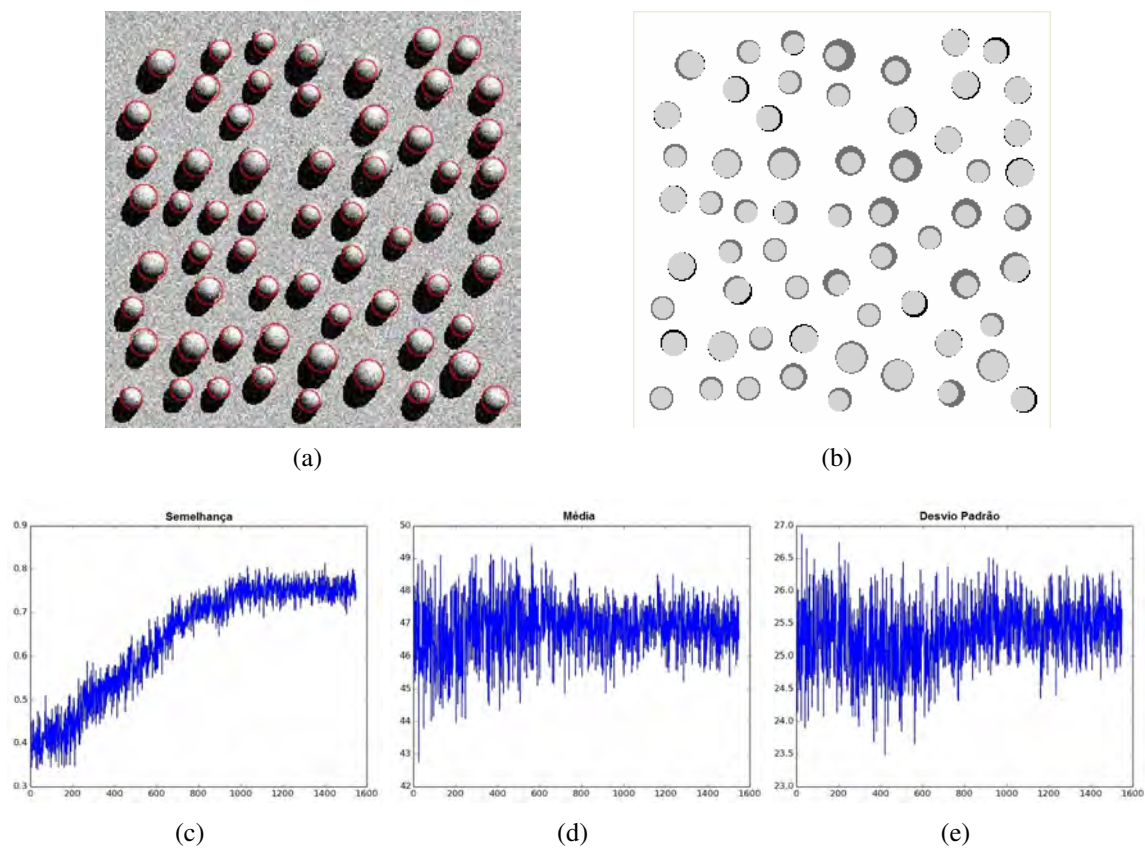





Figura 4.9: Resultados do PPM-TM para detecção das “árvores” na imagem sintética 3: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 3, com 1.550 iterações:  $S_m$ ,  $\mu$  e  $\sigma$ , respectivamente (c-e).




(a)




(b)



(c)



(d)



(e)

Figura 4.10: Resultados do PPM-TM para detecção das “árvores” na imagem sintética 4: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 4, com 2.600 iterações:  $S_m$ ,  $\mu$  e  $\sigma$ , respectivamente (c-e).

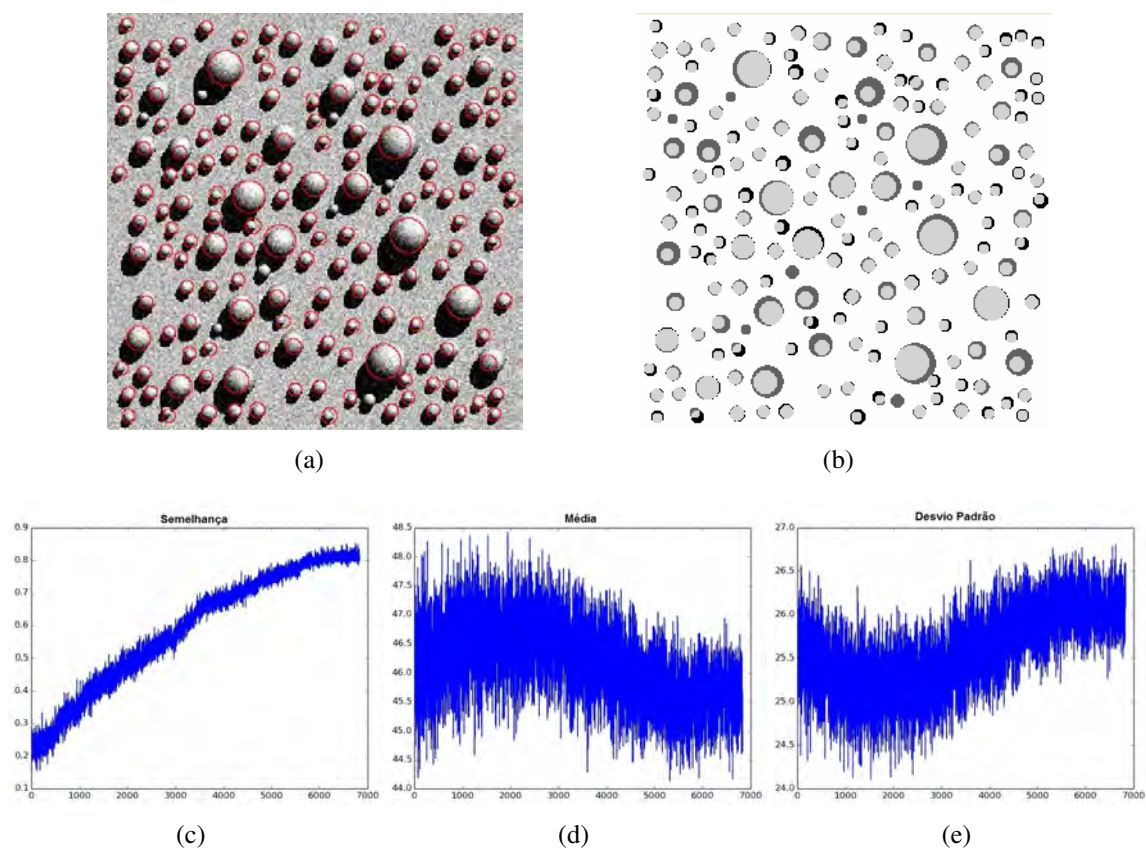


Figura 4.11: Resultados do PPM-TM para detecção das “árvores” na imagem sintética 5: em (a) objetos reconhecidos e seu delineamento, em (b) análise dos erros (cinza claro = acerto; preto = erros de comissão; cinza escuro = erros de omissão). Estatísticas globais obtidas para a imagem sintética 5, com 6.831 iterações:  $S_m$ ,  $\mu$  e  $\sigma$ , respectivamente (c-e).

superestimamos  $\lambda$  em todos os testes realizados. O processo foi interrompido automaticamente todas as vezes, sem que houvesse a ocorrência de falso positivo e com a detecção mais de 95% das árvores em todos os casos. Essa é uma vantagem do algoritmo proposto, uma vez que não existe a necessidade de conhecer a exata intensidade do PPM, pois o algoritmo é interrompido, depois de um certo número de tentativas, quando nenhum objeto atende aos critérios exigidos para ser uma árvore.

Os critérios de  $r_{min}$  e  $r_{max}$  fornecidos para o processamento das imagens foram alterados quando comparados aos utilizados para a criação das imagens sintéticas, visando avaliar se critérios diferenciados influenciariam no processo de reconhecimento dos objetos. A quase totalidade das árvores foi reconhecida, porém uma melhor performance foi observada com intervalos de raios próximos em contextos de menores densidades, tanto para detecção da árvore, quanto para o melhor delineamento da copa.

**O tempo de processamento** das imagens variou entre 15 e 55 min, e o número de iterações foi entre 1.550 e 6.831, ambos aumentando progressivamente conforme a densidade de árvores. O tempo de duração de cada iteração é alterado ao longo do processo, sendo que as iterações da fase inicial demandam mais tempo que as da fase final. No início do processo poucos são os objetos reconhecidos, e todo o espaço amostral está disponível para busca. À medida que o processo avança e os pontos são correlacionados com suas marcas, o espaço de busca é reduzido, tendo em vista que o ponto e a marca de um objeto encontrado não são novamente testados.

Nas Figuras 4.7, 4.8, 4.9 (c-e) são apresentados os valores médios de  $S_m$ ,  $\mu$  e  $\sigma$  **para o conjunto de objetos** criados na fase de nascimento, a cada iteração. Por se tratar de um processo estocástico, ao início do processo poucos são os objetos reconhecidos, pois as chances para “encontrá-los” só aumenta à medida que mais porções da imagem são avaliadas. Por esse motivo, no início do processo os valores de semelhança são baixos, pois muitos dos objetos testados ainda serão eliminados na fase de morte. Conforme o processo avança, mais objetos são reconhecidos e preservados, o que leva ao aumento progressivo dos valores de semelhança do conjunto (Figuras 4.7, 4.8, 4.9 - c). Espectralmente, o modelo 3D poderia ser dividido em duas classes distintas: uma porção diretamente iluminada pelo sol e uma outra porção que recebe menos iluminação solar (porção sombreada). Em termos estatísticos, esse objeto possui alto desvio padrão, refletido no comportamento do conjunto, pois à medida que os objetos são reconhecidos nas imagens, o desvio padrão tende a aumentar. Soma-se ainda, a adição do ruído gaussiano, que também tende a elevar o desvio padrão. Os valores de média também apresentam tendência de redução ao longo das iterações, em função do acréscimo da porção sombreada e de parte da própria sombra no objeto.

## Capítulo 5

# Refinamento do Algoritmo

Os resultados preliminares (Seção 4.4) permitiram identificar as potencialidades e limitações da abordagem PPM-TM para o problema da detecção de copas de árvores em imagens VHR. A partir desse diagnóstico, elencamos as seguintes limitações:

- Falta de mecanismos adequados para a leitura e o processamento de imagens RGB e multiespectrais;
- Processo recursivo com fases iniciais mais lentas, pois todo espaço da imagem é passível de busca, mesmo em imagens de topologia complexa;
- Forte atração entre ponto e marca a partir de modelo menor que a árvore;
- Dificuldade para detecção de árvores muito pequenas em contextos de alta densidade de árvores e grandes intervalos entre os raios mínimo e máximo;
- Atração entre pontos e marcas quando a porção analisada na imagem corresponde à associação entre área iluminada e sombreada;
- Falta de mecanismos para integração direta em sistemas de informação geográfica (SIG).

As próximas seções são dedicadas a apresentar os aprimoramentos desenvolvidos para melhorar a performance do algoritmo.

### 5.1 Leitura e Processamento das Imagens VHR

A metodologia apresentada na Seção 4.2 foi desenvolvida para imagens pancromáticas. Visando a possibilidade de utilização de imagens multiespectrais e RGB, foram definidas diferentes estratégias para processamento das imagens, conforme sua resolução espectral:

- Algoritmo  $Px$  - dedicado a imagens pancromáticas e RGB;
- Algoritmo  $Mx$  - dedicado a imagens multiespectrais.

Realizada a leitura da cena e a extração de suas informações (número de linhas e colunas, bandas, parâmetros geodésicos EPSG, coordenadas iniciais, resolução espacial), a estratégia

consiste na conferência do número de bandas para escolha do algoritmo a ser utilizado (a descrição dos algoritmos  $P_x$  e  $M_x$  é apresentada na Seção 5.7).

Nas imagens multiespectrais, a banda pancromática ainda serve de base para a realização do processamento, mas foram criados mecanismos para leitura, processamento e extração de informações de qualquer uma das bandas.

Para as imagens RGB, é assumido tratar-se de uma imagem sem banda pancromática, como imagens fusionadas, por exemplo. Nesse caso, optamos por tirar proveito das informações contidas nas três bandas espectrais através da conversão da imagem para níveis de cinza. O método escolhido foi o da conversão para luminância (Equação 5.1), que realiza a soma ponderada das bandas com base nas funções de correspondência de cores da Comissão Internacional de Iluminação (CIE - *Commission Internationale de l'Eclairage*).

$$Y = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (5.1)$$

onde  $Y$  é a luminância, e  $RGB$  são as bandas do vermelho, verde e azul, respectivamente.

Essa metodologia foi escolhida por tirar vantagem da maior sensibilidade da visão humana a mudanças na luminância, quando comparado às mudanças no matiz ou saturação (Gonzales e Woods, 2008; Pratt, 2007), e é amplamente utilizada para conversão de imagens RGB para níveis de cinza. Após a conversão da imagem para  $Y$ , o algoritmo  $P_x$  é utilizado.

O pseudo-código do processo de decisão de processamento das imagens é apresentado no Algoritmo 5.

---

**Algoritmo 5** LEITURA DE IMAGENS VHR E ESCOLHA DO ALGORITMO PARA DETECÇÃO DAS COPAS DE ÁRVORE.

---

**Entrada:** *Imagem.geotif*;

**Saída:** Escolha do Algoritmo para detecção das copas de árvores

**início**

Executa a leitura de todas as bandas da imagem e extrai os dados geográficos

**se** *bandas*  $\neq$  1;

**então**

**se** *bandas* = 3;

**então**

Conversão para  $Y$ ;

Execute  $P_x$

**senão**

Execute  $M_x$ ;

**fim**

**senão**

Execute  $P_x$ ;

**fim**

**fim**

---



## 5.2 Divisão do Processamento das Imagens

A estratégia de divisão do processamento visa melhorar os resultados para: 1) detecção de árvores muito pequenas em contextos de alta densidade e grandes intervalos de raio; 2) evitar o problema da atração entre ponto e marca a partir de modelo menor que a árvore.

Definidos os raios mínimo e máximo, o processo é dividido com base em um intervalo máximo de raios admitido para cada fase do processamento ( $I$ ). A detecção é iniciada pelas árvores de maior raio, já que modelos maiores não tendem a se correlacionar com árvores menores. O processamento é repetido  $n$  vezes, até que o raio mínimo seja alcançado. Valores temporários de raios mínimo e máximo são definidos a cada fase do processo ( $r_{mint}$ ,  $r_{maxt}$ ), sendo o valor de  $I$  subtraído de  $r_{mint}$  e  $r_{maxt}$  na fase seguinte. Através da Equação 5.2 define-se o número de divisões do processamento.

$$np = \frac{r_{max} - r_{min}}{I} \quad (5.2)$$

onde  $np$  é o número de vezes em que o processo será dividido e  $I$  é intervalo entre os raios mínimo e máximo admitido para cada fase.

Por exemplo, se o intervalo de raios é de 18 m (ex.:  $r_{min} = 2$  m e  $r_{max} = 20$  m) e  $I$  é igual a 5 m, o processo será dividido em 4. A detecção é iniciada pelas árvores de maior raio, no exemplo 20 a 16 m, em seguida as de raio entre 15 m e 11 m, e assim sucessivamente até que o raio mínimo seja alcançado. O pseudo-código desse processo é apresentado no Algoritmo 6.

## 5.3 Modificação do Espaço Amostral

O algoritmo PPM-TM é baseado em um processo estocástico, no qual toda a imagem é um espaço de busca possível para seleção dos pontos e correlação com suas marcas. Entretanto, em imagens que possuem outras classes conceituais (solo exposto, concreto, asfalto, etc.), a eliminação dessas tende a acelerar o processamento das imagens. Com esse objetivo, propusemos a modificação do espaço amostral, através da criação de máscaras baseadas na limiarização global de uma banda ou de razões de bandas (Equação 5.3). A limiarização multinível não foi utilizada em virtude da alta variância intraclasse das árvores.

$$g(x, y) = \begin{cases} 0 & \text{se } f(x, y) < T \\ 1 & \text{se } f(x, y) \geq T \end{cases} \quad (5.3)$$

onde  $g(x, y)$  é a imagem limiarizada,  $f(x, y)$  é a imagem de entrada e  $T$  é o valor do limiar.

Mesmo com o uso da limiarização, objetos espectralmente muito próximos às árvores (como gramados, por exemplo) não são excluídos, mas há uma redução considerável no espaço a ser analisado. Além de reduzir o tempo de processamento, indiretamente ocorre a

---

**Algoritmo 6** ALGORITMO DE DIVISÃO DO PROCESSO DE BUSCA
 

---

**Entrada:**  $r_{min}, r_{max}, I$ ;

**Saída:** Divisão do processo de detecção dos objetos

**início**

Calcula  $np$ ;

Cria valores temporários para  $r_{min}, r_{max}$  e  $np$  ( $r_{mint}, r_{maxt}, np_t$ );

Iguala os valores de  $r_{max}$  e  $r_{maxt}$ ;

**enquanto**  $np \neq 1$ ;

**faça**

**se**  $r_{maxt} = r_{max}$  e  $np = np_t$ ;

**então**

    | Execute a primeira divisão do processamento;

**se**  $t_r < 2$  **então**

    |  $r_{maxt} = r_{maxt}$ ;

**senão**

    |  $r_{maxt} = r_{maxt} - I$ ;

**fim**

**se**  $t_r < 2$  **então**

    |  $r_{mint} = r_{min}$ ;

**senão**

    |  $r_{mint} = r_{maxt} - I$ ;

**fim**

$np_t = np_t - 1$

**fim**

**fim**

---

redução dos casos de falso positivo e, conseqüentemente, dos erros de comissão.

Para imagens com única banda **pancromática**, a Equação 5.3 é aplicada diretamente sobre a banda a ser processada. Nas imagens **RGB**, a imagem limiarizada é obtida a partir da imagem de luminância ( $Y$ ).

Para modificação do espaço amostral nas imagens **multiespectrais**, o NDVI (Equação 5.4) é utilizado para geração da imagem limiarizada, a fim de eliminar as áreas não vegetadas.

$$NDVI = \frac{IVP - V}{IVP + V} \quad (5.4)$$

onde  $IVP$  é a banda do infravermelho próximo e  $V$  é a banda do vermelho.

Havendo disponibilidade de bandas na região do costal (400 - 450 nm) e da segunda porção do infravermelho próximo, o índice de diferença normalizada da água (NDWI) também é calculado (Equação 5.5). Esse índice foi desenvolvido para maximizar a resposta dos corpos d'água, a partir da eliminação da resposta do solo e da vegetação (McFeeters, 1996). O NDWI foi desenvolvido para utilização em imagens Landsat, mas pode ser adaptado para imagens obtidas por outros sensores. Neste estudo, o objetivo de utilizar esse índice foi para




Figura 5.1: Recorte de um imagem WV-2 (a) e o NDWI obtido para a mesma imagem (b). As sombras em (b) estão representadas pela cor azul e estão associadas aos mais altos valores.

eliminar as sombras de edificações que, em virtude da forte atração entre os pontos e as marcas nessas áreas, tendem a aumentar os erros.

$$NDWI = \frac{Costal - IVP2}{Costal + IVP2} \quad (5.5)$$

onde  $IVP2$  é a segunda banda do infravermelho próximo e  $Costal$  é a banda do costal.

Na Figura 5.1 é apresentado o resultado do NDWI para um recorte de uma imagem WV-2, na qual é possível observar que as sombras contidas na imagem podem ser eliminadas. Existindo a possibilidade de geração de ambos os índices, as imagens limiarizadas de NDVI e de NDWI são somadas, associando a redução proporcionada por cada uma delas.

Em caso de divisão do processamento, os objetos criados em uma fase são adicionados à imagem limiarizada, reduzindo ainda mais o espaço amostral da fase seguinte (Equação 5.6).

$$g(x, y)_m = g(x, y) + \Delta(x_i, m(x_i)) \quad (5.6)$$

onde  $g(x, y)_m$  é a imagem limiarizada modificada,  $g(x, y)$  é a imagem limiarizada e  $\Delta(x_i, m(x_i))$  são todos os pontos e marcas detectados na fase anterior do processo.

O processo estocástico passa a ser regido pelo espaço amostral de  $g(x, y)$ . Essa estratégia é utilizada apenas para a definição dos pontos, sendo as marcas analisadas em todo o espaço amostral (imagem). Isso evita que parte dos objetos sejam eliminados através da limiarização, estando todas as porções próximas ao ponto, disponíveis para análise.

## 5.4 Variação da Intensidade do Processo

A imagem limiarizada agora é o espaço de configurações  $Sp$ , que serve de base para definição da intensidade do processo ( $\lambda$ ). A intensidade é baseada em uma relação de área e de tamanho máximo de raio, portanto, a cada divisão do processamento, a intensidade também é alterada. Isso se dá em virtude da modificação do espaço amostral, pois novas árvores foram detectadas e adicionadas à imagem limiarizada, como também pela redução do raio máximo a cada divisão do processamento. A intensidade do processo passa a ser regida pela Equação 5.7.

$$\lambda_p = \frac{\sum g(x,y)}{d_{max_p} D} \quad (5.7)$$

onde  $\lambda_p$  é a intensidade do PPM a cada divisão do processamento,  $g(x, y)$  é a imagem limiarizada, que pode estar modificada ou não,  $d_{max_p}$  é o diâmetro máximo do modelo na divisão do processamento executada e  $D$  é o fator de densidade do PPM.

## 5.5 Operações de Expansão, Contração e Translação

Com o objetivo de refinar o delineamento dos objetos, ao final do processamento são realizadas operações de expansão, contração e de translação para cada ponto e marca detectados. A abordagem é baseada no relacionamento dos pixels vizinhos ao ponto  $p_i$  e na análise de um certo número de modelos, contidos no catálogo de modelos.

O relacionamento dos pixels vizinhos ao ponto  $p_i$  é, minimamente, sua vizinhança-8 ( $N_8(p_i)$ ), o que inclui seus quatro vizinhos horizontais e verticais, além dos diagonais (Figura 5.2 (a)). O relacionamento é definido por  $t$ , que sendo igual a 1, estabelece vizinhança  $N_8(p_i)$ , sendo igual a 2,  $N_{16}(p_i)$ , e assim sucessivamente.

Com a tendência de modelos menores apresentarem altos valores de  $Sm$  em árvores maiores, os testes foram limitados a modelos de raio uma vez menor e duas vezes maior que o obtido no processamento ( $\omega_i - 1 < \omega_i > \omega_i + 2$ ) (Figura 5.2 (b)). Os pontos dentro desse novo intervalo são analisados com suas posições transladadas e marcas expandidas e contraídas. Se o valor de  $Sm$  é maior que o anterior, o novo ponto e nova marca são assumidos, e continua-se a busca até que todas as posições e marcas tenham sido testadas (Figuras 5.2 (c-f)).

## 5.6 Integração SIG

Visando a integração com SIG, os resultados do processamento são convertidos para arquivos *shapefile*. Dois tipos de geometria são utilizados: pontos e polígonos. O arquivo de polígonos contém o resultado do delineamento da copa. O arquivo de pontos se refere ao

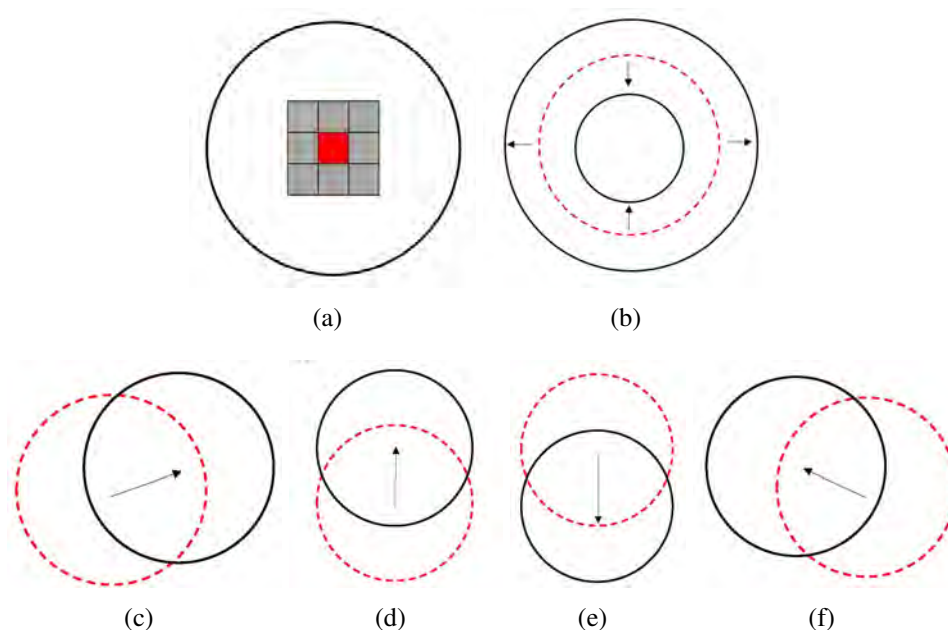


Figura 5.2: Em (a) o ponto e a marca da árvore detectada, com seus vizinhos-8 destacados. Em (b) é ilustrado o processo de expansão e contração da marca. Em (c-f) é ilustrado o processo de translação do ponto e de sua marca com base no relacionamento com os pixels vizinhos  $p_i$ . Se o relacionamento é  $N_8(p_i)$ , oito posições serão testadas para o pixel  $p_i$ .

centroide de cada árvore, e contém em seus atributos as características e estatísticas de cada uma delas:

- Identificação da árvore
- Coordenada da árvore (x,y)
- Raio da copa da árvore
- Valores de  $S_m$  e  $D_{i,f}$
- Estatísticas da árvore: valores de média, desvio padrão, média para cada banda espectral;

As referências geoespaciais são oriundas da imagem VHR.

## 5.7 Abordagem Pancromática versus Multiespectral

Os algoritmos  $P_x$  e  $M_x$  utilizam estratégias ligeiramente distintas para a detecção das árvores. As diferenças residem: 1) na forma adotada para modificação do espaço amostral; e, 2) na análise das marcas, que explora as informações das bandas multiespectrais, quando essas são disponíveis. Na Figura 5.3 é representada a primeira parte do processo de detecção, dividido para uma melhor visualização.

O processo da abordagem  $P_x$ , adotado para bandas pancromáticas e imagens RGB, é apresentado na Figura 5.4. Observe que, além da imagem limiarizada que modifica o espaço

---

**Algoritmo 7** TESTES DE TRANSLAÇÃO E EXPANSÃO / CONTRAÇÃO PARA CADA ÁRVORE DETECTADA.
 

---

**Entrada:** raster com as árvores detectadas,  $t$ , catálogo de modelos ( $\omega [r_{min}, r_{max}]$ ),  $r_{min}, r_{max}$ ;

**Saída:** Árvores identificadas e delineadas com posições transladadas e marcas expandidas ou contraídas, se valor de  $Sm$  durante os testes for superior ao valor inicial.

**início**

Recupera o modelo utilizado para cada objeto detectado ( $\omega_i$ );

**se**  $Sm_i \geq Sm_{min}$ ;

**então**

**para cada** Objeto detectado;

**faça**

    Desloque o  $p_i$  para os pixels vizinhos;

**se**  $\omega_i - 1 < \omega_i > \omega_i + 2$ ;

**então**

      Compara modelo e a imagem ;

      Calcula o valor de  $Sm$ ;

**se**  $Sm > Sm_i$ ;

**então**

        Armazene as características e a nova posição do objeto e calcule as estatísticas;

**fim**

**fim**

**fim**

---

amostral da imagem  $Y$ , é possível utilizar um limiar da média da porção iluminada da copa para análise dos objetos.

Na Figura 5.5 é apresentado o processo da abordagem para imagens multiespectrais,  $Mx$ . Note que, além da utilização de razões de banda (NDVI e NDWI) para modificação do espaço amostral, a informação contida nas bandas espectrais pode ser utilizada para análise dos objetos. Essa informação é valiosa para o processo de decisão de inclusão dos objetos na classe copa de árvore, em especial em contextos de alta diversidade florística.

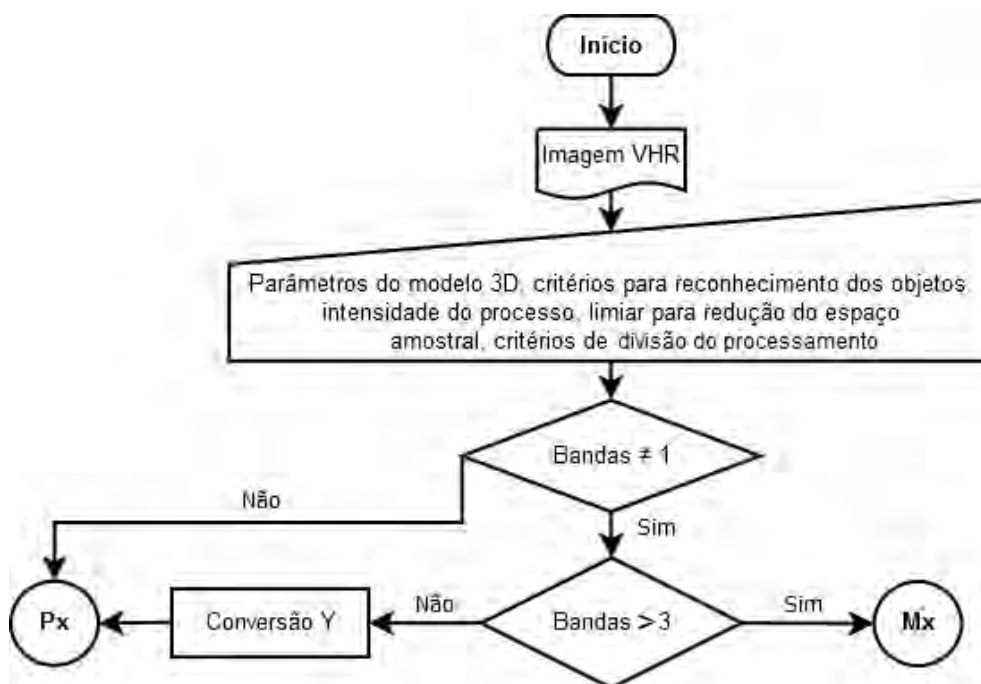


Figura 5.3: Fluxograma do algoritmo PPM-TM, parte A. Na parte inicial do processo são definidos os parâmetros do processamento e a abordagem a ser utilizada:  $Px$  ou  $Mx$ .

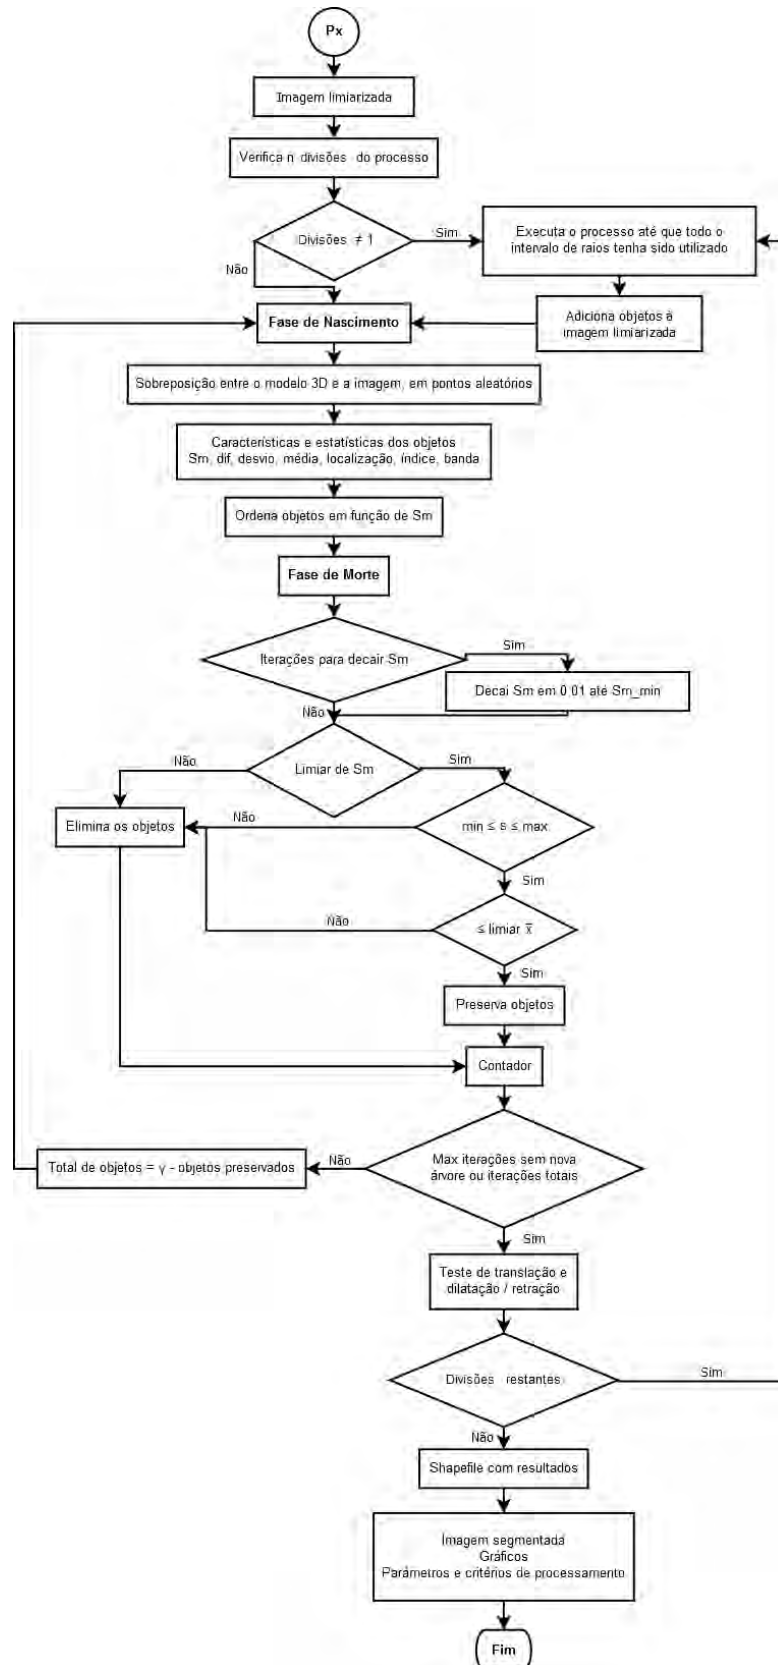


Figura 5.4: Fluxograma do algoritmo PPM-TM, parte B. Abordagem para  $Px$  para imagem pancromática e RGB.



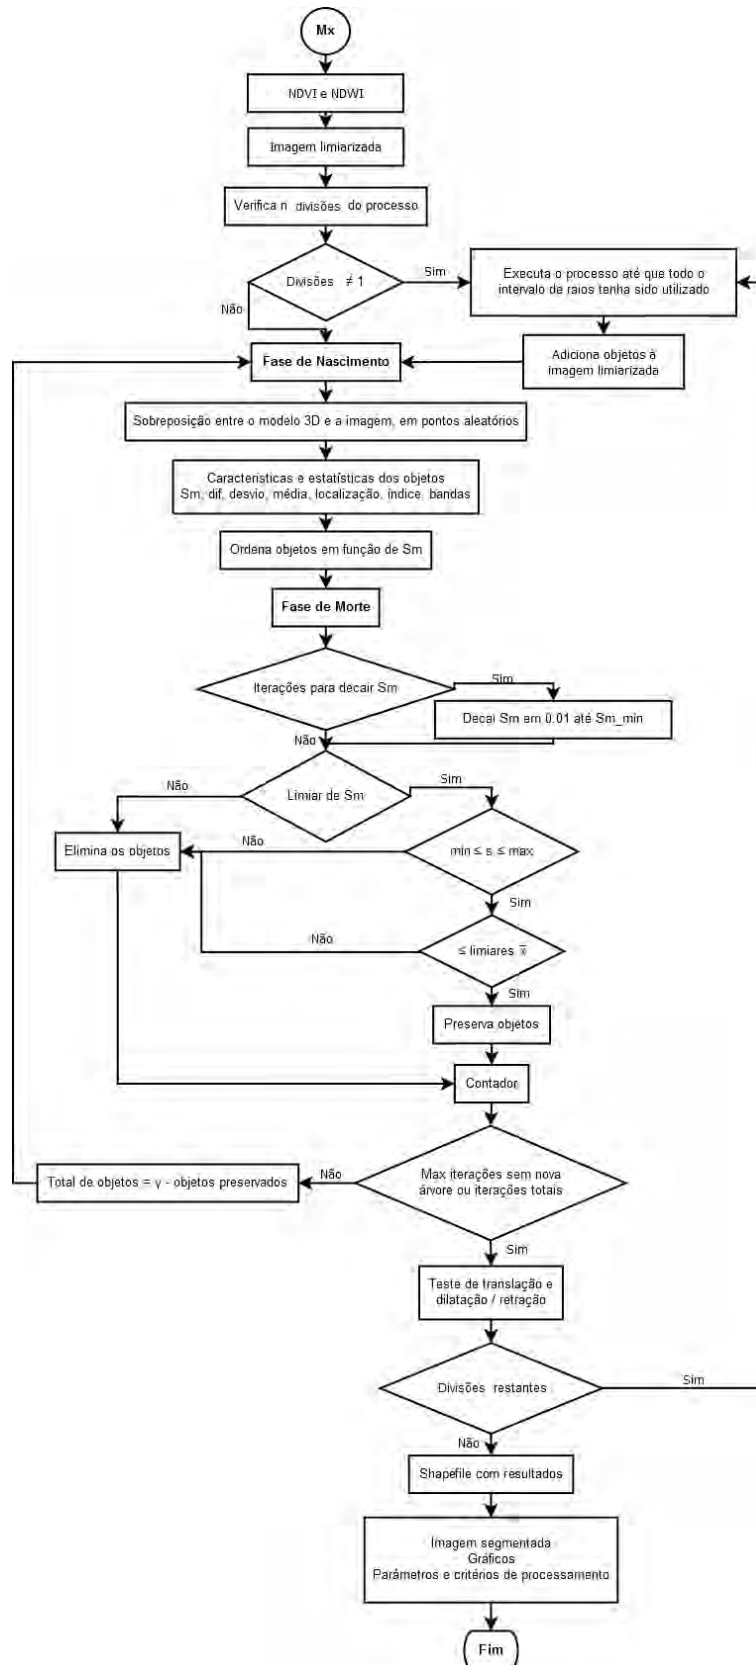


Figura 5.5: Fluxograma do algoritmo PPM-TM, parte C. Abordagem para  $Mx$  para imagens multiespectrais.

## Capítulo 6

# Resultados do PPM-TM em Imagens VHR

Este capítulo é dedicado a apresentar e discutir os resultados obtidos pelo PPM-TM\*, versão aprimorada do PPM-TM. As imagens VHR selecionadas para realização do experimento possuem diferentes espécies e tamanhos de copas de árvores, além de estarem inseridas em contextos distintos, com o objetivo de verificar o desempenho do método proposto nesses ambientes. São avaliados tanto o sucesso para identificação das árvores, quanto para o delineamento de suas copas. Os resultados e os aprimoramentos realizados no PPM-TM são discutidos, a fim de fornecer uma análise sobre o problema.

### 6.1 Avaliação da Acurácia

Os dados de validação foram gerados a partir da interpretação visual das árvores contidas nas imagens. O método de escolha das árvores foi semi-aleatório e os seguintes desafios foram enfrentados para o correto delineamento manual das copas das árvores:

- Dificuldade para identificação das árvores muito pequenas, as quais foram desconsideradas da análise (raio = 1,5 m, ou 3 pixels);
- Copas entrelaçadas, impossibilitando a delimitação precisa do contorno das árvores;
- Árvores decíduas ou semi-decíduas que, tanto pela resolução espacial, quanto pela ausência de folhas, não permitiram a correta identificação dos contornos de suas copas;
- Remanescentes florestais com dossel contínuo, o que também impediu a correta identificação dos limites das copas das árvores. Nesses casos, apenas as árvores de dossel proeminente puderam ser identificadas.

A fim de fazer uma comparação mais justa com os resultados obtidos pelo algoritmo, a forma das copas foi simplificada por um círculo. Quando essa simplificação não era possível, um polígono de  $n$  vértices era utilizado para a representação. Na Figura 6.1 são ilustrados os processos de simplificação da copa (a) e a representação por polígono (b), além da impos-




Figura 6.1: Interpretação visual das copas das árvores para geração dos dados de validação. Em (a) círculos serviram de base para expressar a forma das copas. Em (b), quando a forma não podia ser simplificada por um círculo, foi interpretada como um polígono. Em (c) situação em que não era possível interpretar visualmente as copas das árvores. Nesses casos, os indivíduos com dossel proeminente foram interpretados, e o restante não foi avaliado.

sibilidade de correto delineamento manual de todas as copas em dosséis contínuos (c). Os dados de validação são apresentados na Figura 6.2.

Uma análise espacial de interseção inclusiva entre os dados de validação e os resultados PPM-TM\* serviu para verificar quantas árvores haviam sido corretamente detectadas. A acurácia da detecção ( $A_d$ ) foi calculada a partir da Equação 6.1.

$$A_d = \left( \frac{VP}{N} \right) * 100 \quad (6.1)$$

onde  $VP$  é o total de árvores corretamente detectadas e  $N$  é o total de árvores de validação.


A acurácia global da detecção foi calculada com base na metodologia descrita na Subseção 4.3.1 (Equação 4.25). Da mesma forma, as seguintes situações de detecção foram previstas: 1) verdadeiro positivo (VP), quando a árvore foi corretamente reconhecida; 2) falso positivo (FP), quando o objeto é reconhecido como copa, mas não é (erro de comissão); e 3) falso negativo (FN), o objeto é uma copa, mas não foi reconhecido (erro de omissão).

Para avaliação do delineamento, os dados vetoriais de validação foram convertidos para arquivos raster, e posteriormente somados com o raster resultante da segmentação das copas das árvores pelo PPM-TM\* (Subseção 4.3.2). O sucesso do delineamento foi obtido a partir da contagem do número de pixels corretamente identificados como parte do objeto árvore (acerto), os que deixaram de ser identificados (erros de omissão) e os que foram erroneamente incluídos como parte do objeto (erros de comissão).

## 6.2 Parâmetros do Processamento

Os parâmetros e critérios estabelecidos para o processamento das imagens foram alterados para cada uma delas, em função das características das árvores (resposta espectral, tamanho, contexto) e dos parâmetros de aquisição das imagens.

Na Tabela 6.1 são apresentados os parâmetros de iluminação do modelo 3D para cada




(a)




(b)




(c)



(d)



(e)



(f)

Figura 6.2: Dados de validação (em preto), sobrepostos às imagens de teste: (a) campus da UFMG, (b) P.E. da Pampulha, (c) Jardim Botânico de Sydney, (d) plantação de abacateiros em Morro Bay, (e) cerrado *sensu stricto* em Brasília e (f) remanescente de mata seca, em Itacarambi.

Tabela 6.1: Parâmetros de iluminação do modelo 3D para as imagens de teste.

<b>Imagem</b>	$\theta$	$\phi$	$amb$	$L_M$
1 Campus UFMG	45, 2°	32, 1°	10	70
2 Parque ecológico da Pampulha	45, 2°	32, 1°	10	60
3 Jardim Botânico de Sydney	44, 1°	37, 4°	10	100
4 Plantação de abacateiros	47, 0°	171, 8°	10	130
5 Cerrado	45, 0°	35, 0°	10	60
6 Mata Seca	25, 1°	65, 1°	5	70

$\theta$ : ângulo de elevação solar;  $\phi$ : azimute solar;  
 $amb$ : iluminação difusa;  $L_M$ : radiância máxima do modelo.

uma das imagens. Os valores do ângulo de elevação solar ( $\theta$ ) e do azimute solar ( $\phi$ ) foram retirados das informações de aquisição das imagens. Esses dados não estavam disponíveis para as imagens extraídas do *Google Earth*, então foram estimados. Os valores de radiância máxima ( $L_M$ ) e de iluminação difusa ( $amb$ ) do modelo foram baseados na resposta espectral média de algumas árvores na cena.

Um modelo genérico com geometria de meia esfera ( $\alpha = 1,5$ ) foi utilizado para o processamento de todas as imagens, por ser considerado mais abrangente. E somente uma pequena parte da sombra projetada (fator de corte = 0.96) foi utilizada no processamento.

O usuário pode alterar os parâmetros de mudança ou interrupção do processo. Porém, como padrão, são utilizados os seguintes: iterações máximas ( $Iter_{max} = 10.000$ ); iterações para interromper o processo sem que novas árvores sejam encontradas ( $Iter_{tot} = 100$ ) e, iterações para mudar o valor de semelhança ( $Iter_{sm} = 50$ ).

Para as imagens com bandas multiespectrais, os parâmetros de modificação do espaço amostral foram definidos a partir de um valor próximo à não-vegetação para o NDVI, e próximo à não-água para o NDWI. Os valores não foram iguais a zero, pois não foi realizada correção atmosférica nas imagens. Esse fato não prejudicou o resultado do processamento. Para a banda pancromática, o limiar foi obtido com base em uma análise visual, que visava a eliminação dos altos valores de refletância, tendo em vista que a vegetação possui menor valor de resposta espectral, quando comparada a outros objetos na cena (ex.: estradas, edifícios, solo exposto).

Os parâmetros relativos à caracterização dos objetos e às características do processo foram definidos com base em uma pequena amostra em cada cena, na qual era realizada a identificação visual das maiores e menores árvores, além da resposta espectral dessas ár-

vores. Quando disponível, a banda do amarelo também foi utilizada, tendo em vista a sua capacidade para identificar diferenças sutis na vegetação, especialmente em copas das árvores (Immitzer *et al.*, 2012).

Os testes realizados na Seção 4.4 mostraram que quanto maior o intervalo entre os raios e a densidade de árvores, menor o sucesso da detecção e do delineamento das árvores. Portanto, nesses casos, foi atribuída maior flexibilidade ao processo, tanto através do valor mínimo de semelhança ( $Sm_{min}$ ), quanto pelos critérios que caracterizam o objeto (intervalo da média de desvio padrão e limiar médio dos objetos nas bandas espectrais).

A intensidade do PPM ( $\lambda$ ), que define o total de objetos a serem buscados na cena, é calculada com base na Equação 5.7. O usuário só precisa definir o fator de densidade ( $D$ ), que é estimado visualmente. A intensidade é fornecida antes do início do processamento e pode ser ajustada, caso não seja adequada.

Na Tabela 6.2 são apresentados os parâmetros utilizados para o processamento de cada uma das imagens.

Tabela 6.2: Parâmetros com critérios para reconhecimento dos objetos, limiares para modificação do espaço amostral e critérios de divisão do processamento para cada uma das imagens testadas.

<b>Imagem</b>	$S_m$ (min - max)	$Raio$ (min - max)	$s$ (min - max)	$I$ (m)	$D$	$T_{pan}$ $T_Y$	$T_{NDVI}$	$T_{NDWI}$	$\bar{x}_{pan}$	$\bar{x}_{2banda}$
1 Campus UFMG	0,9 - 0,7	4,5 - 25,5	4 - 29	5	9	-	0,1	0,1	50	45
2 P.E. da Pampulha	0,9 - 0,7	4,5 - 20,5	4 - 40	10	15	-	0,1	0,1	50	35
3 J. B. de Sydney	0,9 - 0,7	5,5 - 35,5	4 - 40	5	10	-	0,1	0,1	110	25
4 Plant. abacateiros	0,9 - 0,65	3,5 - 6,5	6 - 40	2	7	120	-	-	110	-
5 Cerrado	0,9 - 0,65	5,5 - 20,5	6 - 40	3	12	145	-	-	130	-
6 Mata Seca	0,8 - 0,6	15,5 - 25,5	4 - 26	5	13	120	-	-	120	-

$S_m$ : semelhança;  $s$ : desvio padrão;  $I$ : fase do processamento;  $D$ : fator de densidade do PPM;  $T_{pan}$ : limiar para geração da imagem limiarizada a partir da banda pancromática;  $T_Y$ : limiar para geração da imagem limiarizada a partir da imagem de luminância;  $T_{NDVI}$ : limiar para geração da imagem limiarizada a partir da imagem NDVI;  $T_{NDWI}$ : limiar para geração da imagem limiarizada a partir da imagem de NDWI;  $\bar{x}_{pan}$ : média do objeto na banda pancromática;  $\bar{x}_{2banda}$ : média do objeto na segunda banda espectral.

### 6.3 Identificação das Copas de Árvores

Mais de cinco mil objetos foram reconhecidos nas seis imagens analisadas. Ao compará-los com as 2.813 árvores de validação, verificamos que 2.556 deles eram árvores, resultando em uma acurácia de detecção média de 91,90%. Analisando as imagens individualmente, as taxas de sucesso para a identificação das árvores variaram de 82,37% a 100% (Tabela 6.3). Um total de 255 objetos foram identificados como falso negativo (FN) e 100 como falso positivo (FP), resultando em uma acurácia média global de 85,66%. Individualmente, o PPM-TM\* obteve sucesso global para a detecção entre 70,03% e 100%.

Tabela 6.3: Resultados obtidos pelo PPM-TM\* para a detecção de copas de árvores individuais.

Imagem	Validação	TD	VP	FN	FP	$A_d$ (%)	$A_g$ (%)
1 Campus UFMG	732	839	603	129	50	82,37	70,03
2 P.E. da Pampulha	753	793	667	86	40	88,58	79,50
3 J. B. de Sydney	103	1986	103	0	0	100,00	100,00
4 Plant. abacateiros	793	796	788	3	5	99,36	98,99
5 Cerrado	367	567	337	30	0	91,82	84,89
6 Mata seca	65	152	58	7	0	89,23	80,55
<b>TOTAL</b>	<b>2.813</b>	<b>5.133</b>	<b>2.556</b>	<b>255</b>	<b>100</b>	<b>91,90</b>	<b>85,66</b>

TD: total de detecções; VP: verdadeiro positivo; FN: falso negativo; FP: falso positivo;  $A_d$ : acurácia da detecção;  $A_g$ : acurácia global da detecção.

A imagem do campus da UFMG é considerada a mais complexa dentre as analisadas, pela ocorrência de árvores de diferentes espécies, com diferentes tamanhos de copa, alturas e tipos de superfície abaixo delas (asfalto, concreto, grama, solo exposto, telhados). Mesmo nesse cenário, um total de 839 objetos foram detectados, sendo 603 correspondentes às copas de referência, 129 FN e 50 FP. Observou-se um melhor desempenho para a detecção de árvores isoladas, quando comparadas às agrupadas.

Apesar do intervalo de 21 m entre os raios mínimo e máximo, isso não prejudicou a detecção de árvores grandes ou pequenas. Na Figura 6.4 é apresentado um destaque do resultado, no qual é possível observar que tanto as árvores grandes quanto as pequenas foram corretamente detectadas.



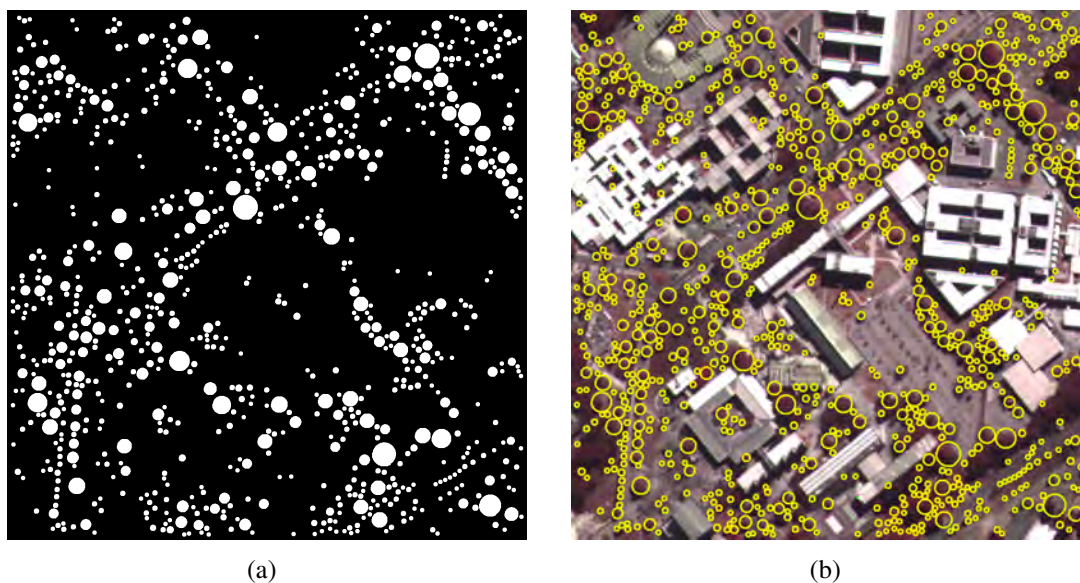


Figura 6.3: Resultados do PPM-TM\* para o reconhecimento das copas de árvores individuais na imagem do campus da UFMG. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (composição colorida em falsa cor).



Figura 6.4: Detalhe do resultado do PPM-TM\* para a imagem do campus da UFMG (em amarelo). Tanto as árvores grandes, como as pequenas, foram bem detectadas e delineadas pelo método.

As copas muito pequenas ( $< 2,5$  pixels) não foram incluídas na análise, tendo em vista a grande diferença espectral entre essas e as maiores. Na maior parte dos casos, essas árvores são mudas recém plantadas, que, pelo tamanho de copa reduzido, tendem a ser mais caracterizadas pela informação da infraestrutura sob elas, do que pelas características espectrais de uma árvore (Figura 6.5 a).

A detecção das espécies semidecíduas e decíduas também não foi avaliada, pela dificuldade de correta interpretação visual de suas copas, como já discutido no Capítulo 2. Um exemplo desse desafio é apresentado na Figura 6.5 (b), onde há várias árvores decíduas sem que seja possível determinar claramente a quantidade e o exato limite das copas.




Figura 6.6: Dificuldade para validação da detecção em um remanescente florestal (a). Exemplo de FP sobre telhado de cerâmica recoberto por musgos (b). Os parâmetros para eliminação de não-vegetação não foram suficientes para excluí-lo do espaço amostral.




Figura 6.5: Desafios para a detecção das copas na imagem do campus da UFMG: (a) copas muito pequenas, menores que 2,5 pixels de diâmetro; (b) espécies decíduas, sendo possível observar apenas a sombra de seus galhos.

Apesar da tentativa de interpretação e delineamento de todas as árvores perenes, isso não foi possível, pela expressiva quantidade e a dificuldade na correta interpretação das copas, que se encontram entrelaçadas ou formam um dossel contínuo (Figura 6.6 a). Mesmo com alguns objetos detectados, não há garantia de que a identificação e o delineamento tenham sido satisfatórios.

A modificação do espaço amostral limitou a ocorrência de falso positivos, mas não os eliminou, sendo observada confusão principalmente com grama e telhados de edifícios, que não foram eliminados com a utilização dos limiares de NDVI e NDWI. Exemplo disso são os telhados de cerâmica recobertos por musgos (Figura 6.6 b).

Assim como o caso anterior, a imagem do Parque Ecológico da Pampulha é composta por árvores de diversas espécies, caracterizadas, em sua maioria, por possuírem pequenos tamanhos de copa ( $\approx 4$  pixels), em virtude de replantio de mudas. Um total de 793 objetos foram reconhecidos nessa imagem, dos quais 667 corresponderam aos dados de validação, resultando em uma acurácia de 88,58% para detecção das árvores (Figura 6.7). Um total de

40 objetos foi erroneamente identificado como árvore e 86 árvores das amostras de validação deixaram de ser identificadas, resultando em um taxa de acerto global de 79,5%. Para as árvores isoladas, tanto as maiores quanto as menores foram reconhecidas (Figura 6.8).




Figura 6.7: Resultados do PPM-TM\* para o reconhecimento das copas de árvores individuais na imagem do Parque Ecológico da Pampulha. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (composição colorida em falsa cor).



Figura 6.8: Detalhe da imagem do Parque Ecológico da Pampulha, na qual tanto as árvores grandes quanto as pequenas puderam ser detectadas pelo PPM-TM\*.

Entretanto, são observados grupamentos de árvores, que não possuem correspondência com o modelo, além de estarem entrelaçadas e formarem um dossel contínuo, o que reduziu o sucesso da detecção (Figura 6.9 a-b). Os maiores erros foram atribuídos à confusão

entre copas de árvores e grama. A modificação dos limiares de NDWI poderiam auxiliar na remoção da grama, porém, isso implicava também na exclusão das pequenas copas de árvore.




Figura 6.9: Exemplo de copas entrelaçadas que formam um dossel contínuo: (a) resultado do PPM-TM\*; (b) mesmo grupamento de árvores visto em uma imagem do *Google Earth*, com 10 cm de resolução espacial; (c) exemplo de falso positivo sobre grama.

A maior acurácia para detecção das árvores foi obtida para a imagem do Jardim Botânico Real da cidade de Sidney (Figura 6.10). Essa área é caracterizada por alta diversidade florística, pois abriga diversas espécies coletadas na Austrália e em outras partes do mundo (Sydney, 2016). Dois fatos merecem destaque: primeiro, que muitas das árvores possuem forma semelhante ao modelo 3D; e segundo que, por ser um ambiente planejado, é observado maior espaçamento entre as árvores. O PPM-TM\* identificou 1.986 objetos, que acertou todas as árvores de amostra de validação. Em uma inspeção visual, não foi constatada a ocorrência de falso positivo.

Os resultados para essa imagem podem ter sido influenciados pelo menor tamanho da amostra de validação. As copas das árvores maiores e mais esparsadas, com menor ocorrência de copas entrelaçadas, podem ter contribuído para os resultados (Figura 6.11 a-b). As copas de árvores com forma diferente do modelo também foram detectadas e bem delimitadas, como apresentado no exemplo da Figura 6.11 (c).

A maior parte dos estudos que utilizaram PPM para detecção de copas de árvores foi realizada em florestas ou plantações de uma só espécie e de mesma idade. A imagem do pomar de abacateiros em Morro Bay, Califórnia, apesar de conter apenas uma espécie, apresenta árvores com diferentes tamanhos de copa, idades e alturas, isoladas ou não, e foi utilizada para testar o potencial do PPM-TM\* em plantações com situações mais complexas. Nessa cena, todas as árvores foram avaliadas. Um total de 796 objetos foram identificados, dos quais 788 eram copas de árvores e 5 eram solo exposto (Figura 6.12). Apenas cinco árvores, de 793, deixaram de ser detectadas, resultando em um sucesso para detecção de 99,36%, e




Figura 6.10: Resultados do PPM-TM\* para o reconhecimento das copas de árvores individuais na imagem do Jardim Botânico Real de Sydney e entorno. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (composição colorida em falsa cor).




Figura 6.11: Detecção das copas na imagem de Sydney, árvores grandes e pequenas (a), pequenas (b) e mesmo com forma diferenciada, a copa pôde ser corretamente detectada e delineada (c).




Figura 6.12: Resultados do PPM-TM\* para o reconhecimento das copas de árvores individuais na imagem de uma plantação de abacateiros na cidade de Morro Bay, Califórnia. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem original (cor natural).

uma acurácia global de 98,99%. Algumas poucas árvores que não eram abacateiros, também foram detectadas, bem como as pequenas, com raio menor que 3 pixels (Figura 6.13 a).

O desempenho do PPM-TM\* em uma área de cerrado no Parque Nacional de Brasília gerou 567 objetos reconhecidos (Figura 6.14). Ao avaliarmos com os dados de validação, das 367 árvores, 337 foram corretamente identificadas, resultando em uma acurácia de 91,82%. Ao incluirmos os 30 FN, foi alcançada uma acurácia global de 84,89%.

De acordo com o mapa elaborado por Ferreira *et al.* (2003), a área da imagem é recoberta por cerrado *sensu stricto*. Mesmo tratando-se de um ambiente natural e com alta diversidade florística, altas taxas de sucesso foram obtidas, com a maior parte das árvores detectadas e bem delineadas (Figura 6.13 b).




Figura 6.13: Em (a) detalhe do resultado do PPM-TM\* para a detecção de copas de árvores em um pomar de abacateiros. Até as menores árvores puderam ser identificadas. Em (b) detalhe do resultado em cerrado no Parque Nacional de Brasília.




Figura 6.14: Resultados do PPM-TM\* para o reconhecimento das copas de árvores individuais na imagem sobre cerrado, no Parque Nacional de Brasília. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem extraída do aplicativo *Google Earth* (cor natural).

A imagem do remanescente de mata seca, no município de Itacarambi, Minas Gerais, foi escolhida com o objetivo de testar a capacidade do PPM-TM\* para a detecção de copas proeminentes. Na Figura 6.15 é apresentado o resultado do processamento. A intensidade do PPM foi subestimada nessa imagem, para que apenas as copas proeminentes fossem detectadas. Um total de 152 objetos foram identificados, dos quais 58 corresponderam às amostras de validação, resultando em uma acurácia de 89,23%. O acerto global da detecção foi de 80,55%, em função da ocorrência de sete falso negativos. Na Figura 6.16 é apresentado um detalhe do resultado da detecção sobre a imagem, no qual é possível observar a qualidade




Figura 6.15: Resultados do PPM-TM\* para o reconhecimento das copas de árvores individuais na imagem sobre mata seca, em um remanescente florestal na cidade de Itacarambi, Minas Gerais. Em (a) resultado da segmentação das copas das árvores. Em (b) vetores resultantes do processo de reconhecimento (em amarelo) sobrepostos à imagem extraída do aplicativo *Google Earth* (cor natural).

da detecção e do delineamento em vegetação de mata seca.




Figura 6.16: Detalhe da imagem sobre vegetação de mata seca, na qual observamos a detecção e o delineamento das copas proeminentes.

## 6.4 Delineamento das Copas de Árvores

A acurácia do delineamento variou entre 50 e 90%, sem aparente tendência para erros de omissão ou comissão. Conforme a imagem e seu contexto, as copas das árvores foram superestimadas ou subestimadas (Tabela 6.4). Apenas as árvores rotuladas como verdadeiro positivo foram avaliadas. Analisando as imagens em conjunto, a acurácia média do delineamento foi de 67,6%, com erros médios de 32,32% para omissão, e de 44,63% para comissão.



Tabela 6.4: Resultados obtidos pelo PPM-TM\* para o delineamento de copas de árvores individuais.

<b>Imagem</b>	<b>Acurácia do Delineamento (%)</b>	<b>Erros de Omissão (%)</b>	<b>Erros de Comissão (%)</b>
1 Campus UFMG	51,69	47,58	34,15
2 P.E. da Pampulha	49,95	50,05	62,40
3 J. B. de Sydney	90,41	9,59	36,99
4 Plant. abacateiros	60,53	39,47	10,93
5 Cerrado	66,83	33,17	39,17
6 Mata Seca	86,21	14,04	57,16
<b>Média</b>	<b>67,61</b>	<b>32,32</b>	<b>44,63</b>

O melhor resultado para o delineamento das copas foi obtido na imagem do Jardim Botânico de Sydney, com acurácia de 90,41%, e erros de omissão e comissão de 9,59% e 36,99%, respectivamente. Novamente, as características da vegetação (árvores maiores, com certo espaçamento) e das classes abaixo dela (grama, principalmente), contribuíram para o melhor delineamento das árvores. Foi observada maior tendência a superestimar o tamanho das copas, especialmente as maiores (Figura 6.17 a).

O PPM-TM\* obteve 86,21% de sucesso para o delineamento das árvores proeminentes na imagem de mata seca, com erros de omissão e comissão de 14,04% e 57,16%, respectivamente. Na Figura 6.17 (b), os resultados são sobrepostos aos dados de validação, sendo possível notar que, na maior parte dos casos, as copas de validação são totalmente incluídas no objeto reconhecido pelo PPM-TM\*, justificando os altos erros de comissão. Em alguns casos, duas copas proeminentes e contíguas foram detectadas como um único objeto, haja vista a dificuldade de separação entre elas, o que também elevou esse tipo de erro.




Figura 6.17: Em (a) detalhe do delineamento obtido para a imagem de Sydney. As copas de validação são representadas em um tom mais claro e o resultado do PPM-TM\* em vermelho. Em (b) detalhe do delineamento para mata seca, com os dados de validação em amarelo, e o resultado do reconhecimento das árvores em vermelho.

O sucesso para delineamento das árvores em cerrado *sensu stricto* foi de 66,83%. Houve leve tendência para erros de comissão maiores (39,17%) do que os de omissão (33,17%), o que gerou uma leve superestimação na área das copas das árvores. Considerando a complexidade das copas das árvores no cerrado e a variedade de espécies, os resultados são promissores (Figura 6.18 a).

O PPM-TM\* obteve acurácia de 60,53% para delineamento das copas das árvores dos pomares de abacateiros em Morro Bay. O delineamento foi melhor quando as árvores estavam isoladas, independente de seu tamanho. Quando as copas se tocavam, houve uma tendência para subestimação da área da copa, resultando em erros de omissão maiores (39,47%) do que os erros de comissão (10,93%). Um exemplo disso é apresentado na Figura 6.18 (b). Quando os modelos eram muito pequenos (raio = 2,5 pixels), o delineamento resultante obteve a forma de quadrado, ao invés de um círculo, em função da resolução espacial do modelo, que é compatível com a resolução da imagem.

As imagens do P.E. da Pampulha e do campus da UFMG obtiveram resultados inferiores em comparação com outras imagens testadas, alcançando acurácia para o delineamento de 49,95% e 51,69%, respectivamente. Na primeira, que oferece um contexto de árvores muito pequenas, com algumas árvores maiores, os erros de comissão foram maiores que os de omissão (62,40% contra 50,05%). Em um contexto de maior diversidade florística e árvores nas mais diversas situações, os erros de omissão foram maiores que os de comissão (47,58% contra 34,15%). Situações com árvores muito pequenas e com alta diversidade florística tenderam a apresentar maiores erros de omissão e comissão, especialmente se permeadas por outras classes conceituais. Na Figura 6.19 são apresentados detalhes para os erros de cada uma das imagens.




Figura 6.18: Copas de validação (amarelo) sobrepostas ao resultado do PPM-TM\* (a) na imagem de cerrado, no qual observamos uma tendência a superestimação das copas das árvores. Em (b) detalhe do resultado do PPM-TM\* para a detecção de copas de árvores em um pomar de abacateiros (amarelo), sobrepostas às copas de validação (vermelho). As copas foram bem delineadas, com tendência à subestimação.




Figura 6.19: Detalhe da análise dos erros para as imagens (a) do campus da UFMG e (b) do Parque Ecológico da Pampulha (roxo = acerto, amarelo = comissão e azul = omissão).

As estatísticas globais de cada uma das imagens em cada divisão do processamento são apresentadas no Anexo C.

## 6.5 Discussão

A abordagem metodológica desenvolvida, que integra PPM, modelagem ótica geométrica das copas e TM, apoiada em métricas de similaridade, intervalos de textura de primeira ordem e limiares espectrais, mostrou-se eficiente para a tarefa da detecção de árvores em ambientes complexos, resultando em taxas elevadas de sucesso em todas as cenas testadas, com acurácia média superior a 90%. As imagens analisadas foram oriundas de diferentes ambientes de TOF e consideradas complexas, pois em nenhuma delas as árvores possuíam as mesmas espécie, idade, tamanho e espaçamento, e elas coexistiam com diferentes classes conceituais (solo exposto, gramados, água, vegetação herbácea e arbustiva, além de infraestrutura humana - casas, edifícios, estradas, passeios, entre outros).

As melhores taxas de sucesso do PPM-TM\* foram obtidas para contextos de parque urbano planejado e de plantação, com a detecção da quase totalidade das árvores de validação. A imagem da plantação de abacateiros poderia ser considerada a mais simples dentre as analisadas, porém as diferenças na idade das árvores, no tamanho de suas copas e no espaçamento entre elas adicionaram dificuldades à análise. Em situação semelhante, Larsen *et al.* (2011), testando seis diferentes algoritmos, obtiveram a melhor acurácia igual a 66%. Para melhorar os resultados da detecção, os autores sugeriram a divisão da imagem em duas, mantendo uma com as árvores pequenas e outra com as grandes. Os aprimoramentos realizados no PPM-TM\*, em especial a possibilidade de divisão do processamento, permitiu a alta taxa de acurácia nesses casos, dedicando a busca a determinados intervalos de raio, em cada divisão.

No contexto do Jardim Botânico de Sydney, as árvores possuíam tamanhos de copas maiores, com maior espaçamento entre elas, além da ocorrência de muitas espécies com características semelhantes ao modelo 3D. O intervalo entre os raios mínimo e máximo nessa imagem é de 30 pixels, fazendo com que, novamente, a divisão do processamento permitisse a melhor detecção e delineamento das árvores. A possibilidade de modificação do espaço amostral foi fundamental para otimização do processamento. E a disponibilidade das bandas multiespectrais contribuíram para eliminação das porções de sombras dos edifícios e das águas da baía de Sydney, que ocupam parte significativa dessa imagem.

O PPM-TM\* obteve taxas de acurácia de cerca de 90% para detecção das árvores em vegetação natural de cerrado *sensu stricto* e mata seca, caracterizadas por formas variadas de copa e de espaçamento entre as árvores. Ambas as imagens foram extraídas do *Google Earth*, e apresentavam menor qualidade quando comparadas às imagens WV-2. A estratégia de conversão das imagens RGB para luminância se mostrou adequada, não interferindo negativamente nos resultados. O desafio para a identificação das árvores no cerrado foi a ocorrência de muitas árvores bastante pequenas, dificuldade essa enfrentada mesmo visualmente. Para a detecção de copas proeminentes na vegetação de mata seca, foi observada tendência a superestimar o tamanho das copas, seja por sua irregularidade, seja pela ocorrência de copas proeminentes e contíguas, que foram interpretadas como uma única árvore. A possibilidade de detecção automática de árvores, mesmo que as proeminentes, nesses ambientes, permite uma série de aplicações, como a utilização dos parâmetros de alguns indivíduos para predição de características dessas florestas, como idade, altura, densidade, entre outros, reduzindo a necessidade de inventários *in loco*.

O Parque Ecológico da Pampulha é caracterizado pela ocorrência de árvores bem pequenas, oriundas do replantio de mudas, e árvores de maior tamanho de copa. Por esse motivo, o intervalo entre os raios mínimo e máximo foi de 16 pixels. Em situação semelhante ao pomar de abacateiros, a possibilidade de divisão do processamento permitiu que as taxas de detecção atingissem 90% de acurácia. Ressalta-se a importância da inclusão de parte da sombra no modelo 3D para detecção das árvores isoladas, especialmente as de menor tamanho.

A situação considerada mais complexa, a de vegetação em área urbana no campus da UFMG, obteve o menor sucesso na detecção das árvores, 82,37%, mas nem por isso menos expressivo. As árvores nessa cena encontram-se disseminadas em meio a outras classes conceituais, mas não consideramos esse o principal fator para resultados mais baixos, mas sim a ocorrência de copas entrelaçadas e de forma variada, que configuraram como fator decisivo para a menor performance, tanto para a detecção, quanto para o delineamento. Quando a copa da árvore não possui correspondência alguma com o modelo, a sua correta detecção e delineamento não são esperados. Contudo, se essas árvores fossem excluídas da análise, o sucesso da detecção e do delineamento seriam elevados. Em áreas urbanas são observadas pesquisas que utilizam abordagens baseadas em classificação orientada a objetos geográficos (GEOBIA) com *eCognition*, com base em uma série de feições das imagens e regras de classificação, os quais não apresentam as estatísticas para detecção dos objetos, como por exemplo o estudo de Pu e Landry (2012). Ardila (2012), em um estudo para detecção de árvores nas cidades de Enschede e Delf, na Holanda, utilizou GEOBIA e obteve acurácia para a detecção das árvores entre 70% e 82% , não sendo apresentados as estatísticas para o delineamento das copas.

A implementação da modificação do espaço amostral também permitiu a diminuição das ocorrências de falso positivo. As maiores fontes de erro foram grama e telhados de casas e edifícios, estes, mesmo com a utilização dos limiares de NDVI e NDWI, não puderam ser eliminados. O intervalo de desvio padrão e a banda do amarelo, quando disponível, contribuíram para reduzir a confusão entre copas de árvore e grama. Porém, em virtude da ocorrência de diferentes tipos de gramados (espécies, densidade e verdor), isso não foi suficiente para maior distinção entre eles. O uso de feições de textura de segunda ordem, a exemplo da homogeneidade da matriz de co-ocorrência dos níveis de cinza (GLCM), utilizada com sucesso na Seção 2.2, tenderia a melhorar os resultados. No entanto, a geração de feições de textura para cada um dos objetos afetaria sobremaneira o tempo de processamento das imagens.

Os falso negativo ocorreram principalmente em duas situações: ausência de correspondência entre o modelo e a copa da árvore, como também em árvores muito pequenas. A flexibilidade dos valores de semelhança permitiu que muitas árvores, relativamente diferentes do modelo, pudessem ser detectadas. Isso foi constatado na detecção de palmeiras e coníferas presentes nas cenas. No entanto, em situações nas quais as copas se entrelaçam ou formam um dossel contínuo, o método não obteve sucesso.

A maior parte dos métodos desenvolvidos nessa área do conhecimento foi testada em ambientes distintos dos avaliados nesta pesquisa, o que dificulta a comparação dos resultados. O estudo mais abrangente em termos de tipos ambiente, sejam TOF ou não, foi o desenvolvido por Larsen *et al.* (2011), no qual os autores testaram seis diferentes algoritmos em imagens florestais homogêneas. As estatísticas para o delineamento das copas não foram apresentadas, e o resultado para a detecção, com as melhores taxas de sucesso foram:

plantação (99,7%), plantação com copas grandes e pequenas (66%), florestas mistas (77%), densas (32,9%), com árvores isoladas (68%) e fora do nadir (68%). Nenhum dos métodos foi eficiente para detectar todos os tipos de floresta e não foram obtidas altas taxas de detecção em todas elas.

Mesmo em situações consideradas altamente complexas, o PPM-TM\* obteve taxas de sucesso para o delineamento que variaram de 49,95% a 90,41%, com acurácia média de 67,61%. Na literatura, poucos são os estudos que apresentam as estatísticas para o delineamento das copas (Ke e Quackenbush, 2011), e menos ainda os que apresentam os erros de omissão e comissão, mesmo em plantações, podendo ser citadas as pesquisas de: Gougeon *et al.* (1999) com acurácia média de 59,8% em uma floresta na área de Nahmint, na Colúmbia Britânica, Canadá. O sucesso do delineamento variou entre 27,4% e 83%, conforme a espécie avaliada; Erickson (2004), que testou diferentes algoritmos de crescimento de região e obteve acurácia entre 73% e 95%, dependendo do tipo de floresta avaliado; e Wang *et al.* (2004), que utilizaram o algoritmo *watershed* em uma floresta na Colúmbia Britânica, Canadá, e obtiveram média de 75,6% para o delineamento das árvores. O ponto em comum entre essas pesquisas foi a utilização de imagens de florestas homogêneas.

Observou-se que, quanto maior o espaçamento entre as árvores e, quanto menor a complexidade de formas das copas, melhores são os resultados para delineamento, produzindo menores erros de omissão e de comissão. Árvores muito pequenas, bem como as muito distintas do modelo, tenderam a ser menos bem delineadas, porém, a possibilidade de flexibilização nos valores de semelhança permitiu a detecção e delineamento parcial dessas árvores, fornecendo informações sobre a contagem do número de árvores, sua localização e, em parte, suas características espectrais. Resoluções mais finas tenderiam a melhorar os resultados para as árvores muito pequenas.

PPM-TM\* fornece um delineamento simplificado da copa das árvores, o que significa que o contorno das copas não é rigorosamente respeitado. Se as copas das árvores forem muito irregulares, haverá maior tendência para erros de comissão. Para as árvores muito pequenas, a sombra parece ser o fator decisivo para sua detecção e delineamento, já que, em função da circularidade do modelo, sua resposta espectral também é caracterizada pelas informações da superfície circundante. Por esse motivo, algumas das detecções tenderam a um deslocamento para a área mais sombreada da copa, aumentando os erros de omissão.

Comparado o PPM-TM\* com a abordagem GEOBIA, poucos parâmetros e conhecimento são necessários para a correta detecção das árvores, oferecendo um menor grau de complexidade para o usuário. Mesmo não sendo totalmente automático, já que alguns parâmetros precisam ser manualmente fornecidos, eles são baseados em análises visuais do operador. E justamente com base no reconhecimento de padrões pelos seres humanos é que são gerados os dados de validação ou parâmetros para processamento, como pontos sementes, para muitos dos processos de segmentação, como em Erickson (2004). Portanto, os padrões visuais são frequentemente considerados na maioria dos métodos, e a utilização de




Figura 6.20: Erros que interferem na qualidade das árvores bem detectadas. Divisão da copa em dois objetos distintos (a), com as copas de validação (em amarelo) sobrepostas ao resultado da detecção (em azul). Detecção de vários objetos em copas entrelaçadas (b).

alguns deles como entrada no processo não tira o valor da abordagem proposta. Ademais, o PPM-TM\* oferece a detecção e delineamento simultâneo das copas de árvores, resultando, na maioria dos casos, em um único objeto segmentado, diferente do observado com a abordagem crescimento de região, que tendeu a dividir as copas das árvores em, pelo menos, dois objetos, um correspondente à porção sombreada, e outro à porção iluminada da copa.

As abordagens  $Px$  e  $Mx$  se mostraram adequadas para a utilização de imagens em diferentes resoluções espectrais. Tanto as imagens WV-2 quanto as obtidas no *Google Earth* que foram convertidas para luminância obtiveram altas taxas de sucesso. Isso demonstra que não são necessárias todas as bandas espectrais para que altas taxas de acurácia sejam obtidas. A utilização das bandas multiespectrais auxiliou na melhor redução do espaço amostral, especialmente em ambientes mais complexos, e na melhor caracterização dos objetos. No entanto, seu potencial não foi amplamente explorado, haja vista que foram utilizadas apenas cinco das oito bandas disponíveis.

A divisão do processamento reduziu significativamente a ocorrência de erros que interferem na qualidade da detecção, em especial, os que dividiam as copas de árvores maiores em dois objetos. Porém, ainda foram verificados os seguintes erros: inclusão de duas copas de árvores em um mesmo objeto; e a detecção de vários objetos em copas sem correspondência com o modelo, em copas entrelaçadas ou em dosséis contínuos (Figura 6.20).

Para todas as divisões do processamento, um número significativo de árvores foi detectado, tendo em vista a diversidade de tamanhos de copa em todas as imagens testadas. Na Figura 6.21 (a) é apresentado o total de árvores detectadas em cada uma das três divisões do processamento realizadas na imagem de Morro Bay. É possível observar que, em todas elas, um número significativo de árvores foi encontrado. E em (b), o total de árvores detectadas conforme o tamanho do raio.




Figura 6.21: Histogramas gerados no processamento da imagem de Morro Bay com o total de objetos detectados em cada divisão do processamento (a), e o total de árvores detectadas pelo tamanho do raio, em pixels (b).

O ajuste fino do delineamento funcionou adequadamente, no qual foram implementadas operações de expansão, contração e translação da copa após o processamento das imagens. Como padrão, a vizinhança-8 foi utilizada em todas elas. Quando maiores valores de semelhança eram obtidos em uma nova localização e/ou novo tamanho de modelo, uma nova posição e/ou novo delineamento foram assumidos.



## Capítulo 7

### Considerações Finais

Esta pesquisa teve como objetivo principal contribuir com a automatização dos procedimentos de mapeamento de árvores individuais a partir de imagens VHR obtidas por sensoriamento remoto orbital ótico. Na carência de métodos para segmentação dedicados ao problema da detecção de copas de árvores em ambientes de árvores fora de florestas (TOF), nesta tese foi proposta e implementada uma abordagem original para a detecção de copas de árvores nesses ambientes. Um algoritmo híbrido foi desenvolvido, o PPM-TM, que integra modelagem ótica geométrica tridimensional e dois métodos consagrados para reconhecimento de padrões em imagens, *template matching* e processo pontual marcado. Uma métrica flexível foi implementada, para considerar a alta variância intraclasse das copas de árvores, especialmente em ambientes não homogêneos e com alta diversidade florística. O processo de reconhecimento dos objetos também foi apoiado em características espectrais e em textura de primeira ordem. Após os primeiros testes, os aprimoramentos realizados permitiram a utilização de diferentes fontes de dados, de regras de divisão do processamento conforme o raio da copa, a criação de máscaras para reduzir a presença de outros objetos nas análises, a melhoria do alinhamento geométrico da detecção, além da geração de arquivos vetoriais, contendo em seus atributos as informações das características e estatísticas de cada objeto, com o objetivo de integração dos resultados com Sistemas de Informações Geográficas.

Os objetivos específicos também foram alcançados:

- *Testar e avaliar a performance, as falhas e as dificuldades na utilização de algumas das principais abordagens metodológicas desenvolvidas para a detecção de copas de árvores individuais a partir de dados VHR.*

Na Seção 2.2, três diferentes abordagens consagradas para o problema de identificação e delineamento das árvores (crescimento de região, *watershed* e *template matching*) foram testadas em uma imagem WV-2 do campus da UFMG. Os resultados mostraram: 1) a dificuldade de utilização da segmentação *watershed* sem o uso de marcadores; 2) a eficiência do *template matching* para identificação de um percentual significativo das copas a partir da utilização de um único modelo; e 3) a eficiência, por um lado, e por outro, a dificuldade para estabelecimento de regras (geometria, textura, relação de vizinhança, características es-

pectrais, funções de pertinência *fuzzy*, entre outros) para a detecção de árvores isoladas com base em classificação de imagens orientada a objetos geográficos.

- *Propor e implementar um método automático de análise de imagens VHR para a detecção e o delineamento de copas de árvores individuais, que seja abrangente e de fácil utilização para o usuário.*

Com base nas potencialidades e dificuldades observadas nos resultados do Capítulo 2 e nas pesquisas que utilizam processos pontuais marcados para reconhecimento de padrões em imagens VHR, o algoritmo PPM-TM foi desenvolvido (Capítulos 4 e 5) com a proposta de aplicação em ambientes TOF, seja em áreas urbanas, plantações, remanescentes de vegetação ou em biomas brasileiros com árvores classificadas como TOF.

- *Testar e avaliar os resultados obtidos pelo método proposto.*

Os resultados preliminares do PPM-TM em ambientes controlados foram apresentados na Seção 4.4. E após o aprimoramento do algoritmo (Capítulo 5), seis imagens de ambientes TOF, em diferentes contextos (urbano, cerrado, mata seca, plantação), foram selecionadas para avaliar a performance do PPM-TM. Na carência de pesquisas nessa área do conhecimento no Brasil, como em outros países tropicais, esta tese possui um caráter inovador, ao demonstrar que a detecção de copas de árvores individuais nesses ambientes é viável, com a obtenção de altas taxas de sucesso. E isso, a partir de uma metodologia de fácil utilização para o usuário, a qual não requer muita experiência e nem a definição de uma série de regras complexas. A entrada dos parâmetros é baseada na análise visual do operador, e não demanda a utilização de informações de outras fontes de dados (ex.: pontos semente oriundos de dados Lidar ou de entrada manual).

As potencialidades do PPM-TM, com a ocorrência ou não de outras classes conceituais, foram observadas para a detecção das árvores: isoladas; em formações florestais abertas; proeminentes no dossel florestal; e em plantações, independente da idade, do espaçamento entre as árvores e do tamanho das copas.

Os resultados obtidos para cerrado *sensu stricto* e mata seca são pioneiros, pois não foram encontradas na literatura pesquisas dedicadas à detecção de árvores individuais nessas formações florestais. Soma-se a isso, as altas taxas de sucesso obtidas para detecção e delineamento das copas. Os resultados fornecem a contagem do número de árvores, sua localização e as características espectrais de suas copas. Esses dados podem contribuir com atividades de monitoramento e manejo em florestas, apoiar estudos de ecologia e biodiversidade, além de possuírem potencial para servir como parâmetro de entrada em modelos que visam estimar as características das comunidades, tais como idade, altura, densidade, área de cobertura da copa, volume de madeira, entre outros. Em plantações, o PPM-TM pode contribuir com o manejo e monitoramento de uma série de culturas, como as de café, laranja, abacate, mexericá, entre outras, permitindo a contagem das árvores e informações sobre a saúde de cada um dos indivíduos (ex.: ausência ou excesso de nutrientes e o acometimento por pragas). Em plantações de mesma idade e espaçamento, o método pode ser simplificado, como proposto

em Maillard e Gomes (2016). Em áreas urbanas, os resultados podem contribuir para o inventário das árvores, principalmente as isoladas, além de dar suporte a decisões de manejo e de monitoramento.

As limitações consistem, sobretudo, em função da adoção de um modelo 3D na detecção das árvores em ambientes mais fechados, com formação de dossel contínuo, com copas entrelaçadas, e com copas muito pequenas, com raio menor ou igual a 3 pixels em imagens com 50 cm de resolução espacial. Para as florestas densas, dosséis contínuos e copas entrelaçadas, pesquisas têm demonstrado que imagens de sensoriamento remoto sozinhas não são capazes da detecção dessas árvores, individualmente, com precisão (Ardila, 2012; Zhou, 2012; Larsen *et al.*, 2011; Erickson, 2004; Pollock, 1996). Para as árvores muito pequenas, a utilização de resolução espacial mais fina e de regras mais flexíveis para essas árvores tenderiam a melhorar os resultados.

O método demonstrou viabilidade computacional, e a modificação do espaço amostral contribuiu para fornecer maior eficiência ao processo. O baixo contraste entre as árvores e a superfície abaixo delas, além da heterogeneidade desses objetos, limitaram a utilização de outros métodos de otimização, como o uso de detectores de pontos de interesse.

Para continuidade desta pesquisa, são feitas as seguintes recomendações e sugestões:

- Estabelecimento de regras mais flexíveis para a detecção das copas de árvores muito pequenas;
- Avaliação do impacto da resolução espacial para o sucesso da detecção;
- Realização de testes e avaliação dos resultados em outros ambientes TOF que ocorrem no Brasil;
- Realização de testes e avaliação dos resultados em outros tipos de plantações;
- Testar o PPM-TM em estudos multitemporais, avaliando a ocorrência de supressão da árvore, acréscimo ou decréscimo na área da copa, além de variações na resposta espectral do objeto. Os pontos gerados pelo PPM poderiam servir de entrada para as novas detecções.
- Nos casos em que o delineamento simplificado não seja suficiente, o processo de segmentação poderia ser aprimorado com a utilização de outros segmentadores após o processamento (como crescimento de região ou *watershed*), ou com a utilização dos pontos do PPM como pontos semente para esses métodos;
- Testar o potencial dos resultados para a classificação de algumas espécies;
- Buscar a automatização da obtenção de alguns parâmetros de entrada, como, por exemplo, os raios mínimo e máximo e a radiância máxima do modelo.

Mesmo com os crescentes esforços, a detecção de árvores individuais em imagens de alta resolução ainda é um desafio para a comunidade de sensoriamento remoto. Além da complexidade estrutural das árvores, muitos outros fatores, como as características da cena (topografia, iluminação e outras variáveis ambientais) e do tipo de vegetação (fenologia e diversidade florística) tornam a tarefa desafiadora. A crescente disponibilidade de imagens

VHR, a partir de satélites comerciais ou mesmo de serviços de mapeamento via *web*, proporcionam um amplo campo de aplicações. Estudos multitemporais fortalecerão ainda mais estas aplicações para fins de monitoramento. Em florestas densas, com a presença de sub-bosque, a integração de imagens VHR e dados Lidar, em função de sua capacidade de penetração na floresta e obtenção de informações dos estratos inferiores, tem obtido melhores resultados, mas ainda assim, detectar todas as árvores dessas florestas é uma meta distante de ser alcançada. Esta pesquisa se configura como mais um esforço na direção de tornar os inventários florestais cada vez mais eficientes, de menor custo, maior repetitividade e recobrindo grandes áreas.

## Referências Bibliográficas

- Andreu, M. G., M. H. Friedman, S. M. Landry, e R. J. Northrop (2008). City of tampa urban ecological analysis 2006-2007. *Final Report to the City of Tampa 24*.
- Arasato, L. S., S. Amaral, e C. D. Rennó (2011). Detecting individual palm trees (arecaceae family) in the amazon rainforest using high resolution image classification. In *Anais XV Simpósio Brasileiro de Sensoriamento Remoto*, Proc. SBSR, pp. 7628–7635.
- Ardila, J. P. (2012, June). *Object-based methods for mapping and monitoring of urban trees of multitemporal image analysis*. Ph. D. thesis, University of Twente, Enschede.
- Avery, T. E. e G. L. Berlin (1992). *Fundamentals of remote sensing and airphoto interpretation*. Prentice Hall.
- Baatz, M. e A. Schäpe (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In J. Strobl (Ed.), *Angewandte Geographische Informationsverarbeitung XII*, pp. 12–23.
- Baddeley, A. e M. V. Lieshout (1993). Stochastic geometry models in high-level vision. *Journal of Applied Statistics* 20(5-6), 231–256.
- Baddeley, A. J., J. Møller, e R. Waagepetersen (2000). Non-and semi-parametric estimation of interaction in inhomogeneous point patterns. *Statistica Neerlandica* 54(3), 329–350.
- Beucher, S. (1992). The watershed transformation applied to image segmentation. In *10th Pfefferkorn Conf. on Signal and Image Processing in Microscopy and Microanalysis*, Volume 6, pp. 299–314.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 2–16.
- Brandtberg, T. e T. Warner (2006). *Computer Applications in Sustainable Forest Management: Including Perspectives on Collaboration and Integration* (1st ed.), Chapter High-spatial-resolution remote sensing, pp. 19–41. Dordrecht, Netherlands: Springer.
- Brasil (2009). *Florestas do Brasil em resumo*. Ministério do Meio Ambiente, Serviço Florestal Brasileiro.

- Bunting, P. e R. Lucas (2006). The delineation of tree crowns in australian mixed species forests using hyperspectral compact airborne spectrographic imager (casi) data. *Remote Sensing of Environment* 101(2), 230–248.
- Caves, R. G., P. J. Harley, e S. Quegan (1992). Matching map features to synthetic aperture radar (SAR) images using template matching. *IEEE Transactions on Geoscience and Remote Sensing* 30(4), 680–685.
- Chiu, S. N., D. Stoyan, W. S. Kendall, e J. Mecke (2013). *Stochastic geometry and its applications*. John Wiley & Sons.
- Culvenor, D. S. (2002). Tida: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. *Computers & Geosciences* 28(1), 33–44.
- Cunha, F. e C. T. M. Centeno (2005). Segmentação de imagens geradas por perfilamento a laser para delimitação de árvores individuais em uma área de reflorestamento de eucaliptos. In *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, Proc. SBSR, pp. 737–744.
- Daley, D. J. e D. Vere-Jones (2003). *An introduction to the theory of point processes: Volume 1: Elementary Theory and Methods*, Volume 2. Springer.
- de Foresta, H. (2017). Onde estão as árvores fora da floresta no brasil? *Pesquisa Florestal Brasileira* 37(91), 393–401.
- De Foresta, H., E. Somarriba, A. Temu, D. Boulanger, H. Feuilly, e M. Gauthier (2013). *Towards the assessment of trees outside forests*. Rome: Food and Agriculture Organization of the United Nations.
- de Foresta, H., E. Somarriba, A. Temu, D. Boulanger, H. Feuilly, M. Gauthier, e D. Taylor (2013). *Towards the assessment of trees outside forests: a thematic report prepared in the Framework of the Global Forest Resources Assessment 2010*. Rome: Food and Agriculture Organization of the United Nations.
- de Melo Franco, V. S. (2006). *Gerenciamento da Arborização na Área do Campus da UFMG Utilizando Ferramentas SIG*. Belo Horizonte: Universidade Federal de Minas Gerais.
- Descamps, S., A. Béchet, X. Descombes, A. Arnaud, e J. Zerubia (2011). An automatic counter for aerial images of aggregations of large birds. *Bird Study* 58(3), 302–308.
- Descombes, X. (2004). *Méthodes stochastiques en analyse d'image: des champs de Markov aux processus ponctuels marqués*. Ph. D. thesis, Université de Nice Sophia-Antipolis.
- DigitalGlobe (2010). The benefits of the 8 spectral bands of worldview-2.

- Erickson, M. (2004, October). *Segmentation and Classification of Individual Tree Crowns in High Spatial Resolution Aerial Images*. Ph. D. thesis, Swedish University of Agricultural Sciences, Uppsala.
- FAO (2010). Towards the assessment of trees outside forests. main highlights: An fao thematic report in the arf framework of the global forest resources assessment.
- Ferreira, M., E. Sano, e L. Ferreira (2003). Atualização do mapa de vegetação do parque nacional de Brasília (bioma cerrado) por meio de imagens orbitais com alta resolução espacial. *X Simpósio Brasileiro de Geografia Física aplicada*.
- Franklin, S. E. (2001). *Remote sensing for sustainable forest management*. CRC press.
- Ge, W. e R. T. Collins (2009). Marked point processes for crowd counting. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pp. 2913–2920. IEEE.
- Gomes, P., M. C. Ferreira, C. Lingnau, E. Bolfe, e M. Siqueira (2008). Segmentação e classificação de dossel florestal em imagens Quickbird. *Ambiência 4*, 35–46.
- Gonzales, R. C. e R. E. Woods (2008). *Digital Image Processing*. Pearson Prentice Hall.
- Gougeon, F. A. *et al.* (1995). A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution aerial images. *Canadian journal of remote sensing 21*(3), 274–284.
- Gougeon, F. A. e D. G. Leckie (2003). *Forest information extraction from high spatial resolution images using an individual tree crown approach*. Canadian Forest Service.
- Gougeon, F. A. e D. G. Leckie (2006). The individual tree crown approach applied to ikonos images of a coniferous plantation area. *Photogrammetric Engineering & Remote Sensing 72*(11), 1287–1297.
- Gougeon, F. A., D. G. Leckie, D. Paradine, I. Scott, *et al.* (1999). Individual tree crown species recognition: The nahmint study. pp. 209–223. Canadian Forest Service Victoria, BC.
- Guan, Y. (2008). A kpss test for stationarity for spatial point processes. *Biometrics 64*(3), 800–806.
- Haralick, R. M., K. Shanmugam, e I. Dinstein (1973). Textural features for image classification. *IEEE Trans. Sys. Man Cybern 3*, 610–621.
- Hay, G. J. e G. Castilla (2008). *Object-Based Image Analysis. Spatial concepts for knowledge-driven remote sensing applications*, Chapter Geographic Object-Based Image

- Analysis (GEOBIA): A new name for a new discipline?, pp. 75–89. Berlin: Springer-Verlag.
- Hung, C., M. Bryson, e S. Sukkariéh (2012). Multi-class predictive template for tree crown detection. *ISPRS journal of photogrammetry and remote sensing* 68, 170–183.
- Immitzer, M., C. Atzberger, e T. Koukal (2012). Tree species classification with random forest using very high spatial resolution 8-band worldview-2 satellite data. *Remote Sensing* 4(9), 2661.
- Ke, Y. e L. J. Quackenbush (2011). A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing* 32, 4725–4747.
- Lamar, W. R., J. B. McGraw, e T. A. Warner (2005). Multitemporal censusing of a population of eastern hemlock (*tsuga canadensis* l.) from remotely sensed imagery using an automated segmentation and reconciliation procedure. *Remote Sensing of Environment* 94(1), 133–143.
- Larsen, M. (1997). Crown modelling to find tree top positions in aerial photographs. In *Presented at the Third International Airborne Remote Sensing Conference and Exhibition*, Volume 7, pp. 10. Citeseer.
- Larsen, M., M. Eriksson, X. Descombes, G. Perrin, T. Brandtberg, e F. Gougeon (2011). Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. *International Journal of Remote Sensing* 32(20), 5827–5852.
- Larsen, M. e M. Rudemo (1998). Optimizing templates for finding trees in aerial photographs. *Pattern Recognition Letters* 19(12), 1153–1162.
- Leckie, D. G., F. A. Gougeon, *et al.* (1999). An assessment of both visual and automated tree counting and species identification with high spatial resolution multispectral imagery. In *International Forum on Automated Interpretation of High Resolution Digital Imagery for Forestry*. Canadian Forest Service, Victoria, British Columbia, Canada, pp. 141–154.
- Levine, M. D. (1985). *Vision in man and machine*. McGraw-Hill College.
- Lombardi, J. A. e P. O. Morais (2003). Levantamento florístico das plantas empregadas na arborização do campus da Universidade Federal de Minas Gerais, Belo Horizonte-MG. *Lundiana* 4(2), 83–88.
- Lucio, P. S., E. M. M. d. Toscano, e M. L. d. Abreu (1999, 11). Caracterizacao de series climatologias pontuais via analise canonica de correspondencia. estudo de caso: Belo horizonte - mg (brasil). *Revista Brasileira de Geofisica* 17, 193 – 207.



- Maillard, P. e M. F. Gomes (2016). Detection and counting of orchard trees from vhr images using a geometrical-optical model and marked template matching. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences* 3(7).
- Marr, D. e E. Hildreth (1980). Theory of edge detection. *Proceedings of the Royal Society of London B: Biological Sciences* 207(1167), 187–217.
- McFeeters, S. K. (1996). The use of the normalized difference water index (ndwi) in the delineation of open water features. *International Journal of Remote Sensing* 17(7), 1425–1432.
- M.C.Lieshout (van) (2010). *Handbook of Apatial Statistics*, Chapter Spatial Point Process Theory, pp. 263–283. Boca Raton: CRC Press.
- Meneguzzo, D. M., G. C. Liknes, e M. D. Nelson (2013). Mapping trees outside forests using high-resolution aerial imagery: a comparison of pixel- and object-based classification approaches. *Environmental Monitoring and Assessment* 185(8), 6261–6275.
- Olinda, R. A. d. (2008). Métodos para análise de independência entre marcas e pontos em processos pontuais marcados. Master's thesis, Universidade Federal de Lavras, Lavras, MG.
- Ortner, M. (2004). *Processus ponctuels marqués pour l'extraction automatique de caricatures de bâtiments à partir de modèles numériques d'élévation*. Ph. D. thesis, Université de Nice Sophia-Antipolis.
- Östeberg, J., T. Delshammar, B. Wiström, e A. B. Nielsen (2013). Grading of parameters for urban tree inventories by city officials, arborists, and academics using the Delphi method. *Environmental Management* 51, 694–708.
- Perrin, G. (2006). *Etude du couvert forestier par processus ponctuels marqués*. Ph. D. thesis, Ecole Centrale Paris.
- Pollock, R. J. (1994). Model-based approach to automatically locating tree crowns in high spatial resolution images. Volume 2315, pp. 526–537.
- Pollock, R. J. (1996). *The automatic recognition of individual trees in aerial images of forests based on a synthetic tree crown image model*. Ph. D. thesis, Concordia University.
- Pouliot, D., D. King, F. Bell, e D. Pitt (2002). Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment* 82(2), 322–334.
- Pratt, W. K. (2007). *Digital Image Processing: PIKS Scientific inside* (4 ed.). Hoboken, New Jersey: John Wiley & Sons.

- Pu, R. e S. Landry (2012). A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. *Remote Sensing of Environment* 124, 516–533.
- Quackenbush, L. J., P. F. Hopkins, e G. J. Kinn (2000). Developing forestry products from high resolution digital aerial imagery. *Photogrammetric Engineering and Remote Sensing* 66(11), 1337–1346.
- Richards, J. A. (1993). *Remote Sensing digital image analysis: an introduction*. Springer-Verlag.
- Rizzini, C. T. (1997). *Tratado de fitogeografia do Brasil: aspectos ecológicos, sociológicos e florísticos*. Âmbito Cultural.
- Sander, H., S. Polasky, e R. G. Haight (2010). The value of urban tree cover: A hedonic property price model in Ramsey and Dakota Counties, Minnesota, USA. *Ecological Economics* 69, 1646–1656.
- Schipperijn, J., W. Pillmann, L. Tyrväinen, K. Mäkinen, e R. O'Sullivan (2005). Information for urban forest planning and management. In *Urban forests and trees*, pp. 399–417. Berlin: Springer-Verlag.
- Shao, G. e K. M. Reynolds (2006). *Computer Applications in Sustainable Forest Management: Including perspectives on collaboration and integration*. Springer.
- St-Onge, B. (1994). *L'apport de la texture des images numériques de haute résolution à la cartographie forestière automatisée*. Ph. D. thesis, Université de Montréal.
- Sydney, T. R. B. G. (2016). The royal botanic garden sydney.
- Szeliski, R. (2010). *Computer vision: algorithms and applications*. Springer.
- Trimble (2011). *eCognition Developer user guide*. München, Germany: Trimble.
- Tso, B. e P. Mather (2001). *Classification Methods for Remotely Sensed Data*. London: Taylor and Francis.
- UNFCCC, U. N. F. C. o. C. C. (2001). The marrakesh accords and the marrakesh declaration. *In adopted by the Conference of the Parties at its seventh session*.
- Van Coillie, F., F. Devriendt, e R. De Wulf (2012). Directional local filtering assisting individual tree analysis in closed forest canopies using vhr optical and lidar data. In *4th International conference on Geographic Object Based Image Analysis (GEOBIA 2012)*, pp. 350–354.

- Venâncio, D. L. (2009). Mapeamento de araucaria angustifolia utilizando dgps e imagem de satélite quickbird-2. Master's thesis, Universidade Estadual do Centro Oeste, Irati, PR.
- Wang, L., P. Gong, e G. S. Biging (2004). Individual tree-crown delineation and treetop detection in high-spatial-resolution aerial imagery. *Photogrammetric Engineering & Remote Sensing* 70(3), 351–357.
- Whitted, T. (1979). An improved illumination model for shaded display. In *ACM SIGGRAPH Computer Graphics*, Volume 13, pp. 14. ACM.
- Wulder, M., K. O. Niemann, e D. G. Goodenough (2000). Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sensing of environment* 73(1), 103–114.
- Zhou, J. (2012). *Application de l'identification d'objets sur images à l'étude de canopées de peuplements forestiers tropicaux: cas des plantations d'Eucalyptus et des mangroves*. Ph. D. thesis, Université Montpellier II-Sciences et Techniques du Languedoc.
- Zhou, J., C. Proisy, P. Couteron, X. Descombes, J. Zerubia, G. le Maire, e Y. Nouvellon (2011). Tree crown detection in high resolution optical images during the early growth stages of eucalyptus plantations in brazil. In *Pattern Recognition (ACPR), 2011 First Asian Conference on*, pp. 623–627. IEEE.
- Zhou, J., C. Proisy, X. Descombes, G. Le Maire, Y. Nouvellon, J.-L. Stape, G. Viennois, J. Zerubia, e P. Couteron (2013). Mapping local density of young eucalyptus plantations by individual tree detection in high spatial resolution satellite images. *Forest Ecology and Management* 301, 129–141.
- Zomer, R. J., H. Neufeldt, J. Xu, A. Ahrends, D. Bossio, A. Trabucco, M. Van Noordwijk, e M. Wang (2016). Global tree cover and biomass carbon on agricultural land: The contribution of agroforestry to global and national carbon budgets. *Scientific reports* 6, 29987.

## **Apêndices**

# Apêndice A

## Publicações e Conferências

A autora produziu as seguintes publicações como primeira autora ou como co-autora:

- Gomes, M. F., Maillard, P., Deng, H. (2018). Individual tree crown detection in sub-meter satellite imagery using Marked Point Processes and a geometrical-optical model. *Remote Sensing of Environment*, 211, 184-195. DOI: <https://doi.org/10.1016/j.rse.2018.04.002>
- Gomes M.F., Maillard P. (2016). Detection of Tree Crowns in Very High Spatial Resolution Images, *Environmental Applications of Remote Sensing*, Prof. Maged Marghany (Ed.), InTech, DOI: 10.5772/62122. Available from: <http://www.intechopen.com/books/environmental-applications-of-remote-sensing/detection-of-tree-crowns-in-very-high-spatial-resolution-images>
- Maillard, P., Gomes, M. F.: Detection and Counting of Orchard Trees from VHR Images using a Geometrical-Optical Model and Marked Template Matching, *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, III-7, 75-82, DOI:10.5194/isprs-annals-III-7-75-2016, 2016.
- Gomes M.F., Maillard P. (2015). Using spectral and textural features from RapidEye images to estimate age and structural parameters of Cerrado vegetation. *International Journal of Remote Sensing*. Volume 36, Issue 12, pg. 3058-3076. DOI:10.1080/01431161.2015.1055604
- Gomes, M.F. and Maillard, P., 2014. Integration of a marked point process and template matching for the identification of individual tree crowns in an urban and a wooded savanna environment in Brazil. In: *Proceedings of SPIE Remote Sensing 2014*, Vol. 9245, International Society for Optics and Photonics, Amsterdam, The Netherlands, pp. 92450X.1 – 92450X.12.
- Gomes M.F., Maillard P. Identification of urban tree crown in a tropical environment using WorldView-2 data: problems and perspectives. In: Michel U, Civco DL, Schulz

K, Ehlers M, Nikolakopoulos KG, editors. SPIE 8893, Earth Resources and Environmental Remote Sensing/GIS Applications IV; 23–25 September; Dresden. Washington: SPIE; 2013. p. 88930C-88930C-13. DOI: 10.1117/12.2029073

- Gomes, M.F. ; Maillard, P. O uso de feições de textura em imagens RapidEye para estimativas da idade e de parâmetros estruturais da vegetação do cerrado. In: XVI Simpósio Brasileiro de Sensoriamento Remoto, 2013, Foz do Iguaçu. Anais do 16º Simpósio Brasileiro de Sensoriamento Remoto, 2013.

A autora participou das seguintes conferências internacionais:

- SPIE Remote Sensing 2013, Dresden, Alemanha, 23 a 26 de Setembro de 2013 (Apresentação oral).
- SPIE Remote Sensing 2014, Amsterdã, Holanda, 22 a 25 de Setembro de 2014 (Apresentação oral).
- Seminaire au Laboratoire d'Études en Géophysique et Océanographie Spatiales, Toulouse, France, 15 de Setembro de 2014 (Apresentação oral).

A autora participou das seguintes conferências nacionais:

- XVI Simpósio Brasileiro de Sensoriamento Remoto (XVI SBSR), Foz do Iguaçu, Paraná, Brasil, 13 a 18 de Abril de 2012 (Apresentação em pôster).

## **Apêndice B**

### **Artigos Publicados**



Contents lists available at ScienceDirect

## Remote Sensing of Environment

journal homepage: [www.elsevier.com/locate/rse](http://www.elsevier.com/locate/rse)

# Individual tree crown detection in sub-meter satellite imagery using Marked Point Processes and a geometrical-optical model

Marília Ferreira Gomes<sup>a,\*</sup>, Philippe Maillard<sup>b,\*</sup>, Huawu Deng<sup>c,\*</sup>

<sup>a</sup> INCRA, Av. Afonso Pena, 6627, Belo Horizonte, MG 31270-901, Brazil

<sup>b</sup> Universidade Federal de Minas Gerais, Av. Antônio Carlos, 6627, Belo Horizonte, MG 31270-901, Brazil

<sup>c</sup> PCI Geomatics, 490 Saint Joseph Blvd., Gatineau, Quebec J8Y 3Y7, Canada

## ARTICLE INFO

## Keywords:

Individual tree crown detection  
Sub-meter satellite images  
Marked Point Process  
Trees outside forests  
Template matching

## ABSTRACT

This article describes a new algorithm for the detection and delineation of tree crowns using optical sub-meter resolution satellite images. The algorithm focuses on detecting individual semi-isolated trees in a variety of environments defined as trees outside forests (TOF). The concept of Marked Point Processes (MPPs), which alternates phases of “birth” and “death” iterations to satisfy a density factor was used as a theoretical basis. The “mark” in the MPP represents the object being sought. Unlike most applications of MPP to object recognition, the mark used in our algorithm is computed from a 3D geometrical optical model artificially lit using the same illumination parameters as the image itself. Because trees differ in size, the process also incorporates a tree crown radius variable. The algorithm is tested on four sub-meter satellite images, each in a different environment. Validation was performed on both detection and delineation. The detection was based on tree crown counting and yielded an accuracy ranging from 0.81 to 0.95 for the four images. The delineation accuracy was estimated based on the crown pixel count and yielded an accuracy of  $\approx 0.63$  (0.57–0.72).

## 1. Introduction

Scattered trees and shrubs in urban areas, plantations, and even pastures not belonging to a forest or woodland ecosystem, are called trees outside forests (TOF) according to the Food and Agricultural Organization of the United Nations (FAO) and almost half the land on Earth is potentially a TOF area of occurrence (FAO, 2010). Even scattered, these TOF play a major role in the economy of populated environments and their management and monitoring are representative of efforts to make these areas sustainable (De Foresta et al., 2013). For instance, TOF offer a variety of ecological services, such as improving the quality of the air and water, regularizing micro-climates, reducing the concentration of carbon dioxide and other pollutants, reducing energy costs, helping control soil erosion by reducing overland flow, and bringing biodiversity to their environment (Meneguzzo et al., 2013; Andreu et al., 2008; Almeida, 2006).

Authors such as Zhang (2001) and De Foresta et al. (2013) have proposed methods for the detection of TOF areas from remotely sensed data. However, the identification of individual trees within these areas is a different problem altogether, which is often solved through traditional inventory methods based on sampling approaches (Pollock, 1994b; Avery and Berlin, 1992). Among the variables these traditional

methods employ, some of the most important ones are 1) the location, 2) the measurements of the trees, and 3) the species, for which sub-meter imagery (hereinafter called VHR to stand for Very High Resolution) can bring an expressive contribution (Pu and Landry, 2012; Ke and Quackenbush, 2011; Zhang, 2001). The basic information of tree location, distribution, density and crown size is useful for a variety of activities in many environments. Given the importance of trees in urban environments, high quality information is needed to support management programs (Östeberg et al., 2013; Schipperijn et al., 2005) and many city administrations are conducting extensive inventories of their tree stocks in streets and parks (Schipperijn et al., 2005). Table 1 presents some examples of this.

Measurements of a tree consist of various variables (height, volume, diameter at breast height, crown diameter, etc.) and because the tree crown diameter is the only one really predictable from monoscopic VHR imagery, it is sometimes used for monitoring tree growth and as an input parameter in canopy models (Clark et al., 2004; Asner et al., 2002). In some cases the projected shadow can also be used to estimate height (Chopping, 2011). Understory tree crowns can be very difficult to detect with remote sensing data (Palace et al., 2008). Conversely, crowns of large tall trees can arguably be better estimated using image data than with field surveys (Clark et al., 2004). Species classification

\* Corresponding authors.

E-mail addresses: [marilia.gomes@bhe.incra.gov.br](mailto:marilia.gomes@bhe.incra.gov.br) (M.F. Gomes), [philippe@ufmg.br](mailto:philippe@ufmg.br) (P. Maillard), [deng@pcigeomatics.com](mailto:deng@pcigeomatics.com) (H. Deng).



**Table 1**

Examples of the usefulness of having basic location and tree crown size information about TOF.

Environment	Importance of information on TOF
Urban areas	inventories, monitoring growth, planning for planting and pruning
Rural areas	sustainable subsistence for rural communities (fire wood, fruit harvesting)
Planted forests	monitoring growth and plague, logging operations planning
Pastures	monitoring shade environments for animals
Orchards	tree counting, planning for pruning, detection of plague, monitoring growth
Power lines	monitoring tree growth under power lines
Underground pipelines	planning tree cutting above pipelines

with multispectral imagery can be very challenging and only a small number of species can usually be recognized. In tropical environments, the variety of species often makes such identification impractical (Fassnacht et al., 2016).

The objective of this article is to present an original algorithm based on the Marked Point Process (MPP) concept for the detection and delineation of individual trees in TOF environments. The algorithm is described in detail in the [Methods section](#) and includes the description of the geometrical-optical model used to create the mark. Testing was performed on four WorldView satellite sub-images in a variety of contexts. Two validation approaches were used to assess the performance of the algorithm. The first one is based on tree crown counts in each image considering true positives, false negatives and false positives. The second approach considers the accuracy of the delineation (crown diameter vs true crown shape and size) by comparing the results with a sample of individual tree crowns collected as ground truth. The [Discussion section](#) brings an analysis of the behavior of the algorithm in the situations encountered through the different images tested but also reflections on its strengths and weaknesses. Considerations and improvements that could be implemented are also discussed. [Section 6](#) concludes the article.

## 2. Background on tree crown detection in VHR images

With the launch of Ikonos in 1999, satellite remote sensing began to supply VHR data with a spatial resolution of one meter, allowing the study of individual trees [Shao and Reynolds \(2006\)](#). Ikonos data quickly demonstrated itself useful for improving land cover mapping and to estimate forest crown diameter, basal area and biomass ([Hurtt et al., 2003](#)). Before that, only high resolution aerial photography could be used for tasks such as tree species recognition and monitoring ([Avery and Berlin, 1992](#)). Since then, a number of VHR satellites (e.g., Quickbird, Geosyde, WorldView, and Pléiades) have become available for consolidating the use of satellite imagery for the study of individual trees. The automated detection and delineation of tree crowns from remote sensing VHR imagery have attracted attention from researchers in forestry, computer vision, and remote sensing in general ([Ke and Quackenbush, 2011](#); [Gougeon and Leckie, 2003](#)). A large amount of research on this subject can now be found in the specialized literature and is usually based on image segmentation algorithms and other advanced image processing and analysis techniques ([Blaschke, 2010](#); [Hay and Castilla, 2008](#)). However, most of this literature has been specifically developed for the detection and delineation of trees in temperate forests ([Ke and Quackenbush, 2011](#)). Many have also added the vertical dimension through Light Detection and Ranging (lidar) to help the recognition or classification of trees ([Van Coillie et al., 2012](#); [Leckie et al., 2003](#)).

The individual tree detection paradigm based on remote sensing images is a complex problem. Trees are not homogeneous objects, and their size, shape, texture, and spectral characteristics vary widely. What

is detected as a single object may in fact represent a group of trees. Conversely, a tree bundle can be confused for a single tree ([Pu and Landry, 2012](#)). Other sources of error include the proximity of neighboring trees, trees located under other trees, trees in shadows, or trees that have a low spectral contrast with their background ([Wulder et al., 2000](#)). Only very sophisticated algorithms can deal with this level of complexity ([Pollock, 1994a](#)).

Authors in the field of remote sensing and individual tree detection have investigated a wide variety of algorithmic approaches. For the specific case of tree crown detection with the use of two-dimensional imagery, such approaches include Local Maximum Filtering (LMF) ([Wulder et al., 2000](#); [Culvenor, 2002](#); [Brandtberg and Warner, 2006](#); [Gonzalez et al., 2010](#)), Template Matching (T-M) ([Caves et al., 1992](#); [Pollock, 1996](#); [Larsen and Rudemo, 1998](#); [Hung et al., 2012](#)), Valley Following (VF) ([Leckie et al., 1999](#); [Gougeon and Leckie, 2006](#)), Watershed (WS) ([Beucher, 1992](#); [Wang et al., 2004](#); [Lamar et al., 2005](#)), Region Growing (RG) ([Culvenor, 2002](#); [Erickson, 2004](#); [Bunting and Lucas, 2006](#)), focal operators and mathematical morphology ([Chopping, 2011](#)) and Marked Point Processes (MPP) ([Descombes, 2004](#); [Perrin, 2006](#); [Zhou, 2012](#)).

[Larsen et al. \(2011\)](#) tested six approaches (viz., LMF, VF, RG, T-M, Markov Random Fields (MRF) and MPP), and concluded that MPPs demonstrate potential for the detection of tree crowns. However, the authors also concluded that none of the six methods achieved good scores in all situations of the forests they tested.

### 2.1. The theory of Marked Point Processes and their use in detecting objects

A Point Process (PP) can be defined in any number of dimensions in space. It can even be defined in time, or a combination of both. In a multi-dimensional space, a PP is realized by a random set of locations  $P = \{p_1, \dots, p_n\}$  in a bounded region  $R$  of  $d$  dimensions,  $P \in R^d$ . If we associate a particular shape with each location, then we need to consider that these objects also have a certain relation with each other. For instance, they cannot occupy the same space or, in the case of trees, can only overlap to a certain extent. In such cases, a PP can be better modeled using a Marked Point Process (MPP) ([van Lieshout, 2010](#)), which is a PP coupled with a second process defined over a space of “marks”  $M$ . The MPP can be defined as  $\chi = P \times M$ . Therefore a configuration of an MPP can be described as

$$\chi = \{(\mathbf{p}_i, m_i) : i = 1, \dots, n, \mathbf{p}_i \in R^d, m_i \in M\} \quad (1)$$

where  $\mathbf{p}_i$  are locations in  $R^d$  and  $m_i$  are the associated marks.

A realization of an MPP is then a set of random locations in a topological space coupled with a separable predefined mark, such as a point, a circle, a rectangle, or any shape. Considering that an image can be viewed as a set of pixels for which the gray level is a realization of a random model version of this image ([Ortner, 2004](#)), the value or property of the pixels can in turn be modeled using geometrical shapes (e.g., circles, ellipses, rectangles) that agree with the geometric and radiometric properties of the image.

MPPs have been used for very specific object recognition purposes in VHR images ([Zhou, 2012](#); [Perrin, 2006](#); [Descombes, 2004](#); [Ortner, 2004](#)). For such applications, an MPP approach bears some resemblance with template matching. In the case of tree crown recognition the location of the trees is governed by multiple factors, one of which is the presence of other trees ([van Lieshout, 2010](#)). As such, the “mark” of the tree can be simply modeled by a disk or an ellipse of varying size.

The density of the MPP is also a critical factor, especially when considering the space of marks and the rules that apply to it. The density of the MPP can be defined by different point distribution functions, such as those of Poisson, Strauss, Gibbs, or Markov. For tree crown recognition, authors have used Gibbs and Markov random fields ([Zhou, 2012](#); [Perrin, 2006](#); [Descombes, 2004](#)). Authors have also used a MPP approach in image processing for counting people in crowds ([Ge](#)

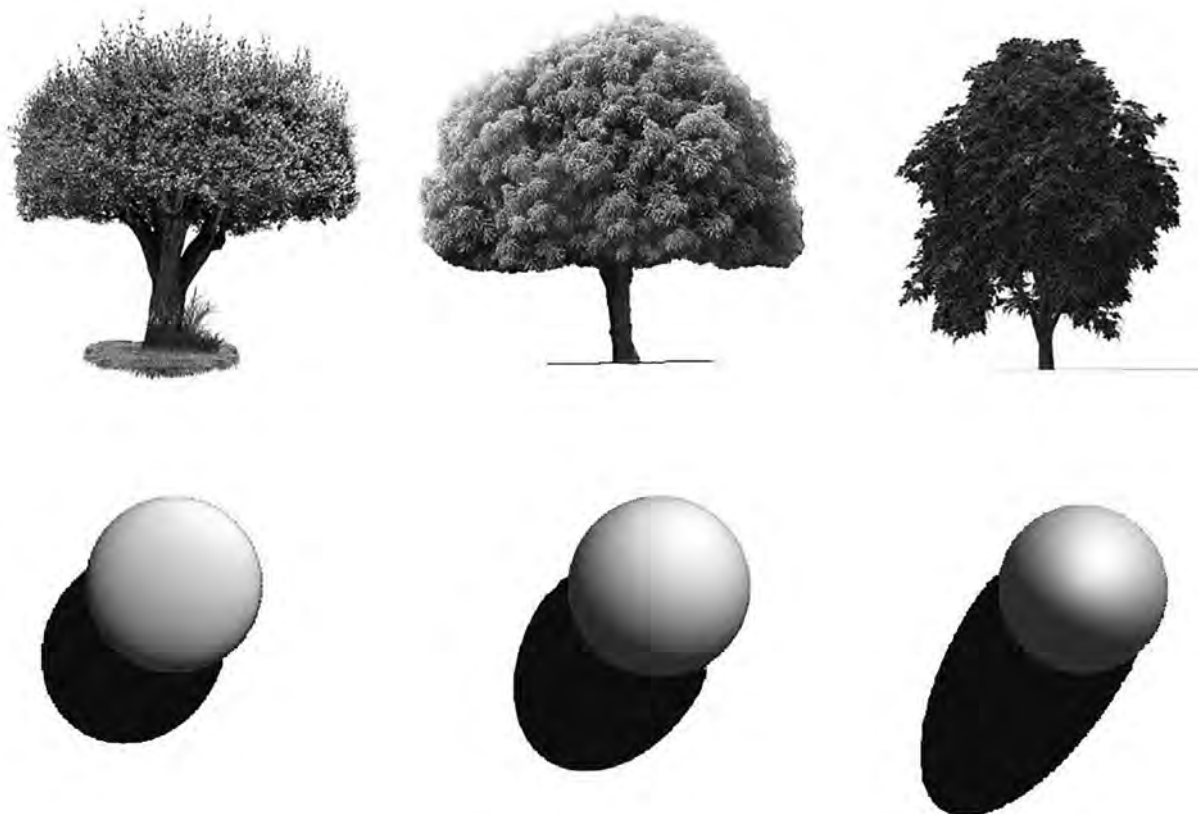


Fig. 1. Examples of 3D geometrical-optical tree crown models with different geometries showing their effect on the illumination and the shadow.

and Collins, 2009), finding buildings in digital surface models (Ortner, 2004), counting large birds in very high resolution images (Descamps et al., 2011), and detecting and mapping trees in various situations (Perrin, 2006; Zhou et al., 2011, 2013).

### 3. Methods: the algorithm

MPPs have received some attention for their usefulness in object recognition with VHR images. In particular, the work done by the team of *Institut national de recherche en informatique et en automatique* (Inria) and the Ariana project (Université Nice — Sophia Antipolis, France) should receive merit for their efforts in using MPPs to detect buildings, large birds, and trees in various environments ([http://www\\_sop.inria.fr/ariana/index.php](http://www_sop.inria.fr/ariana/index.php)). Zhou (2012) used MPPs for detecting trees in a mangrove forest and in planted forests, but these test areas were all quite homogeneous. In all cases, the mark was a simple flat geometrical form.

The use of MPPs was found appropriate for the detection and simplified delineation of tree crowns, and we adapted it for our research. The first adaptation consisted in using a 3D geometrical-optical (3DGO) tree crown model instead of the flat disks used by the previously cited references. We also adopted a similarity measurement integrating a normalized difference and the cross-correlation between the gray levels of the 3DGO model and the image. This constitutes a hybrid approach we called MPPTM for its MPP origin and its resemblance to T-M.

The approach starts from randomly selecting coordinates within the image space where the marks are positioned without overlap. The radius of the mark is chosen from a random pre-defined interval. This sounds similar to a Monte Carlo approach except that in our case, the marks kept after each iteration limit the image space for the next iteration which slightly violate the assumption of statistical independence between events. The fact that the marks are *a priori* non-overlapping characterizes a “germ-grain” model which can be viewed

as a special case of an MPP (Chiu et al., 2013). The search space is also reduced by removing non-vegetated areas, using a mask based on spectral information. Because of the randomness of the process, the Poisson distribution was used, as was the case in Ge and Collins (2009).

Because the 3DGO model usually produces a bi-modal spectral histogram with bright values representing the sunlit part and dark values representing the shaded portion (unless the sun is directly overhead), special considerations were required to take advantage of this peculiarity instead of making it a drawback in terms of within-class variance.

#### 3.1. The 3D geometrical-optical model

The algorithm uses a geometrical-optical tree model and uses a similarity measure between image and model to identify candidate pixels.

The variables that determine the radiance pattern of a tree crown can include: direct and indirect radiation, shape of the tree crown, branch pattern, leaf reflectance, and multiple reflectance within the crown (St-Onge and Cavayas, 1995). To create a valid 3D geometrical-optical model, we chose a simplified version in which the crown is represented by a dome (Eq. (2)).

$$GC_{(i,j)} = (r \times \rho) + (\sqrt{r^2 - d^2}) \times \alpha \tag{2}$$

where GC is the geometry of the tree crown,  $r$  is its radius,  $\rho$  is the height of the tree, defined as a proportion of the crown size,  $d$  is the diameter,  $i,j$  corresponds to each pixel contained in the array, and  $\alpha$  is a shape parameter for the tree. A small  $\alpha$  ( $< 1.0$ ) produces a flatter tree crown, and the larger one ( $> 1.0$ ), a more elongated or oval shape.

The tree crown radiance varies with the sun elevation, using a Lambertian reflectance model (Tso and Mather, 2001) with ambient light and a projected shadow on the ground. Eq. (3) gives the formulation of our radiance model in which each pixel is treated as a

singular surface.

$$L = L_M \left( \frac{\cos \theta_s}{\cos \theta_i} \right) + amb \tag{3}$$

where  $L_M$  is the maximum radiance of the tree crown,  $\theta_s$  is the solar zenith angle,  $\cos \theta_i$  is the angle formed between the sun zenith angle and the surface normal, and  $amb$  is the diffuse illumination variable.

The geometrical-optical model is adjusted according to the specific illumination parameters of the image and the size of the trees present in the scene. Not only can the reflectance of the trees change from one species to another, but its shape can also change (Fig. 1). Similarly a range of radiance values is likely to be sufficient to represent most individual tree objects, given their optical properties (lit on one side and shaded on the other), and to separate them from the other surrounding objects.

To add realism, the model was incremented with projected shadows based on a ray-tracing algorithm (Whitted, 1979) using a simple hard shadow model and an infinite source of light. A projected shadow clipping variable was also added to take into account the fact that it is not beneficial to use the whole shadow in situations where it is projected onto another tree and not on the ground. The height of the tree also affects the size of the shadow and was set as a function of the radius. Fig. 2 shows a comparison between the tree model and an actual tree from the image.

Since the algorithm will randomly choose a radius within a pre-defined range (specific to each image), a “library” of tree crown models is produced when the program starts using the following parameters and variables: minimum and maximum radii, radius interval step, tree crown geometry, illumination and projected shadow proportion used.

### 3.2. Initial setting of the MPPTM algorithm

The spatial distribution pattern of the MPP is random, and can be described by a first-order probability density function. Because of its randomness and its independence, we adopted a Poisson probability distribution so that the process is only controlled by the intensity, which is independent of the radius of the mark. We describe the intensity of the process by the average number of pixels belonging to a tree crown instead of the number of marks (Eq. (4)):

$$\lambda = A_x \times D_{max} \tag{4}$$

where  $A_x$  represents the search area in the image (ha) and  $D_{max}$  is the maximum density of trees per hectare.  $D_{max}$  is set by the user, who needs to estimate this value from the part of the image with the largest tree density. This will result in overestimating the number of trees which is a desired outcome. Conversely, if the density is underestimated, the process might interrupt itself before detecting all the trees. Lambda ( $\lambda$ ) determines the number of trees to look for. It also determines how many trees the birth phase will try to put in the search space and therefore could cause problems if the number is too large for the space available. To prevent this an iteration threshold has been implemented so that the number of trees will automatically be reduced if the algorithm is unable to place any additional tree after 1000 trials.

An important aspect of the program is related to the way the mark (the 3DGO) model is compared with the actual image at each location the MPP will randomly select. For this process, the main metric is given by a similarity value ( $Sm$ ) defined as (Eq. (5)):

$$Sm = \gamma - w \times Dif \tag{5}$$

where  $\gamma$  is the cross-correlation (Eq. (6)) between the radiance values of the model and the gray levels of the pixels in the corresponding portion of the image,  $Dif$  (Eq. (7)) is a normalized absolute difference measure, and  $w$  is a weight factor. The value of  $Sm$  can vary between [-1,w,1]. It was found by trial and error that  $w$  worked better with a value of 0.5.

$$\gamma = \frac{1}{n} \sum_{x,y} \frac{(f_{(x,y)} - \bar{f})(\omega_{(x,y)} - \bar{\omega})}{S_f S_\omega} \tag{6}$$

$$Dif = \left| \frac{\sum_{x,y} f_{(x,y)} - \sum_{x,y} \omega_{(x,y)}}{\sum_{x,y} f_{(x,y)} + \sum_{x,y} \omega_{(x,y)}} \right| \tag{7}$$

In these equations,  $\omega$  is the radiance values of the 3DGO,  $f_{(x,y)}$  are the gray levels of the pixels in the portion of the image under consideration;  $S_f$  and  $S_\omega$  are the standard deviations for  $f_{(x,y)}$  and  $\omega_{(x,y)}$ .

The algorithm alternates between phases of birth and death: the former randomly places marks on a matrix having the same size as the image and the latter destroys the marks rejected by the analysis process. This process continues until interrupt handler is triggered. These three processes (birth, death, termination) are explained in the following paragraphs.




Fig. 2. Comparison between (a) an isolated tree from the panchromatic WorldView-2 image and (b) the 3DGO model with the same illumination parameters and spectral average.




Fig. 3. Four WV-2 test images with their respective validation sample: (a) the UFMG campus of Belo Horizonte, Brazil; (b) the “Parque Ecológico” urban park of the same city; (c) the Royal Botanic Garden of Sydney, Australia; (d) the Morro Bay area in California.

The birth phase starts with placing a predefined number (determined by the intensity) of temporary simple marks (i.e., a disk) of random radii  $[r_{min}, r_{max}]$  inserted at random coordinates within the space of the image.

The location of each random coordinate is discretized to a pixel position (line, column). If it is already occupied by a mark or if the mark overlays another one, the coordinate is rejected and another coordinate is randomly selected. If the mark passes this initial test, the space occupied by the mark on the real image ( $f_{(x,y)}$ ) is compared with the 3DGO model ( $\omega_{(x,y)}$ ) corresponding to the same radius as the disk.

When all the disks are placed on the matrix corresponding to the image, the algorithm calculates and stores the following tree crown parameters: Position, Correlation, Difference, Similarity, Radius, Mean radiance, Standard deviation and Identification index.

These measurements are used for globally monitoring the process. By the end of the birth phase, the similarity values of the disks are sorted in decreasing order so that the death phase will destroy all disks below the  $Sm$  threshold (Supplementary Material Algorithm 1).

The death phase seeks to eliminate the disks that do not correspond to trees. In the MPP proposed by Perrin (2006), Descamps et al. (2011) and Zhou et al. (2011), the death phase is also a random process. We deviated from this approach and our death phase is based on a preset

similarity threshold that can automatically adjust itself with the iterations. In MPPTM, the death phase consists of evaluating the dependency or the repulsion between the central coordinates of the images and their marks. Any disk with an  $Sm$  value equal or greater than to the threshold ( $Sm_T$ ) is kept, while the others are destroyed. To make this process more dependent on the special characteristics of the tree crowns, we also implemented a first-order texture analysis by defining a standard deviation interval ( $[s_{min}, s_{max}]$ ) for the disks to be preserved (Supplementary Material Algorithm 2).

The Recursivity and the process of termination are vital parts of the algorithm. With each iteration the preserved marks are reinserted into the birth process and new objects are sought until the intensity factor is satisfied. If  $\lambda = 100$  and 10 objects are preserved after the death phase, the next birth will put 90 objects on top of the 10 already there. The 100 objects are then sorted according to their similarity and all the objects having  $Sm < Sm_T$  are eliminated. This is especially important towards the end of the iterations and guarantees that the trees with the largest similarity throughout the iterations are kept (Supplementary Material Algorithm 3).

Because the shape and spectral characteristics of the trees can vary, it was desirable to include some flexibility in the iteration process. Three automated adjustment measures were implemented in the code.

First, if no additional tree is found after  $I_{nr}$  iterations (usually 25), the similarity threshold is reduced by a certain factor ( $\sim 0.01$ ). Then, if after  $r$  reductions no trees are found, the process is stopped altogether. Finally, if the maximum number of iterations ( $I_{max}$ ) is exceeded or the minimum similarity value is reached, the process is also stopped. Alternatively, the process can also be stopped by the user using a key command (ctrl[C]).

### 3.3. Elimination of non-vegetated areas

In a TOF environment, a large proportion of the land is often covered by non-vegetated surfaces that would still receive marks. A large portion of the image can easily be eliminated with a simple threshold even in panchromatic images. An image space reduction was implemented by partially eliminating non-vegetated surfaces in the images.

A panchromatic image generally integrates a large portion of the visible spectrum and a small portion of the near infrared. In an urban environment, the upper third of the dynamic range of the pixel values mostly corresponds to concrete and other mineralized surfaces. Furthermore, very low brightness values, often associated with bodies of water and can also be excluded, thus leading to keep only an interval between low and high radiance values that corresponds to vegetation. RGB (red, green and blue) images can be transformed in luminance values proposed by the *Comission Internacional de l'Eclairage* (Gonzales and Woods, 2008; Pratt, 2007) and then receive the same treatment as panchromatic images.

## 4. Image data

WorldView-2 (WV-2) sub-images were selected to test MPPTM and evaluate its performance in different TOF environments (Fig. 3). The first image covers the campus of *Universidade Federal de Minas Gerais* (UFMG) in Belo Horizonte, Brazil, characterized by a wide diversity of tree species (native and exotic) and crown sizes but also by large areas of buildings and grass (Fig. 3a). The second image is mainly covered by an urban park inaugurated in 2004 as a recreational area of Belo Horizonte and is dominated by a majority of relatively small trees (Fig. 3d). The third image is from the city of Sydney, Australia and the treed area belongs to its Royal Botanic Garden (Fig. 3c). The last image was entirely taken from an avocado plantation in Morro Bay, California (Fig. 3b). While the two sub-images from Brazil were acquired from a licensed distributor, the other two were downloaded from the DigitalGlobe web site (<https://www.digitalglobe.com/>) as free image data samples (Table 2).

The panchromatic band from three of the four sub-images was used for testing. The Morro Bay image was converted from RGB to luminance (i.e., as a panchromatic band). The tree crown diameters vary from about 3 m to 20 m. The trees also vary widely in shape and species.

**Table 2**

WorldView-2 test images over TOF lands with their characteristics, location, year and context.

Image	Lat/Long	Site	Bands	Bits	Year	TOF context
1	19° 52'12"S, 43° 57'47"W	UFMG campus, Belo Horizonte, Brazil	1 px and 8 mx	8	2010	Urban area
2	19° 51'26"S, 43° 59'48"W	"Parque ecológico" Belo Horizonte, Brazil	1 px and 8 mx	8	2010	Urban park
3	33° 51'45"S, 151° 13'04"E	Royal Botanic Garden, Sydney, Australia	1 px and 8 mx	8	2011	Urban park
4	35° 23'13"N, 120° 50'14"W	Avocado plantation, Morro Bay, CA, USA	RGB	8	2011	Orchards

px: panchromatic; mx: multi-spectral.

## 4.1. Validation

### 4.1.1. Tree detection accuracy

The first type of validation is based on simply counting trees correctly detected or missing, based on two independent samples: one for the *recall* ( $r$ ) and another for the *precision* ( $p$ ). Recall is inversely related to omission error while precision is inversely related to commission error. The overall accuracy was obtained by the *F-score* (Eq. (8)), a measure that represents the harmonic mean of recall and precision (Lu et al., 2014; Goutte and Gaussier, 2005). Hence larger  $p$  and  $r$  values result in larger *F-scores*. These performance indicators were evaluated considering the true positives (TP for correctly detected trees), false positives (FP for erroneously detected trees) and false negatives (FN for trees not detected). Because the objects being sought do not occupy the whole images, it did not make sense to calculate true negatives (TN for trees not detected where there are no trees).

The *F-score* or overall accuracy is then defined by Eq. (8)

$$F - score = 2 \times \left( \frac{recall \times precision}{recall + precision} \right) \quad (8)$$

where recall and precision are defined as:

$$recall = \frac{TP}{TP + FN} \quad (9)$$

$$precision = \frac{TP}{TP + FP} \quad (10)$$

For the recall (Eq. (9)), a set of 100 sample units for each image was selected using a simple random sampling approach in which the same number of trees was sampled within the search area. Field data were only collected for the UFMG campus image and these included the tree location, height, crown size and species (for further studies). For the other images, the tree crowns were visually delineated by photo-interpretation, which, given the high resolution, is usually considered a valid option (Larsen et al., 2011; Erikson, 2004; Wang et al., 2004). In consideration of the spatial resolution of the images, small trees ( $< 3.5$  pixels of radius), trees in woodlands (non TOF), leafless trees, and trees mostly under other trees were avoided. Fig. 3 shows these samples overlaying the original images. Because this analysis is based on a sample, it does not allow assessing false positives (erroneously detected trees or FP).

To estimate the precision (Eq. (10)), false positives needed to be considered. In this case, the sample units (also 100 for each image) were randomly selected from each detection result and the detected objects were compared with the original image to verify if these objects corresponded to actual trees (TP) or not (FP).

### 4.1.2. Tree crown delineation accuracy

The delineation accuracy is somewhat more complex than the detection accuracy, because it involves the location, the crown radius, and the crown shape, which is not always circle-like. The possible error sources are:

**Table 3**

List of parameters used for processing the four WorldView images.

Image	$\theta$	$\phi$	$amb$	$L_M$	Radii	L range	D / $\lambda$
UFMG campus	45.2°	32.1°	10	40	6.5–17.5	19–55	4/1001
Belo Hor. Park	45.2°	32.1°	10	40	6.5–16.5	19–55	3/924
Sydney B.G.	44.0°	37.5°	10	55	6.5–24.5	27–110	4/1950
Morro Bay	47.0°	172.0°	10	110	4.5–5.5	27–120	8/760

$\theta$ : solar elevation;  $\phi$ : solar azimuth;  $amb$ : diffused light;  $L_M$ : maximum apparent radiance; Radii range in pixels; L: radiance; Density factor;  $\lambda$ : intensity (number of trees).

- The location can be slightly off even if the radius is right.
- The crown size can be larger or smaller than the actual tree crown radius.
- The actual tree crown can have a different shape (other than a circle) even if the total area is right.
- More than one of the above situations can occur simultaneously.

Considering the complexity of determining all these factors, we adopted a pixel-based accuracy assessment where the delineation success is based on the intersection between the tree crown pixels marked by the MPPTM program and the pixels belonging to the visually interpreted tree. The same three performance indicators were used to evaluate the delineation results.

**5. Results**

**5.1. Tree crown detection**

The parameters used for processing the images are presented in Table 3. While the parameters of the first two were taken from the meta-data files, the others were estimated. The ranges of the radii and the average radiance of the trees present in each image were estimated from a sample taken from the images. The diffused light values were recorded from the shaded areas.

Because it would be impractical to consider all variations of the shape, a unique spherical crown model ( $\alpha = 1.0$ ) was adopted for all four images since it fitted well as indicated by initial tests in a number of synthetic images (Supplementary Material Figs. S1 to S3 and Tables S1 to S4). Only a small proportion of the projected shadow was kept ( $\approx 5\%$ ) and the density parameter was visually estimated from the denser parts of the images.

The three termination parameters of the iteration process were:

1. The maximum number of iterations ( $Iter_{max}$ ): 10,000;
2. The maximum number of iterations allowed without finding any new trees ( $Iter_{tot}$ ): 100;
3. The number of iterations without finding trees after which the minimum similarity value is decreased by 0.01 ( $Iter_{sm}$ ): 25.

In all four cases, MPPTM stopped automatically before reaching  $Iter_{max}$  with the following number of iterations: UFMG Campus — 4141; Belo Horizonte park — 4308; Sydney Royal Botanic Garden — 8081; Morro Bay — 3277.

The search space was reduced using loosely defined thresholds to make sure that no values pertaining to trees were excluded. Since only panchromatic images were used at this stage, the reduction was based on observed low (water and shadow) and high (concrete, bare ground) radiance values.

The intensity of the MPP ( $\lambda$ ) that determines the total number of objects sought was purposely overestimated to make sure that all trees are potentially detected. The number of iterations might be greater than needed, but this would not affect the number of objects found.

Table 4 shows the total number of tree crowns found in each image and the grand total of 4520. Comparing the detected objects with the

**Table 4**

Results obtained by MPPTM for the detection of individual tree crowns in the four real images for both samples.

WV test image	Sample 1					Sample 2					F-score (%)
	TD	S <sub>1</sub>	TP	FN	Recall	S <sub>2</sub>	TP	FP	Prec.		
UFMG campus	933	100	93	7	0.93	100	72	28	0.72	0.81	
Belo Horizonte Park	877	100	99	1	0.99	100	70	30	0.70	0.82	
Sydney Bot. Garden	1950	100	85	15	0.85	100	92	8	0.92	0.88	
Morro Bay Plant.	760	100	93	7	0.93	100	97	3	0.97	0.95	
TOTAL	4520	400	370	30	0.93	400	331	69	0.83	0.87	

TD: total detected; TP: true positive; FP: false positive; FN: false negative; S<sub>1</sub>, S<sub>2</sub>: number of units in each sample; Prec.: precision.

400 validation trees, we found that 370 were correctly identified, leaving 30 false negatives for a recall level of 0.93. The largest recall level of 0.99 was obtained with the Belo Horizonte Park image while the Sydney image yielded the smallest with 0.85. The scores for precision are smaller for the first two and larger for the last two. The F-score was estimated between 0.81 and 0.95 for an average of 0.87.

**5.1.1. The UFMG campus image**

The UFMG campus image includes a wide diversity of tree species and crown sizes but also other objects such as buildings. With 93 trees out of 100 for the recall level, the detection rate is quite large. Conversely, many false positives were also detected that are only observable in the precision with a much smaller level of 0.72. These false positives are mostly the result of a shaded area next to a brighter one in the same orientation as the azimuth of the sun. The searching space reduction eliminated neither all the buildings nor the shaded areas, causing these erroneous detections (Fig. 4a).

**5.1.2. The Belo Horizonte Park image**

Almost all validation trees (recall) were detected (99/100) but many objects detected ended up being false positives, producing a precision level of 0.70, similar to that of the UFMG image. Again the presence of bright grass near darker regions (especially the canals) with a similar orientation as the sun azimuth caused most of the false positives (Fig. 4b).

**5.1.3. The Sydney Royal Botanic Garden image**


Because this is a well organized and well cared for traditional space in Sydney, most trees have a dense canopy and are relatively well spaced. These two facts tend to contribute to the large F-score of 0.88 ( $p = 0.85$  and  $r = 0.92$ ). Among the three complex images used (the first three) this one achieves a better balance between FP and FN (Fig. 4c).

**5.1.4. The Morro Bay image**

This fourth image, of an avocado plantation, brings a completely different context than that of the three previous ones. A single species is present but their crown sizes still vary (although much less than in the previous images), and many trees are very close to each other or even slightly overlapping. Most trees have a rounded shape, quite similar to the 3DGO model. This probably explains why this image has the largest F-score level of 0.95 with only 7 FN and 3 FP (Fig. 4d).

**5.2. Tree crown delineation**

To estimate the tree crown delineation accuracy, only TP trees were selected. The quality of the delineation (recall) ranges from about 0.5 to 0.7. When we consider the success in delineation (TP) together with the FP, we obtain the crown delineation precision ranging from  $\approx 0.5$  to



**Fig. 4.** Crown detection results for (a) the UFMG and (b) Belo Horizonte Park images. Left: detected objects overlaying the original image; Right: true positives (white circles) and false positives (black circles) from the random sample. Crown detection results for (c) the Sydney Bot Garden and (d) Morro Bay images. Left: detected objects overlaying the original image; Right: true positives (white circles) and false positives (black circles) from the random sample.




Fig. 4. (continued)

**Table 5**  
Results obtained by MPPTM for the tree crown delineation in the four WV-2 images.

WV test image	Precision	Recall	F-score
UFMG campus	0.67	0.57	0.62
Belo Hor. Park	0.48	0.70	0.57
Sydney R.B.G.	0.75	0.47	0.58
Morro Bay	0.79	0.67	0.72
<b>Mean</b>	<b>0.67</b>	<b>0.60</b>	<b>0.63</b>

0.8. The accuracy of the tree crown delineation was  $\approx 0.6$  to  $0.7$  (Table 5).

By comparing the four tree crown delineation results, the greater score was obtained with the Morro Bay image. Fig. 5 shows the details of the visually accurate delineation of the small trees achieved by MPPTM for the Morro Bay and Sydney images; note that the trees are well separated.

Unfortunately, very small trees often tend to increase FP pixels because part of their surrounding background is included in the tree crown. This explains the decrease of the precision obtained for the Belo Horizonte Park image ( $\approx 0.5$ ). Despite the promising success level for recall ( $\approx 0.7$ ), the FP occurrences cause prejudice to the delineation precision, which is reduced by more than 20%.

For large trees, when the image and the 3DGO model are very similar, the tree crown tend to be more precisely delineated. In some cases however, the MPPTM tends to lose portions of them (Fig. 6a), or sometimes divides them into two or more objects (Fig. 6b).

5.3. Discussion

MPPTM performed remarkably well in finding trees given the complexity of the images tested. With a single 3DGO model (with different radii), even palm trees and tree crowns that differ considerably from the model were recognized despite their singular shape and aspect. This was made possible by the slowly decreasing detection criteria

(similarity), a feature not found in other approaches.

In numerous occasions, small crown models fit onto larger trees because the central part of a larger tree can easily accommodate a smaller model since no background or shade are involved. This adaptability of smaller models over larger trees had already been noticed while testing with synthetic images. Broadbent et al. (2008) encountered similar problems using circular shapes for delineating tree crowns in a tropical forest environment. This leads in turn to an increase of FN and new strategies are being explored to avoid this problem. The opposite situation of a larger model on a smaller tree unlikely to happen because background and shaded areas around the tree crowns would produce a small similarity value.

The greater the radius range and the density of trees, the more likely the accuracy will be negatively affected. This implies that the process should be kept relatively flexible with a lower minimum similarity value ( $< 0.7$ ) and wider ranges of thresholds of radiance and standard deviation. The use of a vegetation mask helps to avoid problems caused by the existence of other objects projecting a shadow in the same direction as the trees. This is especially necessary towards the late iterations when the similarity threshold is smaller. The use of multi-spectral imagery would further help to solve this to a large extent.

The lambda ( $\lambda$ ) variable defines the number of trees to look for, but is mainly used as an indication since the three stopping mechanism will prevent the algorithm from searching without success. In that sense, it is better to overestimate lambda to make sure all the trees can be detected. Conversely, if it is too large, the algorithm will lose time trying to detect trees that are not there. And if it is larger than the capacity of the search space to hold so many trees, a mechanism prevents the algorithm from entering an endless loop.

More precisely delineation was obtained when the trees had well defined and rounded crown shapes and when they are well separated from each other. It is probable that the existence of a single species of trees (like in the Morro Bay image) also contributes to a better success rate.

A limitation of MPPTM could be defined as its inability to detect trees when they form continuous canopy or when tree crowns




Fig. 5. Detailed views of some good results for tree crown delineation of small trees in (a) the Sydney Royal Botanic Garden and (b) the Morro Bay image.






Fig. 6. Detailed views of some delineation problems: (a) portions of the trees are left out; (b) big trees are divided into several objects, but small trees are well delineated.

intertwine. This limitation agrees with other studies that have shown that optical remote sensing imagery alone do not provide the means to detect and delineate individual tree crowns with precision (Ardila, 2012; Zhou, 2012; Erickson, 2004).

It is unlikely that even the most sophisticated algorithm could detect all trees in a complex multi-layered forest. To evaluate the potential of MPPTM, some preliminary tests were performed to assess if a partial detection of tree crowns could be related to the forest structure like the presence of emergent trees. In a wooded savanna, the algorithm detected and delineated most prominent trees that stand out from the scrub (Fig. 7a). A similar result was obtained in a sclerophyllous forest image (Fig. 7b).

In a modified systematic (instead of random) version applied to different types of orchards (walnuts, oranges and mangoes), the approach correctly detected 5537 trees (true positive) out of 5806 (> 95%) (see Gomes and Maillard, 2016). This represents another example of the appropriateness of the similarity measure MPPTM uses.

The algorithm we proposed here is an object-specific approach and

its value should be considered as such. This can be viewed as being an advantage in cases where a single family of objects is sought. A generic object recognition or segmentation approaches (e.g., RG and VF) usually needs to take all categories of objects into consideration and hence incur unnecessary work. MPPTM uses the illumination parameters of the image to produce simplified object models that are sufficiently similar to the actual trees to enable their detection. These implementation choices make the approach partially deterministic and not purely empirical like many other approaches. Still it is sufficiently flexible (termination mechanisms) to enable the search parameters to be loosely defined without much impact on the outcome. Overlapping tree crowns were not considered in the current implementation but many slightly overlapping tree crowns were still detected. Allowing overlapping of trees in a future version could further improve results in tree stands or even in forested areas.

The theoretical framework adopted (MPP) is based on a random search process to locate the objects and to estimate their size. This might be perceived as a drawback from a strictly operational point of




Fig. 7. Examples of results obtained with MPPTM in wooded environments: (a) wooded savanna, (b) dry sclerophyllous forest.

view. However, in consideration of the number of trees in the TOF situations we tested (up to 2000 trees) relative to the number of pixels of any of those images ( $\approx 2\text{--}5$  million), the ratio is quite small and so is the probability of the same pixel being revisited. As the number of iterations grows, fewer and fewer trees are sought and the searching space shrinks with the number of trees that are kept. Processing time reached a little over two hours for the largest WorldView image (Sydney) with  $1979 \times 2667$  pixels. This processing time would be reduced by a large factor if the algorithm was optimized and implemented in a fully compilable language (e.g. C++).

## 6. Conclusion

In this article, we presented an original algorithm, MPPTM to simultaneously detect individual tree crowns and estimate their radius (delineation). The algorithm reached an average detection  $F$ -score of 0.87 in four different images from different environments. The delineation score considers the difference between the round object model and the actual shape of the tree and reached  $F$ -score levels between 0.57 to 0.72. The algorithm performed simultaneously these two tasks in different TOF environments and requires only four parameters when the sun elevation and azimuth are given in the image metadata, and six otherwise.

The implementation of a flexible slowly decreasing similarity measurement allowed MPPTM to find trees of different species, age, spacing and crown size in complex environments with multiple land cover classes. This implementation made it possible to use a single 3DGO model with varying radius.

The detection of individual trees in very high resolution images still represents a challenge for the remote sensing community. Given the importance of the ecological and economical services TOF environments provide, this research brings a contribution towards a more detailed inventories of these environments by providing valuable data on trees to facilitate their management and monitoring.

## Acknowledgments

This work was made possible through the financial support of the Brazilian Federal Government, through the National Institute of Colonization and Land Reform (INCRA). The sub-images of WV-2 satellite from Sydney and Morro Bay are free sample image data provided by DigitalGlobe Corp. (CO, USA).

## Appendix A. Supplementary data

Supplementary data to this article can be found online at <https://doi.org/10.1016/j.rse.2018.04.002>.

## References

- Almeida, A.L.B.S.S.L., 2006. O valor das árvores: árvores e floresta urbana de Lisboa. Ph.D. thesis. Instituto Superior de Agronomia, Lisboa.
- Andreu, M.G., Friedman, M.H., Landry, S.M., Northrop, R.J., 2008. City of Tampa Urban Ecological Analysis 2006–2007. Final Report to the City of Tampa. 24.
- Ardila, J.P., 2012. Object-based Methods for Mapping and Monitoring of Urban Trees of Multitemporal Image Analysis. Ph.D. thesis. University of Twente, Enschede.
- Asner, G.P., Palace, M., Keller, M., Pereira Jr., R., Silva, J.N., Zweede, J.C., 2002. Estimating canopy structure in an amazon forest from laser range finder and ikonos satellite observations. *Biotropica* 34, 483–492.
- Avery, T.E., Berlin, G.L., 1992. Fundamentals of Remote Sensing and Airphoto Interpretation. Prentice Hall.
- Beucher, S., 1992. The watershed transformation applied to image segmentation. In: 10th Pfefferkorn Conf. on Signal and Image Processing in Microscopy and Microanalysis. vol. 6. pp. 299–314.
- Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Int. J. Photogramm. Remote Sens.* 65, 2–16.
- Brandtberg, T., Warner, T., 2006. Computer Applications in Sustainable Forest Management: Including Perspectives on Collaboration and Integration. chapter. High-spatial-resolution Remote Sensing, 1st ed. Springer, Dordrecht, Netherlands, pp. 19–41.
- Broadbent, E.N., Asner, G.P., Peña-Claros, M., Palace, M., Soriano, M., 2008. Spatial partitioning of biomass and diversity in a lowland bolivian forest: linking field and remote sensing measurements. *For. Ecol. Manag.* 255, 2602–2616.
- Bunting, P., Lucas, R., 2006. The delineation of tree crowns in Australian mixed species forests using hyperspectral compact airborne spectrographic imager (casi) data. *Remote Sens. Environ.* 101, 230–248.
- Caves, R.G., Harley, P.J., Quegan, S., 1992. Matching map features to synthetic aperture radar (SAR) images using template matching. *IEEE Trans. Geosci. Remote Sens.* 30 (4), 680–685.
- Chiu, S.N., Stoyan, D., Kendall, W.S., Mecke, J., 2013. Stochastic Geometry and Its Applications. John Wiley & Sons.
- Chopping, M., 2011. Canapi: canopy analysis with panchromatic imagery. *Remote Sens. Lett.* 2, 21–29.
- Clark, D.B., Castro, C.S., Alvarado, L.D.A., Read, J.M., 2004. Quantifying mortality of tropical rain forest trees using high-spatial-resolution satellite data. *Ecol. Lett.* 7, 52–59.
- Culvenor, D.S., 2002. Tida: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. *Comput. Geosci.* 28, 33–44.
- De Foresta, H., Somarriba, E., Temu, A., Boulanger, D., Feuilly, H., Gauthier, M., 2013. Towards the Assessment of Trees Outside Forests. Food and Agriculture Organization of the United Nations, Rome.
- Descamps, S., Béchet, A., Descombes, X., Arnaud, A., Zerubia, J., 2011. An automatic counter for aerial images of aggregations of large birds. *Bird Stud.* 58, 302–308.
- Descombes, X., 2004. Méthodes stochastiques en analyse d'image: des champs de Markov aux processus ponctuels marqués. Ph.D. thesis. Université de Nice Sophia-Antipolis.
- Erickson, M., 2004. Segmentation and Classification of Individual Tree Crowns in High Spatial Resolution Aerial Images. Ph.D. thesis. Swedish University of Agricultural Sciences, Uppsala.
- Erikson, M., 2004. Species classification of individually segmented tree crowns in high-resolution aerial images using radiometric and morphologic image measures. *Remote Sens. Environ.* 91, 469–477.
- FAO, 2010. Towards the Assessment of Trees Outside Forests. Main Highlights: A FAO Thematic Report in the ARF Framework of the Global Forest Resources Assessment.
- Fassnacht, F.E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L.T., Straub, C., Ghosh, A., 2016. Review of studies on tree species classification from remotely sensed data. *Remote Sens. Environ.* 186, 64–87.
- Ge, W., Collins, R.T., 2009. Marked point processes for crowd counting. In: Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on, pp. 2913–2920.
- Gomes, M.F., Maillard, P., 2016. Environmental Applications of Remote Sensing. chapter. Detection of Tree Crowns in Very High Spatial Resolution Images. In: Tech, Rijeka, pp. 41–71.
- Gonzales, R.C., Woods, R.E., 2008. Digital Image Processing, 3rd ed. Pearson Prentice Hall, New York.
- Gonzalez, P., Asner, G.P., Battles, J.J., Lefsky, M.A., Waring, K.M., Palace, M., 2010. Forest carbon densities and uncertainties from lidar, quickbird, and field measurements in california. *Remote Sens. Environ.* 114, 1561–1575.
- Gougeon, F.A., Leckie, D.G., 2003. Forest Information Extraction from High Spatial Resolution Images Using an Individual Tree Crown Approach. Canadian Forest Service.
- Gougeon, F.A., Leckie, D.G., 2006. The individual tree crown approach applied to ikonos images of a coniferous plantation area. *Photogramm. Eng. Remote Sens.* 72, 1287–1297.
- Goutte, C., Gaussier, E., 2005. A probabilistic interpretation of precision, recall and f-score, with implication for evaluation. In: ECIR. vol. 5. pp. 345–359.
- Hay, G.J., Castilla, G., 2008. Object-based Image Analysis. Spatial Concepts for Knowledge-driven Remote Sensing Applications. chapter. Geographic Object-based Image Analysis (GEOBIA): A New Name for a new Discipline? Springer-Verlag, Berlin, pp. 75–89.
- Hung, C., Bryson, M., Sukkarieh, S., 2012. Multi-class predictive template for tree crown detection. *ISPRS J. Photogramm. Remote Sens.* 68, 170–183.
- Hurttt, G., Xiao, X., Keller, M., Palace, M., Asner, G.P., Braswell, R., Brondizio, E.S., Cardoso, M., Carvalho, C.J., Fearon, M.G., et al., 2003. Ikonos imagery for the large scale biosphere-atmosphere experiment in Amazonia (Iba). *Remote Sens. Environ.* 88, 111–127.
- Ke, Y., Quackenbush, L.J., 2011. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *Int. J. Remote Sens.* 32, 4725–4747.
- Lamar, W.R., McGraw, J.B., Warner, T.A., 2005. Multitemporal censusing of a population of eastern hemlock (*Tsuga canadensis* L.) from remotely sensed imagery using an automated segmentation and reconciliation procedure. *Remote Sens. Environ.* 94, 133–143.
- Larsen, M., Eriksson, M., Descombes, X., Perrin, G., Brandtberg, T., Gougeon, F., 2011. Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. *Int. J. Remote Sens.* 32 (20), 5827–5852.
- Larsen, M., Rudemo, M., 1998. Optimizing templates for finding trees in aerial photographs. *Pattern Recogn. Lett.* 19, 1153–1162.
- Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L., Shreenan, R., 2003. Combined high-density lidar and multispectral imagery for individual tree crown analysis. *Can. J. Remote Sens.* 29, 633–649.
- Leckie, D.G., Gougeon, F.A., et al., 1999. An assessment of both visual and automated tree counting and species identification with high spatial resolution multispectral imagery. In: International Forum on Automated Interpretation of High Resolution Digital Imagery for Forestry. Canadian Forest Service, Victoria, British Columbia, Canada, pp. 141–154.
- Lu, X., Guo, Q., Li, W., Flanagan, J., 2014. A bottom-up approach to segment individual

- deciduous trees using leaf-off lidar point cloud data. *ISPRS J. Photogramm. Remote Sens.* 94, 1–12. <http://www.sciencedirect.com/science/article/pii/S0924271614000860><http://dx.doi.org/10.1016/j.isprsjprs.2014.03.014>.
- van Lieshout, M.C., 2010. Handbook of Spatial Statistics. chapter. Spatial Point Process Theory. CRC Press, Boca Raton, pp. 263–283.
- Meneguzzo, D.M., Liknes, G.C., Nelson, M.D., 2013. Mapping trees outside forests using high-resolution aerial imagery: a comparison of pixel- and object-based classification approaches. *Environ. Monit. Assess.* 185, 6261–6275.
- Ortner, M., 2004. Processus ponctuels marqués pour l'extraction automatique de caractéristiques de bâtiments à partir de modèles numériques d'élévation. Ph.D. thesis. Université de Nice Sophia-Antipolis.
- Östeberg, J., Delshammar, T., Wiström, B., Nielsen, A.B., 2013. Grading of parameters for urban tree inventories by city officials, arborists, and academics using the Delphi method. *Environ. Manag.* 51, 694–708.
- Palace, M., Keller, M., Asner, G.P., Hagen, S., Braswell, B., 2008. Amazon forest structure from ikonos satellite data and the automated characterization of forest canopy properties. *Biotropica* 40, 141–150.
- Perrin, G., 2006. Etude du couvert forestier par processus ponctuels marqués. Ph.D. thesis. Ecole Centrale Paris.
- Pollock, R.J., 1994a. A model-based approach to automatically locating individual tree crowns in high-resolution images of forest canopies. In: Proceedings of the First International Airborne Remote Sensing Conference and Exhibition, Strasbourg, France, pp. 12–15.
- Pollock, R.J., 1994b. Model-based approach to automatically locating tree crowns in high spatial resolution images. vol. 2315. pp. 526–537. <http://dx.doi.org/10.1117/12.196753>.
- Pollock, R.J., 1996. The Automatic Recognition of Individual Trees in Aerial Images of Forests Based on a Synthetic Tree Crown Image Model. Ph.D. thesis. Concordia University.
- Pratt, W.K., 2007. Digital Image Processing: PIKS Scientific inside, 4th ed. John Wiley & Sons, Hoboken, New Jersey.
- Pu, R., Landry, S., 2012. A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. *Remote Sens. Environ.* 124, 516–533.
- Schipperijn, J., Pillmann, W., Tyrväinen, L., Mäkinen, K., O'Sullivan, R., 2005. Information for urban forest planning and management. In: Urban forests and trees. Springer-Verlag, Berlin, pp. 399–417.
- Shao, G., Reynolds, K.M., 2006. Computer Applications in Sustainable Forest Management: Including Perspectives on Collaboration and Integration. Springer.
- St-Onge, B., Cavayas, F., 1995. Estimating forest stand structure from high resolution imagery using the directional variogram. *Int. J. Remote Sens.* 16, 1999–2021.
- Tso, B., Mather, P., 2001. Classification Methods for Remotely Sensed Data. Taylor and Francis, London.
- Van Coillie, F., Devriendt, F., De Wulf, R., 2012. Directional local filtering assisting individual tree analysis in closed forest canopies using VHR optical and lidar data. In: 4th International conference on Geographic Object Based Image Analysis (GEOBIA 2012), pp. 350–354.
- Wang, L., Gong, P., Biging, G.S., 2004. Individual tree-crown delineation and treetop detection in high-spatial-resolution aerial imagery. *Photogramm. Eng. Remote Sens.* 70, 351–357.
- Whitted, T., 1979. An improved illumination model for shaded display. In: ACM SIGGRAPH Computer Graphics. vol. 13. pp. 14.
- Wulder, M., Niemann, K.O., Goodenough, D.G., 2000. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sens. Environ.* 73, 103–114.
- Zhang, Y., 2001. Texture-integrated classification of urban treed areas in high-resolution color-infrared imagery. *Photogramm. Eng. Remote Sens.* 67, 1359–1366.
- Zhou, J., 2012. Application de l'identification d'objets sur images à l'étude de canopées de peuplements forestiers tropicaux: cas des plantations d'Eucalyptus et des mangroves. Ph.D. thesis. Université Montpellier II-Sciences et Techniques du Languedoc.
- Zhou, J., Proisy, C., Couteron, P., Descombes, X., Zerubia, J., le Maire, G., Nouvellon, Y., 2011. Tree crown detection in high resolution optical images during the early growth stages of eucalyptus plantations in Brazil. In: Pattern Recognition (ACPR), 2011 First Asian Conference on, pp. 623–627.
- Zhou, J., Proisy, C., Descombes, X., Le Maire, G., Nouvellon, Y., Stape, J.-L., Viennois, G., Zerubia, J., Couteron, P., 2013. Mapping local density of young eucalyptus plantations by individual tree detection in high spatial resolution satellite images. *For. Ecol. Manag.* 301, 129–141.

---

# Detection of Tree Crowns in Very High Spatial Resolution Images

---

Marilia Ferreira Gomes and Philippe Maillard

Additional information is available at the end of the chapter

<http://dx.doi.org/10.5772/62122>

---

## Abstract

The requirements for advanced knowledge on forest resources have led researchers to develop efficient methods to provide detailed information about trees. Since 1999, orbital remote sensing has been providing very high resolution (VHR) image data. The new generation of satellite allows individual tree crowns to be visually identifiable. The increase in spatial resolution has also had a profound effect in image processing techniques and has motivated the development of new object-based procedures to extract information. Tree crown detection has become a major area of research in image analysis considering the complex nature of trees in an uncontrolled environment. This chapter is subdivided into two parts. Part I offers an overview of the state of the art in computer detection of individual tree crowns in VHR images. Part II presents a new hybrid approach developed by the authors that integrates geometrical-optical modeling (GOM), marked point processes (MPP), and template matching (TM) to individually detect tree crowns in VHR images. The method is presented for two different applications: isolated tree detection in an urban environment and automatic tree counting in orchards with an average performance rate of 82% for tree detection and above 90% for tree counting in orchards.

**Keywords:** Tree crown detection, VHR image, Template matching, Marked point process, Valley-following, Watershed segmentation, Local maxima, Region growing

---

## 1. Introduction

Inventories on forest communities are performed with the objective of providing support to the management and conservation activities in rural or urban forests or even in tree plantations. The traditional method of obtaining information on forest communities is to use systematic or random sampling or by sampling stands, so that the final parameters for the population are obtained on the basis of statistical extrapolation [1, 2]. Usually, the following parameters are

---

determined for each tree included in the sampling: location, diameter at breast height (DBH), basal area (BA), height, identification of the species, crown size, and crown closure. Based on these measurements, other parameters such as volume of wood and biomass can be derived for the community stand. This renders the field survey techniques for forest inventories expensive, time consuming, and unsuited for large areas.

Remote sensing with high spatial resolution is a cost-effective and reliable way to obtain information about trees. It may be the only practical manner to assure sustainable management of forests with the necessary information, such as biochemical and biophysical data on the vegetation in a synoptic and repetitive manner for large areas and over long periods of time [3]. The tree crown is the basis of the data required for the inventory, for it allows to determine not only its size but also its position, crown closure, and, in some cases, the species. It also allows the derivation of parameters such as the density of the population, the health condition of the trees, the volume, the biomass, and the carbon sequestration rates [3–6]. This information is crucial to a series of applications such as the inventory and management of forested areas as well as in parks and urban forests. It can also be used for counting and monitoring trees in orchards or under power lines to prevent damage and accidents.

The study of individual trees with remote sensing started with the use of aerial photography with very high spatial resolution (scale greater than 1:10.000), driven mainly by the use of stereoscopy techniques. The task was performed by photointerpreters trained to recognize individual tree species, extract a series of measurements, or evaluate different types of damage [2]. The use of orbital optical remote sensing data for forest studies began in the 1970s, with the development of techniques to separate forested from non-forested areas [7]. The spatial resolution of these satellite images was the main limiting factor for more detailed studies about the forests, and as a result, the studies remained focused on the disturbances affecting forests (such as land clearing, burning, diseases, and pest) or to estimate some biophysical parameters of the vegetation [3,8]. It was only toward the end of the 1990s that orbital remote sensing began to provide very high resolution (VHR) data with a spatial resolution under 1 m, allowing the study of individual trees. Launched in 1999, Ikonos was the first of what is now a series of VHR satellites (Table 1), consolidating the use of orbital data for the study of individual trees. However, the increase in spatial resolution was not always accompanied by an increase in spectral resolution for VHR data which is often restricted to a single panchromatic band.

The increase in spatial resolution changed the focus of many remote sensing studies, which started to analyze not only classes of objects but also each object individually [9]. Branches and irregularities within the crowns became visible, and as a result, the spectral response of a tree is influenced by variations in the shape of the crown (differential illumination) and background effects. This causes an increase in the intra-class variance and often results in a reduced accuracy when using conventional pixel-based classification [10]. This had a significant effect on the image processing techniques for forest studies and generated the development of new forms of information extraction.

Within the study of individual objects, the automatic detection and delineation of tree crowns using remote sensing VHR imagery have attracted much attention from researchers in forestry and computer vision [4,7]. Researchers have developed several automatic and semiautomatic methods for extracting individual trees and their characteristics using digital aerial photos of

various types and VHR satellite images [11]. The applications range from the identification of tree crowns to their delineation and classification and are often based on image segmentation algorithms and other advanced image processing and analysis techniques [9,12]. Most of these algorithms were specifically developed for the detection and delineation of trees in temperate forests based on the assumption that the trees are cone shaped and round (mostly coniferous) in the images, with the apex of the tree having the highest reflectance of the crown area [4].

Satellite	Launch Year	Px resolution* (m)	Mx resolution* (m)	Multispectral bands
<b>Ikonos II</b>	1999	0.82	3.2	Blue, Green, Red, Near IR (4)
<b>QuickBird</b>	2001	0.65	2.62	Blue, Green, Red, Near IR (4)
<b>WorldView-1</b>	2007	0.46	-	-
<b>Geoeye-1</b>	2008	0.46	1.84	Blue, Green, Red, Near IR (4)
<b>WorldView-2</b>	2009	0.46	1.85	Coastal, Blue, Green, Yellow, Red, Red Edge, Near IR, Near IR2 (8)
<b>Pleiades 1A</b>	2011	0.5	2.0	Blue, Green, Red, Near IR (4)
<b>Pleiades 1B</b>	2012	0.5	2.0	Blue, Green, Red, Near IR (4)
<b>Kompsat-3</b>	2012	0.7	2.8	Blue, Green, Red, Near IR (4)
<b>SkySat-1</b>	2013	0.9	2.0	Blue, Green, Red, Near IR (4)
<b>WorldView-3</b>	2014	0.31	1.24	Coastal, Blue, Green, Yellow, Red, Red Edge, Near IR, Near IR2 (8)
<b>SkySat-2</b>	2014	0.9	2.0	Blue, Green, Red, Near IR (4)
<b>Kompsat-3A</b>	2015	0.55	2.2	Blue, Green, Red, Near IR (4)
<b>WorldView-4</b>	2016	0.34	1.36	Not available at time of printing

\* Panchromatic (Px) and Multispectral (Mx) resolution at nadir.

**Table 1.** Very High Resolution satellites (1999-2006), with their spatial resolutions and spectral bands. Note that there is not any available satellite with VHR in multispectral bands.

The analysis of individual trees based on remote sensing images is a complex problem. Images of trees with varied crown size increase the difficulty of the analysis. What is detected as a single object may in fact represent a separate branch or even a group of trees [10]. Other sources of error are caused by the proximity between neighboring trees, trees located under other trees, trees in the shade, or trees that have a low spectral contrast with the background [13]. Consequently, high-level complex algorithms are necessary to exploit this contextual information [1].

This chapter provides an overview of the state of the art in individual tree crown detection based on optical VHR remote sensing data. An original method developed by the authors is also presented as an alternative approach to the problem of tree crown detection. In Part I, we present the main algorithms developed for the detection of individual trees, be it for tree

identification or delineation. The principle of each approach is presented as well as its potential and limitations. Part II is dedicated to outlining the original MPP–TM approach, a hybrid method that combined two methods used in pattern recognition: marked point process and template matching. The results are shown for tree detection and delineation in an urban environment and for tree counting in orchards.

## 2. Part I – Review of tree crown detection methods

We present six of the main algorithms used in individual tree detection in high spatial resolution images. The algorithms are summarily described individually, but it should be noted that many approaches use hybrid methods for the detection and delineation of tree crowns. For instance, some authors might use one algorithm for detecting the trees and another to delineate them; some may even use one approach as a first approximation and another to fine-tune the results.

### 2.1. Local maxima filtering


Local maxima (LM) filtering is a technique used for identifying tree crowns in high spatial resolution imagery which is based on the recognition of the points with the greatest brightness within a search window that scans the entire image [4,14]. The search window, with a fixed size, defines which pixel has the greatest reflectance compared to all the other pixels inside the window. The pixels with the highest digital number are identified as possible tree locations. This method is adequate for trees which have the greatest reflectance at their top, surrounded by lower intensity pixels, and due to its concept, it is widely used for detecting conifers.

When the kernel window passes over the image, it does not take into account the presence of trees with different crown sizes, and the success of the LM tree recognition depends on the careful selection of the size of the search window. If it is too small, errors of commission occur by selecting nonexistent trees or multiple radiance peaks for an individual tree crown; if it is too big, the algorithm is likely to miss some trees (omission errors) [13].

The identification of trees by LM is affected by false bright pixels, which are not part of the brightest part of the crown. An effective method for dealing with the problem is to apply a Gaussian filter to the image. This allows the low-pass filter function to grant more weight to the crown center pixels (surrounded by much lower values) compared to those located toward the crown edge which might belong to other bright objects or noise. Applying a Gaussian filter directly affects the number of local maxima identified and causes the smoothing off of the brightness values on the tree crown edges [15].

In order to minimize the problem of the window size with LM, reference [13] used windows of varying sizes based on the assessment of the spatial structure of the image obtained by analyzing the local semi-variogram with different pixel lags and different window sizes. This results in a personalized window for each pixel, leading to greater accuracy when compared to using a single fixed window size. Reference [16] used LM to identify the centroid of

eucalyptus trees in Australia. The search for the trees is carried out based on the maxima in four linear kernels pertaining to the four main directions (0°, 45°, 90°, and 135°) of the image and by summing the individual maxima found in each pass (Figure 1).



**Figure 1.** Examples of the surface produced by applying a LM kernel operator: (a) original image, (b) the local maxima appearing in the third dimension are associated with the presence of trees, (c) application of local maxima filter in four linear cumulative kernels (0°, 45°, 90°, and 135°).

## 2.2. Template matching

Template matching (TM) is a technique used for object recognition widely cited in the specialized literature which uses quantitative descriptors, such as length, area, and texture to describe recurring patterns in an image [17,18]. Based on a synthetic model or a sample extracted from the image, the correlation coefficient between the model and the image is calculated in order to determine the strength of the match between the two matrices. The object is assumed to be located where the measurement of the match reaches a maximum [4].

For tree crown detection, the study of reference [19] was the first to propose an elliptical 3D model for tree crowns based on an ellipsoid of generalized revolution (Equation 1).


$$\frac{z^n}{a^n} = \frac{(x^2 + y^2)^{n/2}}{b^n} = 1 \quad (1)$$

where  $z$  is the vertical axis of the center of the tree crown in its origin,  $a$  is half the height of the ellipsoid,  $b$  is half the radius, and  $n$  is the parameter of the shape of the tree crown. Subsequently, the model is illuminated using the acquisition parameters of the image (sun elevation and azimuth) and the characteristics of crown absorption and reflection of light in the chosen spectral band.



Because it is based on a physical model (rather than a complex mathematical concept), TM is considered a user-friendly method. Its limitation is mainly due to the need to use a library of models if many types of trees are present in the image, which may involve a complex phase for generating the models. Figure 2 shows examples of synthetic tree models and an application in an orchard.

References [20 and 21] used this technique to identify tree crowns in aerial images. Other researchers used this technique to recognize individual tree crowns, using templates made from small sub-images of the actual scene to identify the trees [22, 23]. Reference [24] proposed an improved version by generating separate models for trees and their shade in VHR images of unmanned aerial vehicles (UAV). The authors explored the relation between the tree and shade models separately and then joined them to generate a more powerful object detector.




**Figure 2.** Left: examples of synthetic tree models to different tree crown shape. Right: identification of trees in an apple orchard showing the model used at the upper right corner.

### 2.3. Valley-following

Valley-following (VF) is a crown delineation method which identifies the shaded areas between the trees. This methodology was initially described in reference [25] and makes an analogy with topographic data, where the shades of gray of the pixels represent local lows in the third dimension. In this analogy, the bright tree crowns would be the hills and the darker zones around the trees the valleys (Figure 3). This darker zone is the one which typically helps human interpreters to separate one tree crown from the other. In this approach the shaded areas are eliminated, making it possible to separate the trees in the image. This was not sufficient to separate all of the trees, so the authors developed an approach based on a series of rules (e.g., no discontinuity, checking directions, context, gap filling, etc.) to accurately describe the boundaries of each tree, one at a time [26].

This approach performed well in images with a combination of low solar elevation angle and conical trees. Conversely, the approach failed to produce good results when the canopy was composed of trees of very different sizes, or when the tree crowns were very large and have internal shadows. The latter case resulted in subdividing the individual tree into two or more parts. Smaller trees, in contrast, tended to be grouped together. Reference [27] found that this



**Figure 3.** Results of the valley-following applied on a forest image in Canada (source: Gougeon and Leckie, 2003; reproduced with permission from Natural Resources Canada).

approach causes many false positives (FPs) in open areas (clearings). As a solution, they suggested the exclusion of these areas by retaining only the high-value pixels in the normalized difference vegetation index (NDVI).

#### 2.4. Watershed

Like VF, the watershed segmentation (WS) is a technique related to thresholding that uses the gray levels in the images as if it were a topographic surface [28]. It is used not only for the delineation of individual tree crowns but also for generic segmentation of images. The watershed concept is based on a 3D image representation, with the third dimension being provided by the intensity of gray. The main objective of the watershed algorithm is to find the “drainage” divide lines. The “relief” in the image is inverted (high gray values become valleys) and progressively filled with a virtual liquid, and when the liquid is almost overflowing from one basin to another, a virtual dam is built, to create the watershed. These lines are considered the limits of each segment. The simplest approach to the construction of the dam is the use of morphological dilation of the minima, without merging the regions [17].

The images are usually preprocessed before the WS is applied. In fact, this segmentation is frequently applied to the gradient of an image, and not to the image itself. This is due to the relative homogeneity of the gray values of objects that do not provide sufficient contrast for


an effective segmentation. In this formulation, the regional minimum value of the catchment basins usually correlates well with the lower gradient values that match the contours of the objects of interest [17,28]. The direct application of the WS algorithm generally leads to over-segmentation due to noise or other local irregularities of the gradient (Figure 4a). One of the approaches used to limit the number of regions is to use markers. The selection of markers can be based on simple procedures, intensity and connectivity between pixels, or even complex descriptors, such as size, format, location, relative distances, texture, and others. The use of markers provides prior knowledge to support the segmentation process [17].

The approaches that use WS for the delineation of the tree crowns normally use markers representing the center of the tree crown, to assist the segmentation process. For instance, reference [29] used WS to detect and delineate tree crowns in a VHR forest image in Canada but divided the approach into two phases, namely using LM to detect the crown and applying WS for the delineation. The LM image with the detected crowns was produced by using a Laplacian of Gaussian edge detection operator. The tree crowns were modeled based on their geometry and radiometry, resulting in an image of markers. This image then served to guide the WS in delineating the crowns. Reference [30] developed a bitemporal procedure for the automatic segmentation and reconciliation of groups of pixels (called blobs) within the forest using WS. By using two dates, they were able to increase the probability of properly defining the tree contours. Many problems were encountered in the segmentation process of the individual trees. For instance, trees with spread branches were sometimes split into two or more segments or contrarily by including several crowns in the same segment when trees were not sufficiently separated.

## 2.5. Region growing

Region growing (RG) is another segmentation technique that groups pixels or groups of pixels based on predefined growth criteria in an attempt to separate and recognize objects in the image [4]. Like WS, RG is used as a generic segmentation method and can be adapted for the delineation of individual tree crowns (Figure 4b). Starting with some seed pixels (which can be random if no other information is provided), the neighboring pixels are examined one by one and added to the growth region if their predefined properties are similar to those of the seeds (such as specific intervals of intensity or color) [17]. When no more pixels can be added or some predefined limit is reached (e.g., number of pixels), these pixels are labeled as belonging to the specific region of the seed pixel. Additional criteria can increase the power of an RG algorithm by introducing a higher concept like size and similarity between candidate pixels and the pixels selected or even the format of the region [17,31].

Reference [16] used RG integrated with LM to identify and delineate tree crowns in Australia. The LM method served to find the center of potential trees, which were then used as seeds for the RG. Reference [6] tested two different types of segmentation by RG, one by Brownian motion and the other by random walk, to detect conifers in a boreal forest. The methods were capable of detecting about 80% of the illuminated portion of the crowns, with a better performance found in larger crowns (Figure 5).




**Figure 4.** Comparison between two segmentation algorithms: (a) watershed and (b) region growing on a WorldView-2 image (panchromatic band with a 50 cm resolution). The WS was applied to the gradient image without using markers and resulted in the over-segmentation of the tree crowns. In (b), the RG segmentation was performed within an object-oriented classification (GEOBIA) approach, where the correct delineation of the tree crowns is noteworthy (source: Gomes and Maillard, 2013).

## 2.6. Marked point processes

The marked point process refers to a probabilistic method which has been used in recent years for the recognition of objects in high spatial resolution imagery [5,11,32–35]. In an MPP, sets of random points in a given space  $(x, y)$  are provided with a mark which is complete and separable, allowing the definition of a topology (defined by the mark) and the attribution of a label. An image is considered a random model where the gray tones are the realization of a random point process [34]. This random configuration of gray levels in the images is then modeled based on geometric figures (ellipses, circles, rectangles, and lines), respecting certain geometric (nature of the objects) and radiometric constraints (type of image).


The laws of density and probability distinguish various types of point processes, which can be Poisson, Strauss, Markov, or Gibbs, among others. The Markov or Gibbs point processes have been used for the recognition of tree crowns by a number of authors [5,32,33]. These



**Figure 5.** Example of RG segmentation to delineate tree crowns in a boreal forest. (a) The original image (with a spatial resolution of 3 cm), (b) with the results using Brownian motion, (c) and random walk (Source: Erikson, 2004).

processes are defined by a density function using a form of energy expressed as a sum of the a priori energy and the local energy. The process seeks to minimize the global energy of the model, by iterating it with some optimization scheme (Markov random fields, algorithm of multiple births and deaths, and Monte Carlo-Monte Carlo simulations).

Reference [5] proposed two different models to serve as marks in an MPP, one in 2D for detection of trees in densely forested zones (Figure 6) and the other in 3D for scattered or isolated zones, based on aerial photos of high spatial resolution in the infrared band. The MPP was integrated with a reversible jump Markov Chain Monte Carlo in a simulated annealing



**Figure 6.** Example of the application of MPP for tree crown recognition on a poplar plantation. The original image is shown at the top and the results at the bottom (Source: Perrin, 2006).

method. Reference [32] used an MPP to automatically detect the tree crowns in high spatial resolution images, based on the modeling of the crowns as 2D circles on high-resolution spatial images. The method was successfully tested on mangrove forests and eucalyptus plantations.

## 2.7. Discussion

In the previous section, we have presented some of the most common algorithms used in the detection of individual trees, be it for their identification, delineation, or both. Table 2 presents a summary of these principles through their main characteristics and limitations.

Trees may differ in shape, size, spectral properties, height, foliage type, and density, and their spatial context varies with illumination, ground type, and inclination. They can also be surrounded by many other objects, especially in an urban setting. As such, the task is not trivial and can become highly complex depending on the number of parameters involved. Conversely, in planted forest and orchards where trees have the same age and species, tree crown extraction can take advantage of their relative uniformity.

Algorithm	Usage	Principle	Researches	Characteristics / Limitations
<b>Local Maxima (LM)</b>	Identification of tree crown	Identification of brightest points locally as corresponding to the apex of a treetop within a search window.	Wulder <i>et al.</i> (2000) Culvenor (2002) Pouliot (2002), Wang <i>et al.</i> (2004)	Appropriate for conifers, with a conical shape and high reflectance point at the top of the tree. Simple method to use. Results are affected by the spatial distribution of trees, variation of tree crowns size, search window size (increased omission errors in larger windows and commission errors in smaller windows).
<b>Template Matching (TM)</b>	Pattern recognition	Quantitative descriptors used to describe patterns. Calculate the correlation between the image and the model. Model may be a sample extracted from the image or not.	Pollock (1996) Larsen (1997) Larsen and Rudemo (1998) Quackenbush <i>et al.</i> (2000) Erikson (2004) Hung <i>et al.</i> (2012)	Enables analysis of the tree crown from its spectral, textural and structural characteristics. Allows neighborhood analysis of the tree crown by considering its shadow. User-friendly method. Needs a template library, making it unpractical in complex forests. Recognition errors increase with irregularity of the tree crowns. Easier to detect larger trees than smaller ones. Performance reduced in very dense environments.
<b>(VF)</b>	Delineation of tree crown	Derives from an analogy with a topographical surface, programmed to identify the shaded portion between the tree crowns (valleys).	Gougeon (1995, 1999) Leckie and Gougeon (1998) Gougeon and Leckie (2003) Erickson (2004) Gougeon and Leckie (2006)	Appropriate for trees with conical shape that create shadow areas between individuals. Most successful to delineate populations of the same age without intertwined tree crowns. Best performance for images in mid-low solar elevation angle. Performance reduced when trees are asymmetrical, of from different species, with different tree crown sizes or when shadows of trees protrude over each other. Tendency to group smaller trees together and split larger trees into multiple segments.

Algorithm	Usage	Principle	Researches	Characteristics / Limitations
<b>Watershed (WS)</b>	Delineation of tree crown	Performed from the image gradient. Image is seen as an inverted topographic surface flooded to determine watershed divides. Commonly uses markers to limit the number of segments.	Wang <i>et al.</i> (2004) Lamar <i>et al.</i> (2005)	Performs best when applied after selection of markers to control segmentation process. More suitable for conifers, which allow preselection of treetops by using another approach (usually LM). Over-segmentation occurs when applied directly to the image or without the use of markers. Can separate tree crowns in different segments when the branches are too spread, or may include several trees in the same segment when there is no spatial separation between them.
<b>Region Growing (RG)</b>	Delineation of tree crown	Groups pixels or sub-regions based on predefined criteria for the growth of region in order to separate and recognize objects in the image.	Culvenor (2002) Pouliot <i>et al.</i> (2002) Erikson (2004) Bunting and Lucas (2006) Pu and Landry (2012)	More complex shapes of trees are better delineated. Method more complex as it requires different rules for different environments. Tends to create more than one segment when the tree has branches with dark portions, and tends to group different trees if they are very similar.
<b>Marked Point Processes (MPP)</b>	Pattern recognition	Stochastic process in which unordered points in a space are provided with marks. Marks are modeled from geometric and radiometric characteristics of objects.	Perrin (2006) Zhou (2012) Larsen <i>et al.</i> (2012)	Performs best with plantations of trees of same species and age and in images of isolated trees. It is less effective to detect trees in more complex environments.

**Table 2.** Summary of Local Maxima, Template Matching, Valley Following, Watershed, Region Growing and Marked Point Processes algorithms used to individual tree crown detection. The principles, main researches and main characteristics and limitations are presented.

Reference [11] compared six different algorithms (valley-following, region growing, template matching, scale-space theory, marked point processes, and Markov random fields) in six different aerial images, ranging from a homogeneous plantation and an area with isolated tree crowns to an extremely dense deciduous forest type. The authors found that none of the algorithms can by itself reach a high rate of success in all of the tested images and concluded that there is no single optimum algorithm for all types of images and forests. They also emphasized that for complex types of forests, monoscopic images are insufficient for a consistent detection of tree crowns, even for human interpreters.



### 3. Part II – A hybrid approach integrating marked point process and template matching

As shown in our brief review, many methods have been developed for trees in temperate forest environments. In an exploratory research [23], three algorithms in urban tropical environments were tested: region growing, watershed, and template matching. Better results were generally obtained by combining region-growing segmentation and geographic object-based image analysis (GEOBIA) for classification. Although highly effective, the approach requires much parameter setting and experience and is not especially dedicated to the problem of tree crown detection.

Studies that use marked point processes have triggered our attention and made us consider that they could benefit from using marks modeled from 3D objects in a different approach than from that developed by reference [5]. We propose to use a geometrical-optical tree model in a manner resembling that of template matching that uses some form of correlation between image and model to identify candidate pixels. An MPP taking advantage of a geometrical optical 3D model and measurements of similarity to seek tree crowns could represent a significant improvement to using simpler marks. Considering such a hypothesis, we developed an algorithm for tree crown detection that combines elements from MPP, TM, and tree crown geometrical-optical modeling for the automatic detection and (simplified) delineation of trees in VHR satellite imagery. We have named our algorithm MPP–TM.

In our approach, the TM did not scan the whole image like it was initially conceived but rather uses an MPP approach to select random locations within the image. Additionally, the 3D marks receive a random diameter between a predetermined range depending on the type of environment. The geometrical-optical model includes both the sunlit and shaded areas of the crown and a portion of the projected shadow to allow a better match between model and image. Some statistical and spectral parameters were also included in the model-matching phase.

MPP-based algorithm for pattern recognition usually alternates between phases of birth and death during which the objects are created (placed) and destroyed when they do not comply with the matching rules. This is also a characteristic of MPP–TM, but we have somewhat deviated from the original concept where the destruction phase also incorporated a random process.

The following subsections are devoted to describe the construction process of the 3D geometrical-optical model and the functioning of the algorithm.

#### 3.1. Description of MPP–TM approach

##### 3.1.1. A geometrical-optical 3D tree crown model

The parameters that determine the radiance pattern of a tree crown are direct and indirect radiation, shape of tree, branch pattern, leaf reflectance, multiple reflectances within the canopy, etc. [36]. In creating a valid 3D geometrical-optical model, we have chosen a simplified version in which the crown is represented by a dome of varying skewness, a Lambertian


reflectance model with ambient light, and a projected shadow on the ground (or on another tree). Equations 2 and 3 give the formulation of our model in which each pixel is treated as a singular surface.

$$\cos(\theta_i) = \left\{ \cos(\theta_s)\cos(\theta_n) + \sin(\theta_s)\sin(\theta_n)\cos(\varphi_s - \varphi_n) \right\} \quad (2)$$

where  $\theta_i$  is the local solar incidence angle,  $\theta_s$  is the solar zenith angle,  $\theta_n$  is the slope of the object surface,  $\varphi_s$  is the solar azimuth and  $\varphi_n$  is the aspect of the object surface.

$$L = L_M \left( \frac{\cos(\theta_s)}{\cos(\theta_i)} \right) + \text{amb} \quad (3)$$

where  $L_M$  is the maximum reflectance of the model, "amb" represents the diffuse ambient lighting. The geometrical-optical model is adjusted according to the specific illumination parameters of the image, and the size of the trees present on the scene. Figure 7 shows two examples of tree models with similar reflectance but different solar elevations.




**Figure 7.** Illustration of the geometrical-optical model of tree crown as seen in the same sun azimuth (32°) but in two different solar elevation angles: (left) 20° and (right) 45°

A parameter of projected shadow clipping has also been added to account for the fact that it was not beneficial to use the whole shadow in situations where it was projected onto another tree and not on the ground. The height of the tree also affects the size of the shadow so that it did not appear wise to set the height to a fixed value. To illustrate this, Figure 8 shows a comparison between the tree model and an actual tree from the image both with whole and clipped shadows.

### 3.1.2. Algorithm description

According to reference [32], using MPP to extract objects consists in searching for the “best” possible object configuration in a scene, the one that will respect a certain number of properties



**Figure 8.** Comparison between an isolated tree from the (a) WorldView-2 image and (b) the geometrical-optical 3D model. A clipping factor of about 80% was applied to the same images in (c) and (d) to enable the use of only a portion of the shadow in cases where that shadow is not projected on the ground but on another object.

both of the objects being sought and the radiometric properties of the image. In our algorithm, the “best” configuration be it geometric or radiometric is given by the model.

The process consists in alternating phases of birth and death. The MPP starts with a birth phase during which tree crowns represented by circles of varying size (a randomized interval) are inserted on a matrix of equal size to the image being processed. Tree crowns are only inserted where no other crowns are present. Once all the circles have been inserted (determined by a density parameter  $N_c$ ), a similarity ( $S_m$ ) value between the image and a version of the model fitted on each circle is computed and stored in a list along with the parameters of the model. A routine then sorts the list by decreasing values of  $S_m$ . During the death phase, the circles that do not comply with the acceptance restrictions ( $S_m$  and minimum and maximum standard deviation threshold) are successively deleted from the matrix and the list. At the end of each death phase, the overall parameters of the pixel distribution of the remaining crowns are updated. The crowns that have been found are definitively kept but are re-thrown in the bundle of crowns of the next iterations. If after an iteration 10 crowns are kept out of 100, then the next iteration will randomly place 90 more crowns, and the new set of 100 crowns are evaluated and sorted for the next iteration. All tree crowns are considered “found” when one of the three possibilities is encountered: 1) the number of trees found is equal to the number given by the

density parameter, 2) one of the interruption criteria has been attained, or 3) the maximum number of iteration has been reached.

The  $S_m$  value is computed as the subtraction of two parameters: cross-correlation and the normalized absolute difference as defined by the following relation (Equation 4):

$$S_m = \gamma - \alpha ND \quad (4)$$

where  $\gamma$  is the cross-correlation between image and model, ND is the normalized sum of absolute differences between them, and  $\alpha$  is a constant weight factor (normally approx. 0.5). The cross-correlation and absolute difference are calculated as follows (Equations 5 and 6).

$$\gamma(x, y) = \frac{\sum_i \sum_j [w_{(i,j)} - \bar{w}] \sum_i \sum_j [f_{(i,j)} - \bar{f}]}{\left\{ \sum_i \sum_j [w_{(i,j)} - \bar{w}]^2 \sum_i \sum_j [f_{(i,j)} - \bar{f}]^2 \right\}^{1/2}} \quad (5)$$

In Equation 5, the cross-correlation is calculated between the model matrix ( $w_{(i,j)}$ ) and the portion of the image that corresponds to the circle of the same radius ( $f_{(i,j)}$ ). In other words, two matrices of same dimensions are always compared.  $\bar{w}$  and  $\bar{f}$  are their respective means. The values of gamma range between -1 and 1. The same logic is used in Equation 6 which computes a normalized difference value between the same two matrices.

$$ND = \frac{\sum w - \sum f}{\sum w + \sum f} \quad (6)$$

In the death phase, tree crowns are kept if their similarity is larger or equal to a pre-set threshold. Because we found that such a threshold represented a weak element in our algorithm, we implemented a strategy by which it needs not be predetermined with a fixed value but rather adjusts itself as the number of iterations grows. The threshold is set very high at the beginning but then starts to decay when a certain number of iterations do not find any "new" tree crown (typically 100 iterations). Additionally, if more than a certain amount of iterations (say 1000) still does not add any new tree crown, then the process is stopped. Ultimately, it will be stopped if the maximum number of iterations is reached. A flowchart of our algorithm is presented in Figure 9 and schematically described in Table 3.

Figure 10a shows the state of the crown matrix after a single birth phase with 163 circles of random radius (between 3 and 15 m) and randomly located within the image matrix. After the death phase, using a similarity threshold of 0.98, only one tree crown was kept (Figure 10b).

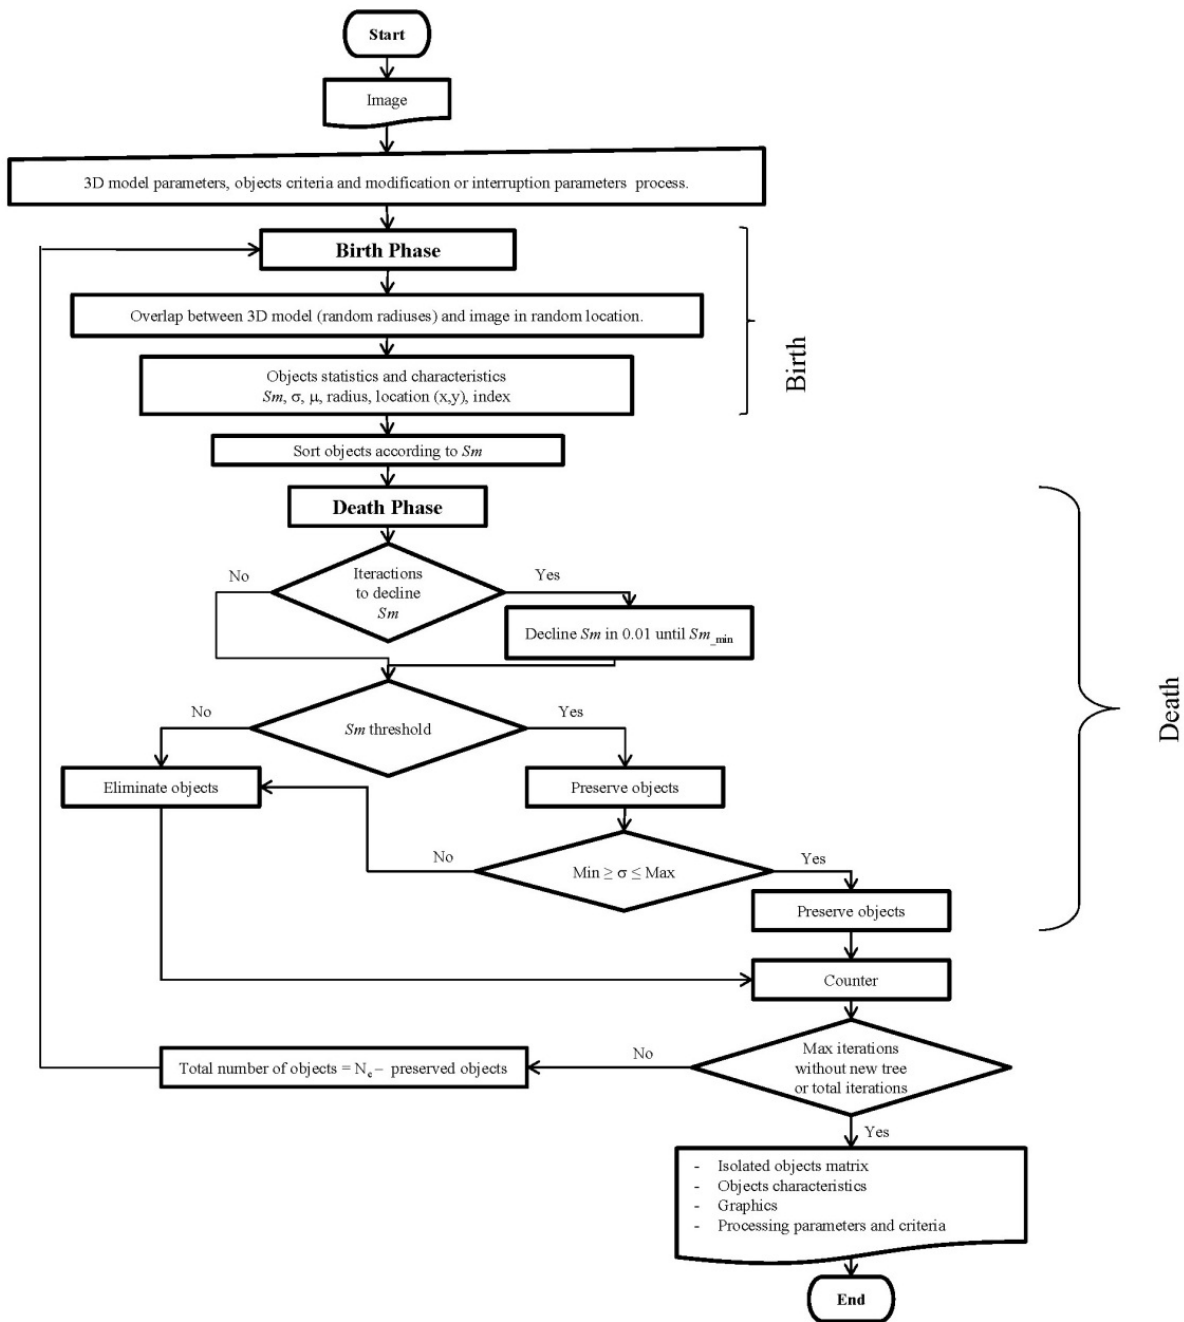


Figure 9. Flowchart of the MPP-TM algorithm.

### 3.1.3. A modified approach for orchards


Because trees in orchards are often individually distinguishable and have similar shape and size, they are perfect candidates for TM with a 3D geometrical-optical model. By using a GOM, the effects of varying illumination (sun elevation and azimuth) become an advantage rather than an obstacle especially when the background is homogeneous. In terms of data, VHR image data such as a large proportion of Google Earth images have sufficient resolution for identi-

<b>1. Task:</b> Tree crown detection in Very High Resolution images.
<b>2. Set parameters:</b>
<ul style="list-style-type: none"> <li>a. <b>3D model:</b> maximum reflectance, ambient light, sun elevation, sun azimuth, tree shape, clip factor.</li> <li>b. <b>Descriptors of the objects:</b> minimum and maximum radius, minimum and maximum standard deviation (<math>\delta</math>) threshold, maximum and minimum similarity (<math>sm</math>) threshold, trees density.</li> <li>c. <b>Change the process:</b> maximum iterations for decrease similarity</li> <li>d. <b>Interruption of the process:</b> total iterations, maximum iterations without find new trees.</li> </ul>
<b>3. Approach to tree crown detection:</b>
<ul style="list-style-type: none"> <li>a. While the number of searched trees is not achieved or some of the interruption process (total iterations or minimum threshold for similarity).</li> </ul>
<b>4. Starts the birth phase:</b>
<ul style="list-style-type: none"> <li>a. Randomly pick a radius within model catalogue</li> <li>b. Randomly pick <math>i</math> and <math>j</math> coordinates within the image space</li> <li>c. Check if crown is already present</li> <li>d. If not: <ul style="list-style-type: none"> <li>i. Fill area with circle of radius <math>r</math></li> <li>ii. Extract corresponding area in the image matrix</li> <li>iii. Compare image and model matrices</li> <li>iv. Calculate and store values: <math>i, j</math>, average, standard deviation and <math>Sm</math></li> </ul> </li> </ul>
<b>5. Starts the death phase:</b>
<ul style="list-style-type: none"> <li>a. Input parameters: birth image matrix; crown statistics (<math>Sm</math> sorted); <math>Sm</math> threshold; tree models catalogue with radius between maximum and minimum radius</li> <li>b. While <math>sm_{crown} &lt; sm_{threshold}</math>: <ul style="list-style-type: none"> <li>i. Zero crown pixels in birth image matrix</li> </ul> </li> <li>c. While <math>\delta_{crown} &lt; \min \delta_{threshold}</math> and <math>\delta_{crown} &gt; \max \delta_{threshold}</math>: <ul style="list-style-type: none"> <li>i. Zero crown pixels in birth image matrix</li> </ul> </li> </ul>
<b>6. Update object and global statistics</b>
<b>7. Update number of crowns eliminated for next birth phase</b>
<b>8. When the process finish:</b> reports, graphs and image with individual tree crowns

**Table 3.** Description of MPP-TM algorithm.

fying orchard trees. In this case, however, illumination parameters are not readily available and must be determined.

The objective of this modified approach is to introduce an adaptation of the algorithm described earlier to detect and count trees in orchards of different types. Because it was aimed at a more regional or even global application, Google Earth images were used in an attempt to simulate a generic operational framework. The modified approach uses a similarity measurement between the GOM and the image to calculate the probability of being the center of tree and then places trees in nonoverlapping positions (unless some overlapping is allowed). The algorithm also incorporates a module to determine the illumination parameters from a sample.



**Figure 10.** Illustration of the (a) birth and (b) death phases of the MPP-TM algorithm. In this example, of the 163 randomly positioned crowns, only one had a similarity value larger than the threshold of 0.98.

The algorithm is based on three principles. First, it assumes that the trees have a dome-like shape approximated with a GOM and the right illumination parameters. Second, there is little or no overlapping between trees, and third, the pixel with the highest similarity represents the most likely central position of the tree.

The GOM is a simple dome model for which the height is estimated at 1.5 times the diameter of the crown, and to simplify the problem we have assumed a unique diameter for all trees in the orchard (this can easily be modified to incorporate a range of diameters). The algorithm responsible for the detection of trees are best explained through a list of steps.

**Step 1.** Get user parameters: percent overlapping allowed minimum similarity value, tree diameter, and coordinate of sample tree. These parameters cannot be estimated automatically and are entered by the user. The illumination parameters can optionally be entered by the user, else they will be estimated by the program using the tree sample.

**Step 2.** If sun elevation and azimuth are not provided by the user, the parameters are automatically estimated by the program using the coordinates of a single-tree sample. The program then computes the similarity between the sample and all possibilities of illuminations parameters in steps of 10 degrees.

**Step 3.** Calculate the similarity value for each pixel.

**Step 4.** Sort pixels by decreasing similarity and store coordinates. If the value is lower than the minimum allowed, the pixel is not stored.

**Step 5.** Place a temporary tree “stamp” (flat template) at the next pixel location with highest similarity value.

**Step 6.** Verify if space is already occupied by a tree. If some overlapping is allowed, make sure that the number of nonzero pixel is smaller than the percentage of overlapping allowed. An

output image is created to receive a permanent "stamp" of the GOM shape with the value of similarity associated.

**Step 7.** Validate the results. Validation is performed by estimating the overall number of trees using the density of a representative sample and comparing with the number of trees found.

### 3.2. Testing the MPP–TM approach

#### 3.2.1. Urban trees

Urban trees play an important role in the welfare and quality of life in cities. They contribute to improving air and water quality, mitigate the carbon dioxide and other pollutants, moderate the microclimate and air temperature, help control soil erosion, reduce the flow of rainwater, and provide biodiversity [37–39]. A good knowledge of the species planted in cities and their health contributes to the inventory and management of these trees. To fulfill their role in the urban environment, trees need to be looked after through maintenance practices such as pruning and monitoring them for pests and diseases.

A WorldView-2 (WV-2) image of the campus of the Universidade Federal de Minas Gerais (UFMG) (and surroundings) in Belo Horizonte, Brazil, was used as our test data (Figure 11). The scene was already orthorectified and radiometrically corrected. Although WV-2 offers nine different spectral bands, only the panchromatic band ( $\lambda \approx 450\text{--}800\text{ nm}$ ) with a ground resolution of 50 cm was used since all other bands have a ground resolution of 2 m.

Three WV-2 sub-images were selected to test the performance of MPP–TM algorithm (Figure 10). These images were chosen from different contexts with both isolated and grouped trees and with other objects present in the scene. A wide variety of crown radii is also present in these images. The first two images (Figure 12a and b) are from the university campus of UFMG, and the last is from an urban park (Figure 12c).

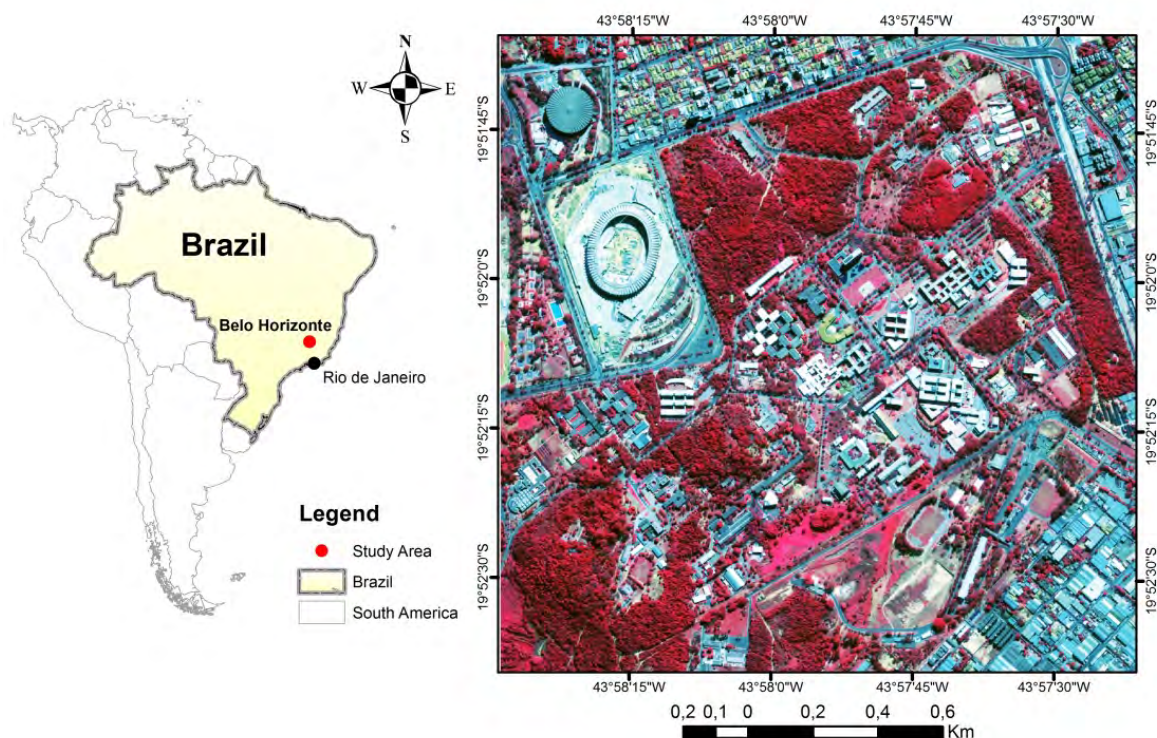
To assess the quality of the results produced by MPP–TM, validation was done by comparing our results with a visual interpretation of the trees in the image. For these, only tree counting was used as validation. For the crown counting validation, we considered the following situations: 1) true positives (TP) for found trees, 2) false positives (FP) when a detected object is not a tree, and 3) false negatives (FN) for trees not encountered. The success score was computed as follows (Equation 7):

$$A = \left( \frac{TD - FP}{N + FN} \right) \times 100 \quad (7)$$

where TD represents the total detected trees and  $N$  is the total number of trees.

These results are shown below with their respective overall similarity and standard deviation graphs (Figure 13). The validation results are presented in Table 4.






**Figure 11.** Location of study area. The image on the right is a WorldView-2 false color composite

Image	Number of Trees	Trees Detected	False Positive	False Negative	Overall Accuracy (%)
WV image 1	47	43	3	8	72.73
WV image 2	50	59	8	5	92.73
WV image 3	175	161	5	20	80.00

**Table 4.** Validation of the MPP-TM results with the three WV-2 images.

In the two images of the campus, the program was able to find 73% and 93% of the trees, respectively, with very few errors in isolated trees (Figure 13a and b). The presence of other objects (buildings, streets, and sidewalks) did not hinder the identification of trees and few false positives (3 and 8, respectively) were found. In both images, MPP-TM was able to find most grouped trees, but the crown diameter was often slightly off. It should be noted that some cases are even difficult to correctly identify and delineate visually. Mostly, the errors came from dividing a single crown into two, or including two different crowns as a single object.

The WV-2 image 3 is from a protected urban park area with predominantly isolated trees and relative homogeneous crown size of about 6 m (Figure 13 c). A total of 161 objects were detected with only 5 false positives and 20 false negatives for an overall success of 80%. Although most deciduous trees were selected, the crown size was often incorrect but given the highly irregular



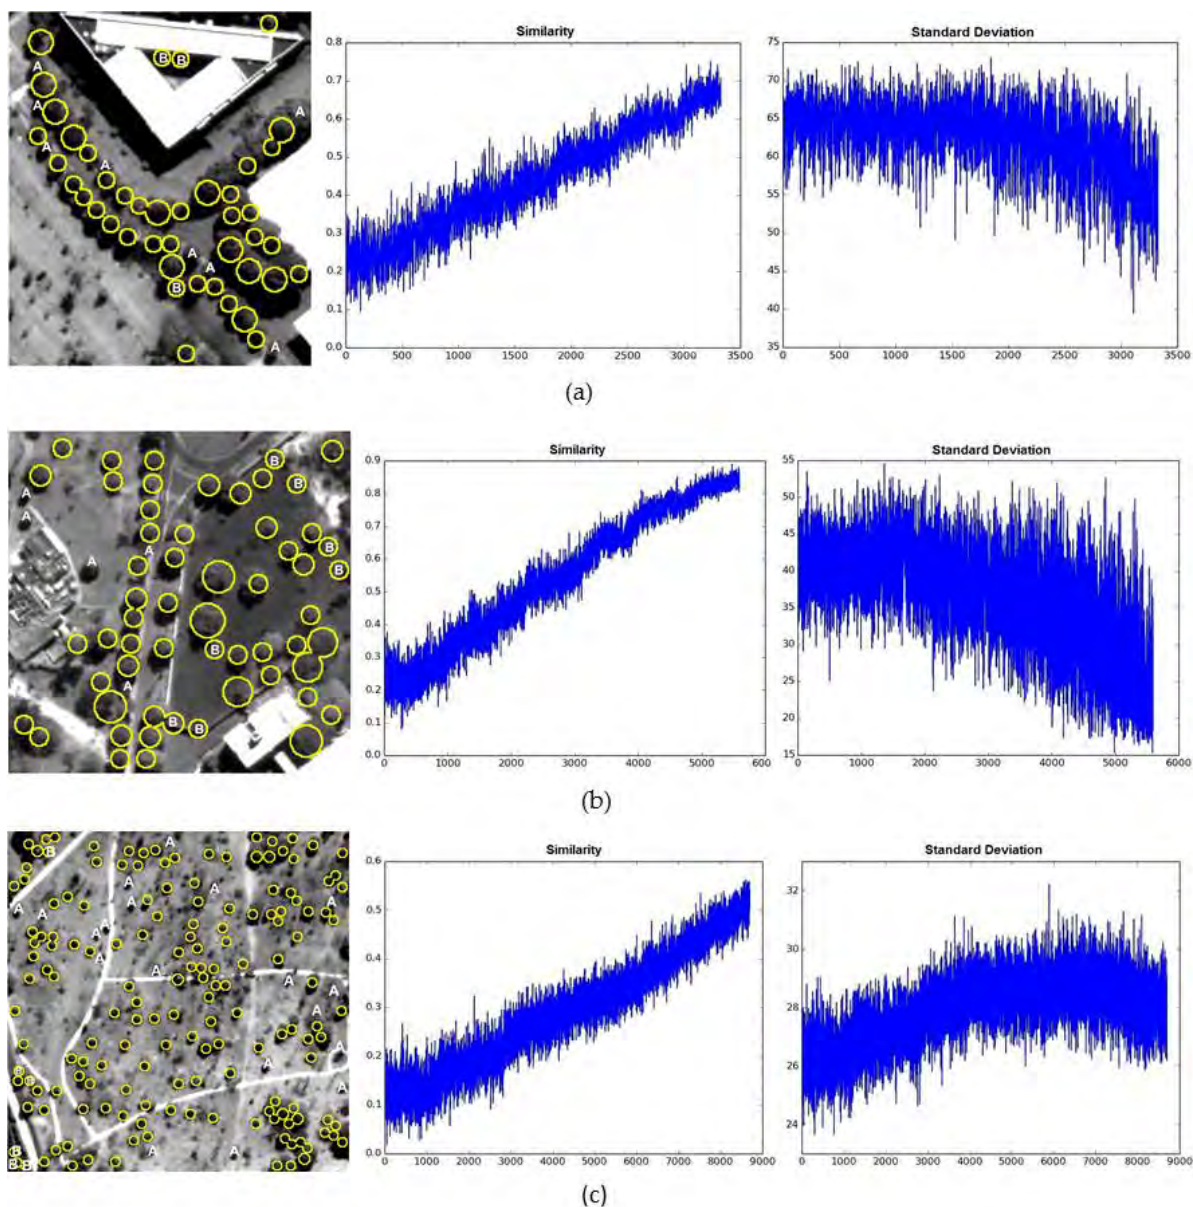
**Figure 12.** Sub-images selected from the WV-2 image.

shape of many of these trees, this was somewhat expected, and similar problems have been reported by reference [4].

The behavior of the overall similarity during the iterations tend to increase as the image is progressively occupied by found trees and this is why the overall similarity increases. The standard deviation, however, is very different for each image and is mostly related to the amount of contrast in the original image. Images with highly contrasting objects (e.g., building tops) will tend to show a progressively decreasing standard deviation. Images of low contrast will tend to see it increasing as the trees are progressively added because of the double illumination nature of the trees.

### **3.2.2. Orchards**

Orchards are collections of individual trees often arranged regularly for which the MPP-TM algorithm could easily be adapted. Tree counting in orchards can be very useful for inventory and management purposes. For instance, the European Union (EU) Common Agricultural Policy (CAP) regulations (EC 73/2009) provide support for permanent crops such as hazelnuts, almonds, walnuts, and fruits in general [40–42]. Eligible orchards need to have a certain size and tree density depending on the type of crop. It has been estimated that orchard fruit production represents approximately 3–4% of the total arable land [43], so the task of estimating fruit production needs tools for counting trees in a timely fashion. Furthermore, the task can take advantage of the near-global high-resolution image cover provided by Google (Google Earth and Google Map) and other Internet-based image services.



**Figure 13.** MPP-TM results obtained with the three WV-2 image 1-3 (left) and their graphs of global similarity (center) and standard deviation (right). The yellow circles correspond to correctly identified trees (true positive or TP), the objects marked with a yellow "A" are false negatives (FN) and the objects marked with a yellow "B" are false positives (FP).

Orchards are plantation of trees of the same species and often of the same age. Consequently, trees of orchards usually have similar size and shape and are regularly spaced. Image processing can easily be adapted to such a task providing VHR images are available. To illustrate the adapted MPP-TM algorithm (which no longer is a real MPP), we have tested over three different types of orchards: a mango plantation in Brazil near Juazeiro, a walnut plantation in France near Grenoble, and an olive plantation in Italy near Bracciano. The three images were directly extracted from Google Earth and had a relatively bad quality as they appeared to have been enhanced for sharpness. To validate the results, we have asked three geography students

to manually interpret and mark the trees belonging to orchards for the three test images, and we have evaluated the results in the following way:

- the total number of trees (NT) was determined by the interpreters;
- matched trees were computed as true positive and are defined by the number of trees found by the algorithm minus the false positives;
- unmatched trees (present on the image but absent from the results) were computed as false negative (FN);
- trees marked by the algorithm but not by the interpreters were marked as false positive;
- the final accuracy was computed as  $TP / (NT + FN)$ .

To be fair, the interpreters were told not to mark the trees that seem too small or too big for the orchards. In addition, valid trees that were found by the algorithm but did not pertain to an orchard were not computed as false positive. As a further improvement, restricting the search within the boundaries of the orchards would increase the accuracy and enable the similarity parameter to be relaxed. The addition of other spectral bands should also improve the results.

Test Image	Number of trees	True positives	False positives	False negatives	Overall accuracy
Grenoble	2435	(2358-69)= 2289	69	103	90.19%
Bracciano	837	(1071-264)=807	264	29	93.19%
Juazeiro	2534	(2555-114)= 2441	114	93	92.92%

**Table 5.** Results of the tree counting algorithm for the three regions (France, Italy and Brazil).

Table 5 shows an overview of the results for the three test images, and Figure 14 shows the graphical results. The top row shows the original images, the center row shows the results of the tree identification (as well as false positives and negatives), and the bottom row displays a detailed section of the image on which the results were overlaid. The Grenoble test image (Figure 14 left column) was characterized by densely arranged walnut trees, which have a large round crown so that the model was well correlated with trees on the image, but the fact that the trees are close to one another produced a relatively large number of “miss” (103). This forced to relax the similarity threshold and caused a few false positives (69). In the case of the Bracciano image (Figure 14 center column), the olive trees are more ill-shaped than the walnut trees, and the relaxation of the similarity threshold caused a large number of false positives, especially in the nearby forested areas. Conversely, very few trees were missed. Finally, the last test image from Juazeiro (Figure 14 right column) is populated by mango trees that, like the walnut trees, have large round crowns. Still, the algorithm produced a fair amount of both false positives and false negatives mainly because of the variation of tree crown size and the particular situation of the dirt road at the top of the image that created a pattern of light and shade similar to the trees (approximately one-third of the false positives came from that road). The three very different images still produced similar accuracy results between 90 and 93%.



**Figure 14.** Illustration of the results of the tree counting for the three test images: Grenoble (left column), Briacciano (center column), and Juazeiro (right column). The empty circles represent the trees that were found, “x” represents the false positives and the black circles represent the false negatives.

#### 4. Final considerations

The detection of individual tree crown in images of very high resolution is a growing and challenging field of research within the remote sensing community. In addition to the structural complexity of the forest, many other factors such as the characteristics of the scene (topography, illumination, and other environmental variables) and forest type (season and

biodiversity) make the task difficult. To reference [16], the ability to achieve individual tree crown delineation of all trees in a forest was recognized as an unrealistic expectation.

In an effort to provide the reader with an overview of the current state of the research in tree crown detection, Part I presented a brief review of some of the most common computerized techniques for detecting and delineating trees in optical VHR images. Part II describes the concepts and implementation of a novel approach based on two mathematical/pattern recognition concepts integrated to improve performance. MPP-TM was developed based on concepts from marked point processes and template matching for the former to take advantage of a mark built from a geometrical-optical model.

MPP-TM was highly effective in finding trees in urban environment with images from the WorldView-2 satellite (ground resolution of 50 cm). A total of 263 trees out of 272 were found (96%), and taking false positives into account, a success rate over 90% was still achieved. The algorithm was also adapted for a tree counting application such as is often needed in large orchards. To count trees in orchards, the approach works very well when the trees are easily distinguishable. Results from three datasets of different crops show an average success better than 90%. Out of 5806 trees, 5537 were found excluding all false positives.

The growing availability of VHR images from commercial satellites or even from web mapping services opens a wide field of applications especially that VHR multispectral images are becoming increasingly common. Multi-temporal studies will further strengthen these applications for monitoring purposes.

Finally, we should mention that Lidar (light detection and ranging) data are also becoming widely available, and its integration with VHR images promises to further improve the results of tree detection algorithm. By adding a third dimension to the images, Lidar reduces the probability of errors by strengthening the evidence around the digital representation of trees.

## Acknowledgements

We are grateful to François Gougeon, Donald Leckie, Guillaume Perrin and Mats Erikson for having kindly provided the rights of reproduction of their figures.

## Author details

Marilia Ferreira Gomes<sup>1,2\*</sup> and Philippe Maillard<sup>1</sup>

\*Address all correspondence to: [mariliafgomes@yahoo.com](mailto:mariliafgomes@yahoo.com)

1 Geography Department, Geosciences Institute, Federal University of Minas Gerais, Belo Horizonte, Brazil

2 Cartography Department, National Institute of Land Reform, Belo Horizonte, Brazil

## References

- [1] Pollock RJ. Model-based approach to automatically locating tree crowns in high spatial resolution images. In: Jacky Desachy, editor. *Proceedings SPIE 2315: Image and Signal Processing for Remote Sensing*; 30 December 1994; Rome. International Society for Optics and Photonics; 1994. p. 526–537. DOI: 10.1117/12.196753
- [2] Avery TE, Berlin GL. *Fundamentals of remote sensing and airphoto interpretation*. 5th ed. New Jersey: Prentice Hall; 1992. 472 p.
- [3] Shao G, Reynolds KM, editors. *Computer applications in sustainable forest management: Including perspectives on collaboration and integration*. 1st ed. Dordrecht: Springer Netherlands; 2006. 277 p. DOI: 10.1007/978-1-4020-4387-1
- [4] Ke Y, Quackenbush LJ. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*. 2011;32(17):4725–4747. DOI: 10.1080/01431161.2010.494184
- [5] Perrin G. *Etude du couvert forestier par processus ponctuels marqués* [thesis]. Paris: Ecole Centrale Paris; 2006. 170 p. Available from: <https://tel.archives-ouvertes.fr/tel-00109074/> [Accessed: 2015-06-08]
- [6] Erikson M. *Segmentation and classification of individual tree crowns in high spatial resolution aerial images* [thesis]. Uppsala: Swedish University of Agricultural; 2004. 45 p. Available from: <http://pub.epsilon.slu.se/676/> [Accessed: 2015-04-12]
- [7] Gougeon FA, Leckie DG. *Forest information extraction from high spatial resolution images using an individual tree crown approach*. 1st ed. Victoria: Canadian Forest Service; 2003. 27 p.
- [8] Franklin SE. *Remote sensing for sustainable forest management*. 1st ed. New York: CRC Press; 2001. 424 p.
- [9] Blaschke T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2010;65(1): 2–16. DOI: 10.1016/j.isprsjprs.2009.06.004
- [10] Pu R, Landry S. A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. *Remote Sensing of Environment*. 2012;124:516–533. DOI: 10.1016/j.rse.2012.06.011
- [11] Larsen M, Eriksson M, Descombes X, Perrin G, Brandtberg T, Gougeon F. Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. *International Journal of Remote Sensing*. 2011;32(20):5827–5852. DOI: 10.1080/01431161.2010.507790
- [12] Hay GJ, Castilla G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline?. In: Blaschke T, Lang S, Hay G, editors. *Object-Based Im-*

- age Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications. 1st ed. Berlin: Springer; 2008. p. 1.4. DOI: 10.1007/978-3-540-77058-9
- [13] Wulder M, Niemann KO, Goodenough DG. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sensing of Environment*. 2000;73(1):103–114. DOI: 10.1016/S0034-4257(00)00101-2
- [14] Pouliot DA, King DJ, Bell FW, Pitt DG. Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment*. 2002;82(2):322–334. DOI: 10.1016/S0034-4257(02)00050-0
- [15] Brandtberg T, Warner T. High-spatial-resolution remote sensing. In: Shao G, Reynolds KM, editors. *Computer Applications in Sustainable Forest Management: Including Perspectives on Collaboration and Integration*. 1st ed. Dordrecht: Springer Netherlands; 2006. p. 19–41. DOI: 10.1007/978-1-4020-4387-1
- [16] Culvenor DS. TIDA: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. *Computers & Geosciences*. 2002;28(1):33–44.
- [17] Gonzales RC, Woods RE. *Digital Image Processing*. 3rd ed. New Jersey: Pearson Prentice Hall; 2008. 954 p.
- [18] Caves RG, Harley PJ, Quegan S. Matching map features to synthetic aperture radar (SAR) images using Template Matching. *IEEE Transactions on Geosciences and Remote Sensing*. 1992;30(4):680–685. DOI: 10.1109/36.158861
- [19] Pollock RJ. The automatic recognition of individual trees in aerial images of forests based on a synthetic tree crown image model [thesis]. Toronto: The University of British Columbia; 1996. 172 p. Available from: <https://circle.ubc.ca/handle/2429/6135>
- [20] Larsen M. Crown modelling to find tree top positions in aerial photographs. In: *In Proceedings of the Third International Airborne Remote Sensing Conference and Exhibition, volume II; 7-10 July 1997; Copenhagen*. Ann Arbor: ERIM International; 1997. pp. 428–435.
- [21] Larsen M, Rudemo M. Optimizing templates for finding trees in aerial photographs. *Pattern Recognition Letters*. 1998;19(12):1153–1162. DOI: 10.1016/S0167-8655(98)00092-0
- [22] Quackenbush LJ, Hopkins PF, Kinn GJ. Developing forestry products from high resolution digital aerial imagery. *Photogrammetric Engineering and Remote Sensing*. 2000;66(11):1337–1346.
- [23] Gomes MF, Maillard P. Identification of urban tree crown in a tropical environment using WorldView-2 data: problems and perspectives. In: Michel U, Civco DL, Schulz K, Ehlers M, Nikolakopoulos KG, editors. *SPIE 8893, Earth Resources and Environmental Remote Sensing/GIS Applications IV; 23–25 September; Dresden*. Washington: SPIE; 2013. p. 88930C-88930C-13. DOI: 10.1117/12.2029073



- [24] Hung C, Bryson M, Sukkarieh S. Multi-class predictive template for tree crown detection. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2012;68:170–183. DOI: 10.1016/j.isprsjprs.2012.01.009
- [25] Gougeon F. A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution aerial images. *Canadian Journal of Remote Sensing*. 1995;21(3):274–284.
- [26] Leckie DG, Gougeon FA. An assessment of both visual and automated tree counting and species identification with high spatial resolution multispectral imagery. In: Hill DA, Leckie DG, editors. *International Forum on Automated Interpretation of High Resolution Digital Imagery for Forestry*; 10–12 February 1998; Victoria. Victoria: Canadian Forest Service; 1998. p. 141–154.
- [27] Gougeon FA, Leckie DG. The individual tree crown approach applied to Ikonos images of a coniferous plantation area. *Photogrammetric Engineering & Remote Sensing*. 2006;72(11):1287–1297. DOI: 10.14358/PERS.72.11.1287
- [28] Szeliski R. *Computer vision: algorithms and applications*. 1st ed. London: Springer-Verlag; 2010. 812 p. DOI: 10.1007/978-1-84882-935-0
- [29] Wang L, Gong P, Biging GS. Individual tree-crown delineation and treetop detection in high-spatial-resolution aerial imagery. *Photogrammetric Engineering & Remote Sensing*. 2004;70(3):351–357. DOI: 10.14358/PERS.70.3.351
- [30] Lamar WR, McGraw JB, Warner TA. Multitemporal censusing of a population of eastern hemlock (*Tsuga canadensis* L.) from remotely sensed imagery using an automated segmentation and reconciliation procedure. *Remote Sensing of Environment*. 2005;94(1):133–143. DOI: 10.1016/j.rse.2004.09.003
- [31] Bunting P, Lucas RM. The delineation of tree crowns in Australian mixed species forests using hyperspectral Compact Airborne Spectrographic Imager (CASI) data. *Remote Sensing of Environment*. 2006;101(2):230–248. DOI: 10.1016/j.rse.2005.12.015
- [32] Zhou J. Application de l'identification d'objets sur images à l'étude de canopées de peuplements forestiers tropicaux: cas des plantations d'Eucalyptus et des mangroves [thesis]. Montpellier: Université Montpellier II - Sciences et Techniques du Languedoc; 2012. 191 p. Available from: <https://tel.archives-ouvertes.fr/tel-00763706/>
- [33] Descombes X. Méthodes stochastiques en analyse d'image: des champs de Markov aux processus ponctuels marqués [thesis]. Nice: Université de Nice Sophia-Antipolis; 2004. 225 p. Available from: <https://tel.archives-ouvertes.fr/tel-00506084/> [Accessed: 2015-09-20]
- [34] Ortner M. Processus ponctuels marqués pour l'extraction automatique de caricatures de bâtiments à partir de modèles numériques d'élévation [thesis]. Nice: Université de Nice Sophia-Antipolis; 2004. 250 p. Available from: <https://tel.archives-ouvertes.fr/tel-00189803> [Accessed: 2015-09-01]

- [35] Baddeley AJ, Van Lieshout MNM. Stochastic geometry models in high-level vision. *Journal of Applied Statistics*. 1993;20(5-6):231–256. DOI: 10.1080/02664769300000065
- [36] St-Onge B. L'apport de la texture des images numériques de haute résolution à la cartographie forestière automatisée [thesis]. Montréal: Université de Montréal; 1994. 502 p.
- [37] Östeberg J, Delshammar T, Wiström B, Nielsen AB. Grading of parameters for urban tree inventories by city officials, arborists, and academics using the Delphi method. *Environmental Management*. 2013;51(3):694–708. DOI: 10.1007/s00267-012-9973-8
- [38] Sander H, Polasky S, Haight RG. The value of urban tree cover: A hedonic property price model in Ramsey and Dakota Counties, Minnesota, USA. *Ecological Economics*. 2010;69(8):1646–1656. DOI: 10.1016/j.ecolecon.2010.03.011
- [39] Almeida, A. L. B. S. S. S. L.. O valor das árvores: árvores e floresta urbana de Lisboa [thesis]. Lisboa: Instituto Superior de Agronomia; 2006. 342 p. Available from: <http://hdl.handle.net/10400.5/469>[Accessed: 2015-06-01]
- [40] Santoro F, Tarantino E, Figorito B, Gualano S, D'Onghia AM. A tree counting algorithm for precision agriculture tasks. *International Journal of Digital Earth*. 2013;6(1): 94–102. DOI: 10.1080/17538947.2011.642902
- [41] Aksoy S, Yalniz IZ, Tasdemir K. Automatic detection and segmentation of orchards using very high resolution imagery. *Geoscience and Remote Sensing*. 2012;50(8): 3117–3131. DOI: 10.1109/TGRS.2011.2180912
- [42] Tasdemir K. Classification of hazelnut orchards by self-organizing maps," in *Pattern Recognition in Remote Sensing (PRRS)*. In: Aksoy S, Younan NH, Forstner W, editors. *IAPR Workshop on Pattern Recognition in Remote Sensing (PRRS)*; 22–22 August 2010; Istanbul. Institute of Electrical and Electronics Engineers IEEE; 2010. pp. 1–4. DOI: 10.1109/PRRS.2010.5742803
- [43] Food and Agriculture Organization of the United Nations. *Statistical yearbook 2013: World food and agriculture*. 1st ed. Rome: FAO; 2012. 289 p.



# DETECTION AND COUNTING OF ORCHARD TREES FROM VHR IMAGES USING A GEOMETRICAL-OPTICAL MODEL AND MARKED TEMPLATE MATCHING

Philippe Maillard<sup>a,\*</sup>, Marília F. Gomes<sup>a,b</sup>

<sup>a</sup> UFMG, Departamento de Geografia, Av. Antônio Carlos, 6627, Belo Horizonte - MG, Brazil - philippe@ufmg.br

<sup>b</sup> INCRA, Av. Afonso Pena, 3500, Belo Horizonte - MG, Brazil - mariliafgomes@yahoo.com

Commission VII, WG VII/4-5

**KEY WORDS:** Orchards, VHR Images, Template Matching, Tree Crown Detection, Geometrical-Optical Model, Tree Counting

## ABSTRACT:

This article presents an original algorithm created to detect and count trees in orchards using very high resolution images. The algorithm is based on an adaptation of the “template matching” image processing approach, in which the template is based on a “geometrical-optical” model created from a series of parameters, such as illumination angles, maximum and ambient radiance, and tree size specifications. The algorithm is tested on four images from different regions of the world and different crop types. These images all have < 1 meter spatial resolution and were downloaded from the GoogleEarth application. Results show that the algorithm is very efficient at detecting and counting trees as long as their spectral and spatial characteristics are relatively constant. For walnut, mango and orange trees, the overall accuracy was clearly above 90%. However, the overall success rate for apple trees fell under 75%. It appears that the openness of the apple tree crown is most probably responsible for this poorer result. The algorithm is fully explained with a step-by-step description. At this stage, the algorithm still requires quite a bit of user interaction. The automatic determination of most of the required parameters is under development.

## 1. INTRODUCTION

It is estimated that orchard fruit production represents approximately 3%–4% of the total arable land (FAO, 2012). The EU CAP regulations (EC 73/2009) provide support for permanent crops like hazelnuts, almonds, walnuts and fruits in general (Santoro et al., 2013; Aksoy et al., 2012; Tasdemir, 2010) but eligible orchards need to have a certain size and tree density, depending on the type of crop. The task of estimating fruit production generally implies counting trees, a time consuming task that could benefit from the use of the very high resolution (VHR) satellite images now available, but also the near-global high resolution image coverage such as is provided by Google-Earth and other internet-based image services. An orchard is a plantation of trees of the same species and often the same age. Consequently, trees in orchards usually have similar sizes and shapes and are regularly spaced. Image processing can be adapted to such a task, providing efficient algorithms that can take advantage of the particular aspect of the orchards and the availability of VHR images.

Very high spatial resolution remote sensing images represent a cost effective and reliable way of obtaining information about trees. It may be the only practical manner to ensure a sustainable stewardship of forests with the necessary data about trees in a synoptic and repetitive form for large areas and over long periods of time (Shao and Reynolds, 2006). As remote sensing goes, it is generally the tree crown that stands as the basis for the data required for the inventory, for it allows determining not only the tree’s size but also its position, the density of leaf coverage, and in some cases the species. It can also be used to estimate ecological parameters such as the density of the population, the health condition of the trees, their volume, their biomass, and carbon sequestration rates (Ke and Quackenbush, 2011; Perrin, 2006; Erickson, 2004).

The analysis of individual trees based on remote sensing images is a complex problem given the variability of the size, shape, and

spectral response of the crown. What is detected as a single object may in fact be, in some cases, a separate group of branches, or in other cases a group of trees (Pu and Landry, 2012). Other sources of error are caused by the proximity of neighbouring trees, trees’ being located under other trees, trees in the shade, or trees that have a low spectral contrast with the background (Wulder et al., 2000). Still, the information provided this way is crucial to a series of applications, such as the inventory and management of forested areas as well as of parks and urban forests. It can also be used for counting and monitoring trees in orchards or under power lines to prevent damage and accidents. In the case of orchards, VHR remote sensing can also contribute to early stress detection, yield prediction, and phenology monitoring (Stuckens et al., 2010).

Larsen et al. (2011) have made a review of six algorithms (arguably the most well recognized) for the detection of individual trees and concluded that no single algorithm is best for all situations of tree density and characteristics. Furthermore they found template matching (TM) to produce the best results for individual isolated trees, which is often (but not always) the situation in orchards where trees are generally well separated from each other.

Recently, Gomes and Maillard (2014) used a marked point-process (MPP) and TM with a 3D geometrical-optical model (GOM) to locate isolated trees of varying size and shape in urban environments. Because trees in orchards are often individually distinguishable and have a similar shape and size, they are perfect candidates for TM with a 3D GOM. In this article, VHR Google Earth images were used for identifying orchard trees. Orchards being collections of individual trees often arranged regularly, a combined TM-GOM algorithm can easily be adapted for the task of tree counting in a timely fashion.

A number of approaches have been proposed for the mapping of orchards using VHR images, some of which are presented in Table 1. All these approaches use some primitive structur-

\*Corresponding author

ing element which is compared to the image or texture analysis or a combination of both. The use of some structuring element (usually a circular shape) is closely related to template matching (TM).

In this selection of approaches, three (Bazi et al., 2009; Recio et al., 2013; Santoro et al., 2013) used some morphological approach based on some simple shape to detect the trees. A fourth (González et al., 2007) used a Chamfer transform, which is also shape-based. One approach employed region growing on spectral features (Srestasathiern and Rakwatin, 2014) and two (Tasdemir, 2010; Aksoy et al., 2012) aimed at detecting whole orchard plots rather than the trees. These latter two approaches offer an interesting complement to the tree detection problem, in which the detection of the orchards prior to the tree detection phase would reduce significantly the search areas and eliminate false positives found outside the orchards.

It has become clear that the use of some kind of morphological element represents a key element in detecting orchard trees in VHR images. It is also the approach we have favoured here but we opted to introduce a three-dimensional structuring element based on a GOM to make the approach more consistent with the specific characteristics of the image at hand.

Reference	Algorithm	Comments
González et al. (2007)	Chamfer transform	Comparison with flat dark disk and probability of being in a reticular arrangement.
Tasdemir (2010)	Self-organizing map	Combining spectral and texture features to detect orchards as whole objects
Aksoy et al. (2012)	Texture-based classification	Texture based on primitive and granulometric analysis using Gabor filters. Pre-processing by applying a Laplace of Gaussian filter.
Santoro et al. (2013)	Structuring elements and classification	Uses an asymmetrical filter to account for differential illumination. Non-vegetation areas are masked using NDVI.
Recio et al. (2013)	Morphological operator on classified image	Uses unsupervised $k$ -means, detects tree class, and applies morphological operator to eliminate false positives
Bazi et al. (2009)	Morphological operator on binary image	First classifies image, then uses morphological analysis (erosion).
Srestasathiern and Rakwatin (2014)	Local peak detection	Uses a series of spectral features and rank filtering. Calculates window size based on semi-variogram.

Table 1: List of articles dedicated to orchard tree detection using VHR images ( $\leq 1$  m) along with their respective generic approach.

The objective of this research is to introduce an adaptation of TM with a 3D GOM to detect and count trees in orchards in VHR images such as provided by Google Earth. The TM is adapted to this particular situation by placing marks to “reserve” the space for each tree found. The approach also incorporates a module to determine a near-best model (GOM radius, and illumination parameters) from an image sample. Lastly, the algorithm can handle both monochromatic and multi-spectral images. Results are

presented for four sample scenes (two monochromatic and two multi-spectral) from different countries and crop types.

## 2. METHOD

By using a GOM, the effects of varying illumination (sun elevation and azimuth) become an advantage rather than an obstacle, especially when the background is homogeneous. In terms of data, VHR image data, including a large proportion of Google Earth images, have sufficient resolution for identifying orchard trees. In this case however, the illumination parameters are not readily available and must be determined. Although we have implemented an automated routine to determine most of these parameters (sun elevation, sun azimuth, crown size), it is still in development to make it perform better and the user’s visual estimation is usually quicker and often better than our automated estimation.

The proposed approach is to introduce an adaptation of the algorithm mentioned above (TM and MPP) to detect and count trees in orchards of different types. Aiming at a regional application, Google Earth images were used to demonstrate a proof-of-concept with images of lesser spectral and radiometric quality. The algorithm uses measure of the similarity between the GOM and the image to estimate the probability of being the centre of a tree and then places a mark for that tree in a non-overlapping position (unless some overlapping is allowed). The overlapping parameter can also be used to force a minimum spacing between the tree crowns; in this case a negative value is used. The algorithm also incorporates a module to determine the illumination parameters (sun azimuth and elevation, maximum and ambient radiance) from a sample.

### 2.1 Geometrical-Optical 3D Model

In creating a valid 3D geometrical-optical model we have chosen a simplified version in which the crown is represented by a dome of varying skewness, a Lambertian reflectance model with ambient light and a projected shadow on the ground. Equations 1 and 2 give the formulation of our model, in which each pixel is treated as a singular surface.

$$L = L_{max} \times \left( \frac{\cos(\theta)}{\cos(i)} \right) + amb \quad (1)$$

where

$$\cos(i) = \{ \cos(\theta_s)\cos(\theta_n) \} + \{ \sin(\theta_s)\sin(\theta_n)\cos(\phi_s - \phi_n) \} \quad (2)$$

Here,  $L$  is the radiance of the pixel,  $L_{max}$  is the maximum radiance of the tree,  $\cos(i)$  is the angle between the incidence angle of the sun and the normal of the tree surface,  $\theta_s$  is the solar elevation angle,  $\theta_n$  is the slope of the object surface,  $\phi_s$  is the solar azimuth,  $\phi_n$  is the aspect of the object surface and  $amb$  represents the ambient diffuse lighting.

The geometrical-optical model is adjusted according to the specific illumination parameters of the image and the size of the trees present on the scene. Figure 1 shows two examples of tree models with similar reflectances but different solar elevations.

A parameter of projected shadow clipping has also been added to take into account the fact that it was not always beneficial to use the whole shadow in situations where it was projected onto another tree and not on the ground. The height of the tree also affects the size of the shadow, so that it did not appear wise to set the height to a fixed value: it was made proportional to the crown radius.




Figure 1: Illustration of the geometrical-optical model of tree crown as seen in two different solar elevation angles: (a) 20° and (b) 45°.

## 2.2 Algorithm

The algorithm is based on three principles: Firstly, it assumes that the trees have a dome-like shape approximated with a GOM and the right illumination parameters; Secondly, that there is little or no overlap between the trees; Thirdly, that the pixel with the highest similarity represents the most likely central position of the tree.

The algorithm is not based on a “marked point process” since it is not completely random. It does however take advantage of the principle of a mark to ensure that the trees found follow a rank based on the similarity between the image and the GOM. The marked process makes sure that the location where a tree has been detected cannot be occupied by another tree unless some overlap has been previously allowed. The GOM is a simple dome model in which the height is estimated to be 1.5 times the diameter of the crown. To simplify the problem, we have employed the same diameter for all trees in the orchard (this can eventually be modified to incorporate a range of diameters). The algorithm responsible for the detection of trees can be best explained through a step-by-step description.

- Step 1. Get user parameters: percentage of overlap allowed, minimum similarity value, tree diameter, and coordinate of sample tree. These parameters cannot yet be estimated automatically and are entered by the user. The illumination parameters can optionally be entered by the user; if not, they will be estimated by the program using the tree sample.
- Step 2. If the sun elevation and azimuth are not provided by the user, these parameters are automatically estimated by the program using the coordinates of at least one tree sample from the image. The program then computes the similarity between the sample and all possibilities of illumination parameters in steps of 10 degrees in azimuth and 5 degrees in sun elevation.
- Step 3. Calculate a similarity value (SV) for each pixel. The similarity is a combination of the cross-correlation and the normalized absolute difference between the GOM and the image at each pixel location and is given by Eq. 3.

$$Sm = \gamma - \alpha ND \quad (3)$$

where  $\gamma$  is the cross-correlation,  $ND$  is the normalized absolute difference, and  $\alpha$  is a constant weight factor (usually between 0.25 and 0.5 depending on radiometric quality of the image). The cross-correlation and absolute difference are calculated as follows (Eq. 4 and 5).

$$\gamma(x, y) = \frac{\sum_i \sum_j [\omega_{(i,j)} - \bar{\omega}] \sum_i \sum_j [f_{(i,j)} - \bar{f}]}{\{\sum_i \sum_j [\omega_{(i,j)} - \bar{\omega}]^2 \sum_i \sum_j [f_{(i,j)} - \bar{f}]^2\}^{1/2}} \quad (4)$$

Here,  $\omega_{i,j}$  is the GOM and  $f_{i,j}$  is the portion of the image that corresponds to a circle of the same radius, so that two matrices of same dimensions are always compared. The  $\bar{\omega}$  and  $\bar{f}$  are their respective means. The values of  $\gamma$  range between  $-1$  and  $1$ . The same logic is used in Eq. 5, which computes a normalized difference value between the same two matrices.

$$ND = \left| \frac{\sum \omega - \sum f}{\sum \omega + \sum f} \right| \quad (5)$$

- Step 4. If the image is a multispectral image, repeat step 3 for all bands and make the similarity cumulative (the final value will then be divided by the number of channels/bands).
- Step 5. Sort the pixels by decreasing similarity and store the coordinates. If the value is lower than the minimum allowed, the pixel is not stored.
- Step 6. Place a temporary tree mark (circle) at the next pixel location with the highest similarity value.
- Step 7. Verify whether the space is already occupied by a tree. If some overlap is allowed, make sure that the number of non-zero pixels is smaller than the percentage of overlap allowed. An output image is created to receive a permanent mark of the GOM shape with the associated similarity value.
- Step 8. Validate the results. The validation is performed by comparing the number of trees found and their locations. The comparison is made by tree and not by pixel. Alternatively, it can be done by estimating the overall number of trees using the density of a representative sample and comparing this with the number of trees found.

By ordering the image pixels by their SV and progressively occupying the space with tree marks, the tree detection criterion automatically decreases with time until it reaches a minimum specified by the user.

## 2.3 Test and Validation

To illustrate the adapted TM-GOM algorithm we have tested it on four different types of orchards: a mango plantation in Brazil near Juazeiro (BA), a walnut plantation in France near Grenoble, an apple orchard near Southington (CT), and an orange plantation near Citrus Grove (FL)—the last two in the United States. These images were selected more or less arbitrarily using the four fruits as criterion and searching for regions renowned for their production. These regions are from both temperate (Grenoble and Southington) and tropical (Citrus Grove and Juazeiro) environments. The four images were directly extracted from Google Earth and had a relatively bad quality, as they appear to have been

enhanced for sharpness. The first two were used in monochromatic mode while the last two were kept in RGB mode. To validate the results, we asked three geography students to manually interpret and mark the trees belonging to the orchards for all test images and we have evaluated the results in the following way:

- the total number of trees (N) was determined by the interpreters;
- matching trees were computed as true positives (TP) and are defined by the number of trees found by the algorithm;
- unmatched trees (present on the image but absent from the results) were marked as false negatives (FN);
- trees marked by the algorithm but not by the interpreters were marked as false positives (FP);
- the final accuracy was computed as  $\frac{TP}{N+FP} \times 100$ .

The results show the proportion of true tree crowns found relative to the total number of tree crowns that should have been found plus the crowns that were found by the algorithm but are not trees. By further adding the wrongly found trees, the index shows a fairer value of success.

The interpreters were told not to mark trees that were much smaller or larger than the average tree in the orchards. This was initially necessary because we used a single crown size to compute similarity values in our tests. We are currently correcting this shortcoming by applying successive passes with different crown sizes, starting with larger crown sizes and ending with smaller ones. This order is logical since larger trees occupy larger areas and can be more difficult to find, whereas small tree GOMs can produce high similarity values even on large trees but not the inverse. Also, valid trees that were found by the algorithm but did not pertain to an orchard were not computed as false positives. As a further improvement, restricting the search to within the boundaries of the orchards would increase the accuracy and would enable the similarity parameter to be relaxed.

### 3. RESULTS AND DISCUSSION

Table 2 shows an overview of the results for the four test images while the graphical results are shown in Figures 2 and 3. Figure 2 shows the original images and a colour-coded result where the warmer tones indicate stronger similarity values and Figure 3 represents a mapping of the results showing the true positives (○), the false negatives or missing trees (●), and the false positives (×). Figure 4 shows the histogram of similarity values for the four images as well as the sample tree used to compute the maximum relative radiance and the ambient light (the relative radiance in the shadows).

The **Grenoble** test image (Figures 2a and 3a) is characterized by densely arranged walnut trees which have a large round crown (Figure 5a) so that the model was well correlated with the trees in the image and produced an overall accuracy of  $\approx 90\%$ . But the fact that the trees are close to one another still produced 103 “misses”. This forced the relaxation of the similarity threshold and caused a few false positives (69), all of which are outside the orchards. Interestingly, the histogram of SVs (Figure 4a) is clearly bimodal with the right peak roughly corresponding to the walnut trees.

In the case of **Juazeiro** (Figures 2b and 3b), the area is populated by mango trees that, like the walnut trees, have large round

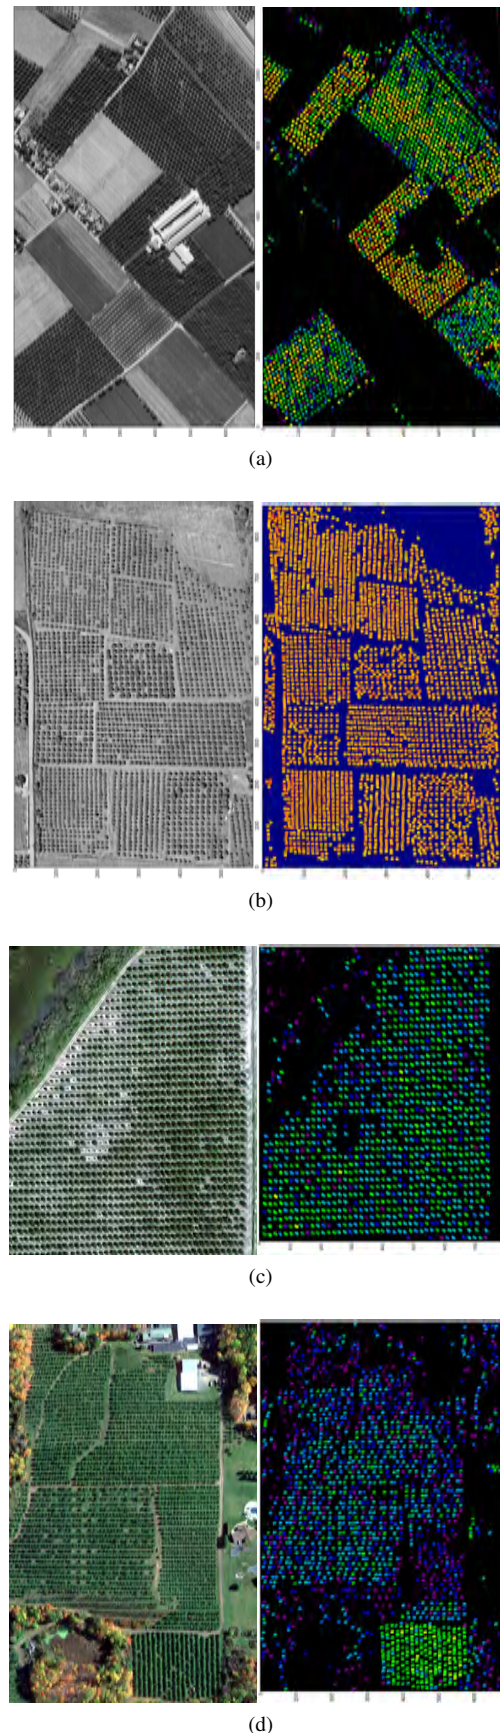


Figure 2: Results of the tree counting algorithm for the four test images: a) Grenoble, b) Juazeiro, c) Citrus Grove, d) Southington. The left column shows the original images while the right one shows the colour-coded results where warmer colours represent higher similarity values.

Test Image	Type M/C	N	TP	FP	FN	Overall accuracy	User accuracy
Grenoble	M	2435	2289	69	103	90.19%	94.00%
Juazeiro	M	2534	2441	114	93	92.92%	96.33%
Citrus Grove	C	1185	1131	39	54	91.28%	95.44%
Southington	C	1873	1576	224	297	72.63%	84.14%

Table 2: Results of the tree counting algorithm for the four test images (France, Brazil, two in the USA). Legend: Type M=monochromatic, Type C=color N=number of trees, TP=true positive, FP= false positive, FN=false negative. User accuracy is the success rate attained when considering only the trees within the orchard’s limits (no commission error).

crowns (Figure 5b) that generated a success rate of  $\approx 93\%$ . The algorithm produced a fair amount of both false positives (114) and false negatives (93) mainly because of the variation of tree crown size and the particular situation of the dirt road on the left of the image that created a pattern of light and shade similar to the trees (approximately one-third of the false positives came from that road). Unlike the Grenoble case, the histogram of SVs (Figure 4b) has a unique peak showing that there is little difference between the trees and their surroundings. Again, all false positives are outside the orchards.

The **Citrus Grove** colour test image generated somewhat similar results with  $\approx 91\%$  overall success (Figures 2c and 3c). The fact that colour was used improved the results by about 6% in relation to using a monochromatic channel (not shown here). Although most trees in the orchards are well defined, there are quite a few clearly smaller trees that were not detected. The SV histogram is clearly multi-modal with three dominant peaks and some secondary ones. This is due to the effect of using the three colour channels since some pixels were correlated to the GOM in one channel but not in the other ones, and shows the contribution of colour to help separate trees that are similar to the GOM and the sample relative radiance values.

The **Southington** test image produced poorer results with an overall success rate of only  $\approx 73\%$  (Figures 2d and 3d). We attribute this to two main facts. Firstly, apple trees are known to be ill-shaped, with a sparser crown than the other three fruit trees (Figure 5d). Secondly, the orchards in Figure 3d are not very regular, with trees varying widely in size and spacing. The interpreters reported having the most difficulty with the Southington test image because of these variations. It can be observed in the two figures (Figures 2d and 3d) that the orchard located on the Southeast corner was well processed with only one false negative. This orchard is also characterized by the warmest colour, meaning that high SV were obtained in it.

The colour-coded images based on SV (Figure 2, right column) give a good indication of the strengths and weaknesses of the algorithm. As shown in Table 2, the algorithm worked well in most situations. It did not perform well in cases where the trees were much smaller or much bigger than the average or when their shape was very different from the idealized dome we used as a GOM. Similarly, it did not produce high SV in cases where the tree crowns overlap each other, as in the Southeast orchard of the Grenoble image (Figure 2a). It also appears that the edges of the orchards generated more false negatives, probably because these edges are often in contact with other objects like trails, roads, houses or even trees of different species with a different size. The most common of these problems are illustrated in Figure 6. A significant improvement could be achieved by limiting the search to within the orchards’ boundaries, which would eliminate most

false positives, as shown in the rightmost column of Table 2 (user accuracy).

In its current stage of development, the algorithm requires eight parameters: sun elevation, sun azimuth, maximum radiance, ambient radiance, crown radius, percent of projected shadow (GOM), minimum similarity value, and spacing/superposition allowed. The first six parameters can be estimated through a routine that is activated when the parameter is not supplied. For this to take place, the user needs to provide at least one coordinate of a typical tree crown in the image (if more than one coordinate is supplied, the routine analyses all trees and returns average values for the six parameters). At this stage we have found that a visual estimation of these parameters by the users is at least as good as the one supplied by the routine, and we are still working on improving the parameter estimation routine. In the case of real panchromatic or multi-spectral images, the first two parameters are included in the metadata of the image. Our next version of the algorithm will also include the possibility of running successive passes each with a different tree crown size, starting with the larger radius.

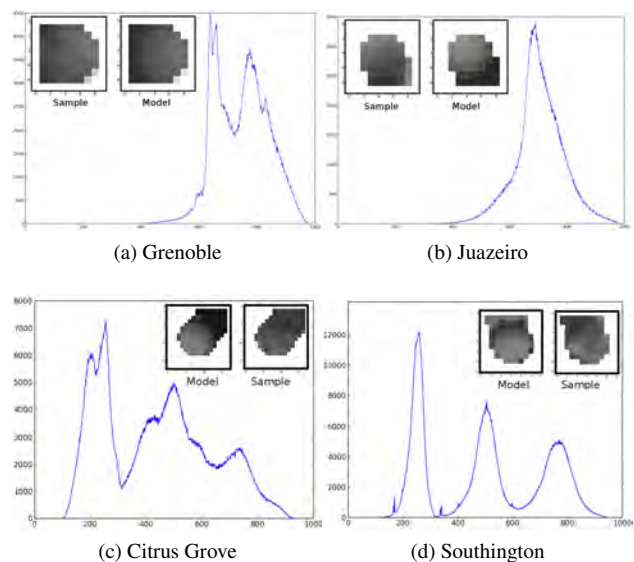


Figure 4: Similarity value histograms for the four test images. The grey tone corner images represent the the scale geometrical-optical models and the sample on which it was based.

#### 4. CONCLUSIONS

Orchards have important VHR image features that can take advantage of crown recognition algorithms to ease the tasks of counting and monitoring trees. In this article we presented an adaptation of Template Matching that uses a geometrical-optical tree model based on illumination and radiance parameters. The algorithm also features a search by rank based on similarity values and the placement of marks to preserve the spatial distribution of the trees within the orchards. The algorithm can use both monochromatic or multi-spectral images and was tested in four different contexts with four different types of tree: walnut, mango, orange and apple. These test images were not original images but processed ones directly downloaded from the GoogleEarth web application. It was found that the first three types produced results above 90% but the apple orchards generated much poorer results, mostly because the apple tree is not as well shaped as the other three types. The program incorporates a module to automatically determine the illumination and radiance parameters. The illumination parameters are, however often better determined visually



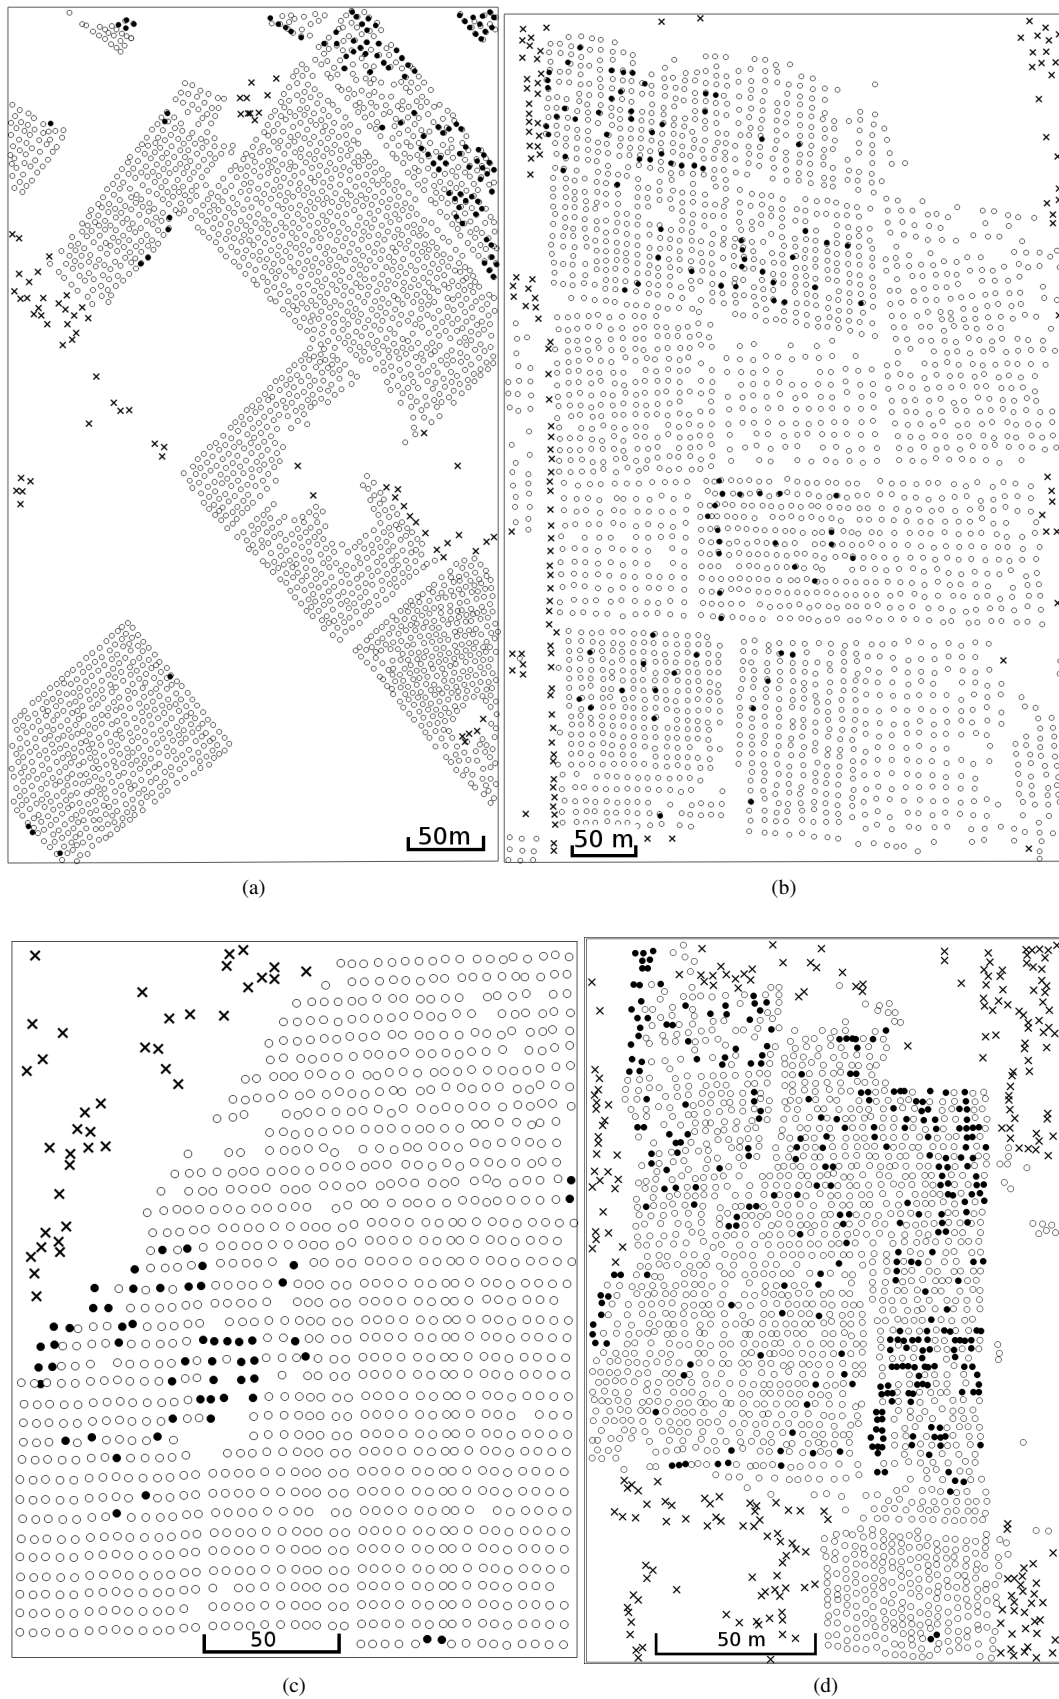


Figure 3: Mapping of the tree counting results for the four test images (a) Grenoble, b) Juazeiro, c) Citrus Grove, d) Southington): empty circles (o) represent trees that were found, “x”s represents the false negatives and the black circles (●) represent the false positives.

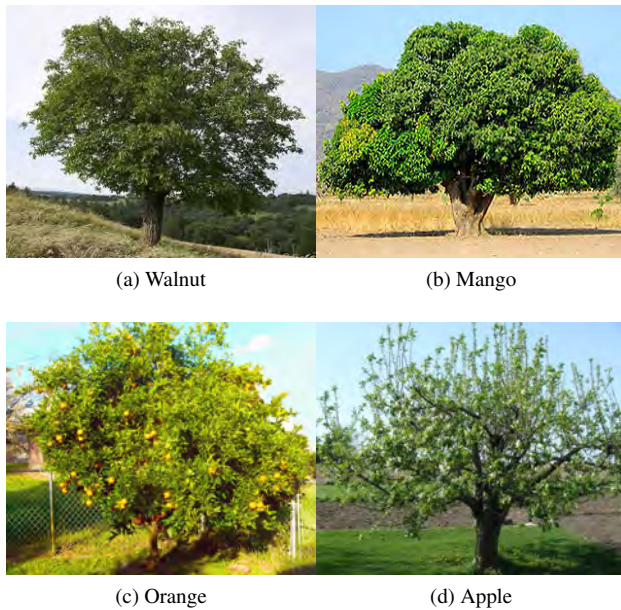


Figure 5: The different types of fruit trees analysed with the tree-counting algorithm. Note how the apple tree crown is much more open than the other three types.




Figure 6: Some of the problem situations encountered by the tree counting algorithm.

by the user. The following points summarize the results obtained.

- Almost all trees found within the orchards' limits are true positives.

- Without considering the false positives outside the orchards' limits, the overall success increases to over 93% in three of the four test images (except Southington).
- Many false negatives created doubts in the interpreters, because of their small size or their odd shape.
- The algorithm is quite efficient when the trees in the orchards are well separated and have a uniform shape.

In its present state, the algorithm still relies on a threshold that is set by the user, but we think this could be replaced by limiting the search to actual orchards and providing a tree density value. Further refinements will test other measures of similarity, like the Spectral Information Divergence (SID) proposed by Du et al. (2004) and used by Stuckens et al. (2010) for citrus tree recognition. Work is also underway to incorporate the context and take advantage of the fact that orchard trees are never isolated. Lastly, we are looking into testing the approach proposed by Tasdemir (2010) that detects orchards as a single object before detecting and counting the tree crowns within the orchards, which would lead to a more robust hierarchical approach.

#### ACKNOWLEDGEMENTS

This work was produced within the context of a project of tree crown detection of the authors, and did not receive any specific financing. The authors are grateful to Google for enabling the download of very high resolution colour images from the Google Earth application. Finally we would like to thank Barbara Henrique Oliveira, Iara Marques Vilela and Dayane Freitas for mapping all the trees in the test images.

#### REFERENCES

- Aksoy, S., Yalniz, I. Z. and Tasdemir, K., 2012. Automatic detection and segmentation of orchards using very high resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(8), pp. 3117–3131.
- Bazi, Y., Al-Sharari, H. and Melgani, F., 2009. An automatic method for counting olive trees in very high spatial remote sensing images. In: *Proceedings of the 2009 IEEE International Geoscience and Remote Sensing Symposium*, Vol. 2, IEEE, Cape Town, South Africa, pp. II.125–II.128.
- Du, Y., Chang, C.-I., Ren, H., Chang, C.-C., Jensen, J. O. and DAmico, F. M., 2004. New hyperspectral discrimination measure for spectral characterization. *Optical Engineering*, 43(8), pp. 1777–1786.
- Erickson, M., 2004. *Segmentation and Classification of Individual Tree Crowns in High Spatial Resolution Aerial Images*. PhD thesis, Swedish University of Agricultural Sciences, Uppsala.
- FAO, F., 2012. *Statistical Yearbook 2013: World Food and Agriculture*. FAO (Food and Agriculture Organization of the United Nations), Rome.
- Gomes, M. and Maillard, P., 2014. Integration of a marked point process and template matching for the identification of individual tree crowns in an urban and a wooded savanna environment in Brazil. In: *Proceedings of SPIE Remote Sensing 2014*, Vol. 9245, International Society for Optics and Photonics, Amsterdam, The Netherlands, pp. 92450X.1 – 92450X.12.

- González, J., Galindo, C., Arevalo, V. and Ambrosio, G., 2007. Applying image analysis and probabilistic techniques for counting olive trees in high-resolution satellite images. In: *Advanced Concepts for Intelligent Vision Systems*, Springer, pp. 920–931.
- Ke, Y. and Quackenbush, L. J., 2011. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *International Journal of Remote Sensing*, 32, pp. 4725–4747.
- Larsen, M., Eriksson, M., Descombes, X., Perrin, G., Brandtberg, T. and Gougeon, F., 2011. Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. *International Journal of Remote Sensing*, 32(20), pp. 5827–5852.
- Perrin, G., 2006. *Etude du couvert forestier par processus ponctuels marqués*. PhD thesis, Ecole Centrale Paris.
- Pu, R. and Landry, S., 2012. A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. *Remote Sensing of Environment*, 124, pp. 516–533.
- Recio, J., Hermosilla, T., Ruiz, L. and J.Palomar, 2013. Automated extraction of tree and plot-based parameters in citrus orchards from aerial images. *Computers and Electronics in Agriculture* 90, pp. 24–34.
- Santoro, F., Tarantino, E., Figorito, B., Gualano, S. and D’Onghia, A. M., 2013. A tree counting algorithm for precision agriculture tasks. *International Journal of Digital Earth*, 6(1), pp. 94–102.
- Shao, G. and Reynolds, K. M., 2006. *Computer applications in sustainable forest management*,. Vol. 11, Springer.
- Srestasathiern, P. and Rakwatin, P., 2014. Oil palm tree detection with high resolution multi-spectral satellite imagery. *Remote Sensing (MDPI)*, 6(10), pp. 9749–9774.
- Stuckens, J., Somers, B., Albrigo, G. L., Dzikiti, S., Verstraeten, W. W., Swennen, R., Verreyne, S. and Coppin, P., 2010. Off-nadir viewing for reducing spectral mixture issues in citrus orchards. *Photogrammetric Engineering & Remote Sensing*, 76(11), pp. 1261–1274.
- Tasdemir, K., 2010. Classification of hazelnut orchards by self-organizing maps. In: *IAPR Workshop on Pattern Recognition in Remote Sensing*, 2010, IEEE, pp. 1–4.
- Wulder, M., Niemann, K. O. and Goodenough, D. G., 2000. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sensing of Environment*, 73(1), pp. 103–114.

# Integration of Marked Point Processes and Template Matching for the identification of individual tree crowns in an urban and a wooded savanna environment in Brazil

Marília Ferreira Gomes<sup>a</sup> and Philippe Maillard<sup>a</sup>

<sup>a</sup>Universidade Federal de Minas Gerais (UFMG), Av. Antônio Carlos, 6627, Belo Horizonte, Brazil.

## ABSTRACT

A number of methods have been developed for the automatic identification and delineation of individual tree crowns from high spatial resolution satellite image to provide support for the management and maintenance of forests both in natural and urban environments. In this paper we present a method that integrates a Marked Point Processes (MPP) model and Template Matching (TM) to extract individual tree crowns in two tropical environments. The MPP is an extension of Markov random fields in which objects are defined by their position within a space of possible positions and their marks (e.g. shape). The MPP has been increasingly used for the recognition of objects but most implementation use an oversimplified model as mark. We argue that the MPP could take better advantage of the geometry of trees by incorporating a three-dimensional model as a mark. Conversely, TM is an approach to pattern recognition that takes the characteristics of the objects into account. Our method uses cross-correlation for determining which objects have been correctly targeted by the MPP. The correlation between the illuminated 3D crown model and the image is an inheritance from TM. The methodology was applied in synthetic images and sub-images of the WorldView satellite in two different contexts in Brazil. The results are validated by counting the correctly identified trees and by comparing their size with our interpreted version. Results are encouraging with 65 to 90% of correctly identified trees. The most difficult cases are mostly related to the existence of clustered tree crowns.

**Keywords:** Tree crown detection, High resolution image, Marked Point Processes, Template matching

## 1. INTRODUCTION

The Earth's forests play a vital role as environmental, social and economical assets. They bring major contributions to conserving ecosystems and fresh water resources, stabilizing the climate, controlling erosion, promoting biodiversity, providing prime matter as well as having invaluable cultural and recreational values.<sup>1-4</sup> In turn, even trees taken individually are precious natural elements of our urban environments. They improve the quality of the air and water, reduce concentrations of carbon dioxide and other pollutants, help stabilize the temperature and other climatic phenomena, reduce energy consumption, contribute to control erosion and bring biodiversity to our otherwise artificial cities.<sup>5,6</sup> As such, it is essential for the wellbeing of our society to keep inventories of our trees and forests, be it in the cities or in wild. Much time and resources are typically consumed by these inventories that are rarely thorough and have an insufficient frequency. Satellite remote sensing has often been use to try to remedy these problems but only in recent years it has been offering products and techniques capable of supplying information on individual trees. Recent studies have ventured into extracting a wealth of information from high resolution satellite imagery such as population density, species composition, canopy health and structure, volume of wood, biomass, carbon sink information, etc.<sup>7-10</sup> The detection and delineation of tree crowns is one such technique that has attracted researchers from both environmental and computer vision fields.<sup>7,11</sup> The availability of very high resolution (VHR) satellite imagery has triggered the use of object-based approaches in computer vision instead of the pixel-based methods more traditionally used in remote sensing.<sup>8</sup>

---

Further author information: (Send correspondence to Marília Ferreira Gomes)

M. F. Gomes: E-mail: mariliafgomes@yahoo.com, Telephone: +55 (31) 92 35 06 17

P. Maillard: E-mail: philippe@ufmg.br, Telephone: +55 (31) 33 24 76 69

Earth Resources and Environmental Remote Sensing/GIS Applications V, edited by Ulrich Michel,  
Karsten Schulz, Proc. of SPIE Vol. 9245, 92450X · © 2014 SPIE  
CCC code: 0277-786X/14/\$18 · doi: 10.1117/12.2066848

Proc. of SPIE Vol. 9245 92450X-1

In 2013 we presented a paper at the SPIE Remote Sensing Conference<sup>12</sup> that brought an overview of the challenges and perspectives of recent object-based techniques for the detection and delineation of tree crowns in a tropical urban environment. In this paper we tested three approaches for detecting individual trees and assessing their shape: *region growing*, *watershed* and *template matching*. Better results were generally obtained by combining region growing segmentation and *geographic object-based image analysis* (GEOBIA) for classification. Although highly effective, the approach demands much parameter setting and experience and is not especially dedicated to the problem of tree crown detection. Other more specific approaches have been applied to the problem and seemed more appropriate.

Marked Point Processes (MPP) are mathematical concepts useful for describing phenomena occurring at random location or time.<sup>13</sup> MPP has already received attention for the recognition of objects \* in VHR satellite images.<sup>9,13-17</sup> In particular, the ARIANA project from the INRIA (Université Nice - Sophia Antipolis, France), have developed a number of algorithms for detecting different objects (*e.g.* buildings, tree crowns and flamingos) in VHR images. Among these studies, Ref. 14 and 9, use MPP for the specific extraction of trees. Both these studies used flat marks (circles or ellipses) with a single brightness value and tested their approaches mainly in very homogeneous forests or plantations usually exempt of other objects (like buildings or streets). The best performance was obtained for planted forests as confirmed by the study of Ref. 15.

These studies have triggered our attention and made us consider that MPP could benefit from using marks modelled from 3D objects but differently from what proposed Ref. 9. We propose to use a geometrical-optical tree model in a manner resembling that of template matching (TM) that uses some form of correlation between image and model to identify candidate pixels. A MPP using a geometrical optical 3D model and measurements of correlation or other spectral characteristics to seek tree crowns could represent a significant improvement to using simpler marks. Considering such a hypothesis, this article presents an algorithm for tree crown detection that combines elements from MPP, TM and tree crown geometrical-optical modelling for the automatic detection and (simplified) delineation of trees in VHR satellite imagery.

## 2. METHODOLOGY

### 2.1 Remote sensing data

A WorldView-2 (WV-2) image of the campus of the *Universidade Federal de Minas Gerais* (and surroundings) in Belo Horizonte, Brazil, was acquired as our primary test data. Although WV-2 offers nine different spectral bands, only the panchromatic band ( $\lambda \approx 450 - 800nm$ ) with a ground resolution of 50 cm was used at this stage since all other bands have a ground resolution of 2 m. Another WV-1 image from the Diamantina region (also in Minas Gerais) was used as a secondary test site for being less accessible and therefore more difficult to validate. The latter had a very noisy aspect and we applied a gaussian filter to reduce it. The Figure 1 shows the four portions selected from the WV images.

---

\*The Mark in MPP represents the object being sought.




Figure 1. Sub-images selected from the WV-2 image: sub-image 1 (a), 2 (b) and 4 (d). And from WV-1 image: sub-image 3 (c).

## 2.2 Experimental design

All developments were programmed with Python 2.7 using some routine libraries from third parties (Numpy, Scipy, Matplotlib). We have named our algorithm PPMG3D (from the portuguese “*Processo Pontual com Modelo Geométrico 3D*”) which handles both the creation of the geometrical-optical model and the tree crown detection routine that borrowed concepts from MPP and TM approaches.

In our approach the TM did not scan the whole image like it was initially conceived but rather uses a MPP approach to select random locations within the image. Additionally, the marks (the 3D models in our case) receive a random diameter between a predetermined range depending on the type of environment. The geometrical-optical model includes both the sunlit and shaded areas of the crown and a portion of the projected shadow to allow a better match between model and image. Some statistical and spectral parameters were also included in the model matching phase.

MPP-based algorithm for pattern recognition usually alternate between phases of birth and death during which objects are created (placed) and destroyed when they do not comply with the matching rules. This is also a characteristic of PPMG3D but we have somewhat deviated from the original concept in which the destruction phase also incorporates a random factor.

### 2.2.1 3D Model

The parameters that determine the radiance pattern of a tree crown are: direct and indirect radiation, shape of tree, branch pattern, leaf reflectance, multiple reflectance within the canopy, etc.<sup>18</sup> In creating a valid 3D geometrical-optical model we have chosen a simplified version in which the crown is represented by a dome of varying skewness, a lambertian reflectance model with ambient light and a projected shadow on the ground (optionally on another tree). Equation 1 gives the formulation of our model in which each pixel is treated as a singular surface.

$$\cos(\theta_i)_m = \{ \cos(\theta_s)\cos(\theta_n) + \sin(\theta_s)\sin(\theta_n)\cos(\phi_s - \phi_n) \} + amb \quad (1)$$

Where  $\theta_s$  is the solar elevation angle,  $\theta_n$  is the slope of the object surface,  $\phi_s$  is the solar azimuth,  $\phi_n$  is the aspect of the object surface and  $amb$  represents the diffuse ambient lighting.

The geometrical-optical model is adjusted according to the specific illumination parameters of the image and the size of the trees present on the scene. Figure 2 shows two examples of tree models with similar reflectance but different solar elevations.

A parameter of projected shadow clipping has also been added to account for the fact that it was not beneficial to use the whole shadow in situations where it was projected onto another tree and not on the ground. The height of the tree also affects the size of the shadow so that it did not appear wise to set the height to a fixed value. To illustrate this, Figure 3 shows a comparison between the tree model and an actual tree from the image both with whole and clipped shadows.




Figure 2. Illustration of the geometrical-optical model of tree crown as seen in two different solar elevation angles: (a) 20 and (b) 45.




Figure 3. Comparison between an isolated tree from the (a) WorldView-2 image and (b) the geometrical-optical 3D model. A clipping factor of about 80% was applied to the same images in (c) and (d) to enable to use only a portion of the shadow in cases where that shadow is not projected on the ground but on another object.

### 2.2.2 The PPMG3D Algorithm

According to Ref. 14, using MPP to extract objects consists in searching for the “best” possible object configuration in a scene, the one that will respect a certain number of properties both of the objects being sought and the radiometric properties of the image. In our algorithm, the “best” configuration be it geometric or radiometric are given by the model.

The process consists in alternating phases of birth and death. The MPP starts with a birth phase during which tree crowns represented by circles of varying size (a randomized interval) are inserted on a matrix of equal size to the image being processed. Tree crowns are only inserted where no other crowns are present. Once all the circles have been inserted (determined by a density parameter  $N_c$ ), a similarity ( $Sm$ ) value between the image and a version of the model fitted on each circle is computed and stored in a table along with the parameters of the model. A routine then sorts the table by decreasing values of  $Sm$ . During the death phase, the circles that do not comply with the acceptance restrictions ( $Sm$ ) are successively deleted from the matrix and the table. At the end of each death phase, the overall parameters of the pixel distribution of the remaining crowns are updated. The crowns that have been found are definitively kept but are re-thrown in the bundle of crowns of the next iterations. If after an iteration 10 crowns are kept out of 100, then the next iteration will randomly place 90 more crowns and the new set of 100 crowns are evaluated and sorted for the next iteration. All tree crowns are considered “found” when one of three possibilities is encountered: 1) the number of trees found is equal to the number given by the density parameter, 2) one of the interruption criteria has been attained or 3) the maximum number of iteration has been reached.

The  $Sm$  value is computed as the subtraction of two parameters: cross-correlation and the normalized absolute difference as defined by the following relation (Eq. 2):

$$Sm = \gamma - \alpha ND \quad (2)$$

where  $\gamma$  is the cross-correlation between image and model,  $ND$  is the normalized sum of absolute differences between them and  $\alpha$  is a constant weight factor (normally  $\approx 0.1$ ). The cross-correlation and absolute difference are calculated as follows (Eqs. 3 and 4).

$$\gamma(x, y) = \frac{\sum_i \sum_j [w_{(i,j)} - \bar{w}] \sum_i \sum_j [f_{(i,j)} - \bar{f}]}{\{\sum_i \sum_j [w_{(i,j)} - \bar{w}]^2 \sum_i \sum_j [f_{(i,j)} - \bar{f}]^2\}^{1/2}} \quad (3)$$

In Eq. 3, the cross-correlation is calculated between the model matrix ( $w_{i,j}$ ) and the portion of the image that corresponds to the circle of same radius ( $f_{i,j}$ ). In other words, two matrices of same dimensions are always compared. The  $\bar{w}$  and  $\bar{f}$  are their respective means. Values of  $\gamma$  range between  $-1$  and  $1$ . The same logic is used in Eq. 4 which computes a normalized difference value between the same two matrices.




Figure 4. Illustration of the birth (a), and death (b) phases of the PPMG3D algorithm. In this example, of the 163 randomly positioned crowns, only one had a similarity value larger than the threshold of 0.98.

$$ND = \left| \frac{\sum \omega - \sum f}{\sum \omega + \sum f} \right| \quad (4)$$

In the death phase, tree crowns are kept if their similarity is larger or equal to a preset threshold. Because we found that such a threshold represented a weak element in our algorithm, we implemented a strategy by which it need not be pre-determined with a fixed value but rather adjusts itself as the number of iterations grow. The threshold is set very high at the beginning but then starts to decay when a certain number of iterations do not find any “new” tree crown (typically 100 iterations). Additionally, if more than a certain amount of iterations (say 1000) still does not add any new tree crown, then the process is stopped. Ultimately it will be stopped if the maximum number of iterations is reached.

Figure 4 (a) shows the state of the crown matrix after a single birth phase with 163 circles of random radius (between 3 and  $15m$ ), and randomly located within the image matrix. After the death phase, using a similarity threshold of 0.98 only one tree crown was kept (b).

The following two frames synthesize the processes of birth and death in PPMG3D.

#### Birth Phase

1. Input parameters:  $N_c$ ; tree models catalogue with radius between  $r_{min}$  and  $r_{max}$ ; Image
2. While tree count  $< N_c$ :
  - (a) Randomly pick radius  $r$  within model catalogue
  - (b) Randomly pick  $i$  and  $j$  coordinates within the image space
  - (c) Check if crown is already present
  - (d) If not:
    - i. Fill area with circle of radius  $r$
    - ii. Extract corresponding area in the image matrix
    - iii. Compare image and model matrices
    - iv. Calculate and store values:  $i, j, \mu, \sigma, Sm$



### Death Phase

1. Input parameters: birth image matrix; crown statistics ( $Sm$  sorted);  $Sm$  threshold; tree models catalogue with radius between  $r_{min}$  and  $r_{max}$
2. While  $Sm_{crown} < Sm_{threshold}$  :
  - (a) Zero crown pixels in birth image matrix
  - (b) update object and global statistics
  - (c) Update number of crowns eliminated for next birth phase

### 2.2.3 Accuracy

To assess the quality of the results produced by PPMG3D two basic approaches were taken. First we tested the approach on a set of five synthetic images simulating various controlled situations then we tested the algorithm on a series of sub-images extracted from the two WV scenes. We had full control of the quantity and size of all the trees in the synthetic images so that we had full validation data. For the WV images, validation was done by comparing our results with a visual interpretation of the trees in the image. For these, only tree counting was used as validation. For the crown counting validation we considered the following situations: 1) true positive (TP) for found trees, 2) false positive (FP), when a detected object is not a tree and 3) false negative (FN) for trees not encountered. The success score was computed as follows (Eq. 5):

$$A_g = \left( \frac{TP - FN}{N + FP} \right) * 100 \quad (5)$$

where  $N$  is the total number of trees.

The evaluation of the differences between the circle diameters and the actual size of the trees in the synthetic images was done by using a contingency table between binary versions of the original synthetic images and the resulting PPMG3D image in the manner displayed in Table 1.

From this matrix were derived the overall accuracy (Eq. 6), omission errors (Eq. 7) and comission errors (Eq. 8).

$$Oac = \frac{TP}{TP + FP} \quad (6)$$

$$Omission = \frac{TP}{TP + FP} \quad (7)$$

$$Comission = \frac{TP}{TP + FN} \quad (8)$$

Table 1. Contingency matrix used to compute crown size accuracy.

PPMG3D	Original image	
	Tree	Non-tree
Tree	TP	FN
Non-tree	FP	TN

Table 2. Parameters used to create the synthetic image to test the performance of PPMG3D.

Image	Minimum radius	Maximum radius	Density (tree/ha)	Number of trees
1	8.5	10.5	3.88	35
2	5.5	20.5	6.11	55
3	8.5	11.5	6.77	61
4	3.5	15.5	13.88	125
5	4.5	12.5	19.22	173




Figure 5. Synthetic image set created to test the performance of PPMG3D. By order of increasing density: image 1 (a), image 2 (b), image 3 (c), image 4 (d) e image 5 (e).

#### 2.2.4 Synthetic Images

Using the same approach as the PPMG3D program, five synthetic images were created to test the algorithm. Tree models were used to create “forest” images with different density parameters. The parameters used to create the images are described in Table 2 and the images themselves are presented in Figure 5. To increase the level of difficulty, a Gaussian noise of 0.4 was added.

### 3. RESULTS AND DISCUSSION

Table 3 shows the results obtained with the five synthetic images both for the detection and delineation of trees. The overall rate of success for the detection was superior to 90% in the five cases and not one false positive was detected. The program performed better with lower density images (*images 1, 2 and 3*) where 100% of the trees were detected. In the two images of higher density the program missed mostly trees of small radius, some of which lay in the shade of other larger trees. We argue that with a greater radius range, the probability of finding small trees decreases for two reasons. Firstly because the number of possible locations increases and secondly because although smaller model may still appear to “fit” onto larger trees (where the apex still shows a sunlit and a shaded side), the opposite is not likely to occur since a large tree model over a small tree will incorporate portions of ground or other objects that will decrease the cross-correlation.

To validate the delineation, we computed a confusion matrix of the individual pixels divided in three categories: correctly identified (success), not identified (omission errors) and identified but not belonging to the tree (commission errors). The overall accuracy ranged between 69.9% and 82%. Again, the best results were obtained with *image 1* being the image with the smallest range of tree radius and the lowest density (Figure 6). The worse result (69.9%) was achieved with *image 4*, the most complex case with radius range variation of 12 m and a high tree density (Figure 7). Omission errors tended to be more frequent since small tree models can have a high similarity with larger trees on which they were sometimes fitted.

Figures 6 and 7 (b) e (c) show the overall values of similarity and standard deviation computed at the end of each birth phase. Being a stochastic process by nature, few objects are found initially but the chances of finding them increase as the image is progressively occupied by found trees and this is why the overall similarity increases. The standard deviation also increases initially and then stabilizes. The increase is due to the fact that

Table 3. Results obtained by the PPMG3D algorithm for the detection and delineation of tree crowns in the five synthetic images. The top values on the right panel are in pixels and the bottom italic represent the overall success.

Image	Trees	True positive	False positive	Overall success	Accuracy of delineation	Commision errors	Omission errors
1	35	35	0	100%	8624 <i>82.04%</i>	1035 <i>9.85%</i>	1888 <i>17.96%</i>
2	55	55	0	100%	12141 <i>70.07%</i>	1194 <i>6.89%</i>	5184 <i>29.92%</i>
3	61	61	0	100%	13649 <i>75.91%</i>	664 <i>3.69%</i>	4331 <i>24.08%</i>
4	125	119	0	95.2%	12084 <i>69.89%</i>	903 <i>5.22%</i>	5206 <i>30.10%</i>
5	173	165	0	95.37%	13747 <i>70.66%</i>	2278 <i>11.7%</i>	5707 <i>29.33%</i>




Figure 6. PPMG3D results obtained with synthetic *image 1* (a) and graphs of global similarity (b) and standard deviation (c) for each of the 2.200 iterations.




Figure 7. PPMG3D results obtained with synthetic *image 4* (a) and graphs of global similarity (b) and standard deviation (c) for each of the 2.200 iterations.

the trees have both a sunlit and a shaded face (as well as a shadow) with very different radiance values. This is also the strength of the approach that does not look for homogeneous objects. This peculiar appearance of the tree model can cause small models to fit well over large trees if the sunlit and shaded parts match but the opposite is unlikely since large model fitted over small trees will present low similarity because of the ground another objects that would enter the area of the model.

All tests were done purposely overestimating the tree density but PPMG3D was able to stop the iterations automatically after a preset number of iterations without finding any “new trees”. This is also a strength of PPMG3D since the user does not need to know the exact density of trees but should always overestimate it to make sure all trees are found.

PPMG3D is an ongoing research and little effort has been invested in optimizing the program. Processing times varied between 15 and 55 min and the number of iteration necessary between 1550 e 6831 depending on tree density. The synthetic images were all  $512 \times 512$ . We expect to be able to significantly reduce the processing time by optimizing the program.

### 3.1 WV Images

Four WV sub-images were selected to submit PPMG3D to a realistic context. These images had very different contexts with both isolated and grouped trees and with different objects present in the scene. A wide variety of radius is also present in these images. The first two images (Figure 8a and 8b) are from the university campus (UFMG), the third is a savanna area near Diamantina (Figure 8c) and the last is from a park (Figure 8d). All four are shown below with their respective overall similarity and standard deviation graphs. The validation results are presented in Table 4.


In two images of the campus, the program was able to find 69% and 95% of the trees respectively with very few errors with isolated trees (Figure 8a and b). The presence of other objects (buildings, streets and sidewalks) did not hinder the identification of trees and few false positives (3 and 8 respectively) were found. In both images PPMG3D was able to find most grouped trees and the crown size was often erroneous. Some cases are even difficult to correctly identify and delineate visually. Mostly, the errors were dividing a single crown in two, or including two different crowns in a single object.

The *WV image 3* is from a savanna area with a large variety of tree crown size, shape and reflectance. Even with these additional difficulties, an overall success rate of 65.38% was attained. The *WV image 4* is from a protected park area with predominantly isolated trees and relatively homogeneous crown size of about 6 m (Figura 8d). A total of 161 objects were detected with only five false positives and 20 false negatives for an overall success of 78.33%. Although most deciduous trees were selected, the crown size was often incorrect but given the highly irregular shape of many of these trees, this was somewhat expected and similar problems have been reported by Ref. 7.


The behavior of the overall similarity during the iterations is somewhat similar to that observed with the synthetic images. The standard deviation however is very different for each image and is mostly related to the amount of contrast in the original image. Images with highly contrasting objects (*e.g.* building tops) will tend to show a progressively decreasing standard deviation. Images of low contrast will tend to see it increasing as the trees are progressively added because of the double illumination nature of the trees.

Table 4. Validation of the PPMG3D results with the four WV images.


<b>Image</b>	Number of Trees	Trees Detected	False Positive	False Negative	Overall Accuracy
WV image 1	47	43	3	8	68.62%
WV image 2	50	59	8	5	94.82%
WV image 3	52	41	0	7	65.38%
WV image 4	175	161	5	20	78.33%




(a) WV image 1



(b) WV image 2



(c) WV image 3



(d) WV image 4

Figure 8. PPMG3D results obtained with the four synthetic *WV image 1 - 4* (left) and their graphs of global similarity (center) and standard deviation (right). The red circles correspond to correctly identified trees (true positive or TP), the object marked with a yellow “A” are false negative (FN) and the objects marked with a yellow “C” are false positives (FP).

## 4. CONCLUSION

The detection of individual tree crown in images of very high resolution is a growing and challenging field of research within the remote sensing community. Although many object-based techniques have been developed, few offer specific applications to extract trees.

In this article we describe the concepts and implementation of a novel approach based on two mathematical/pattern recognition concepts integrated to improve performance. PPMG3D was developed based on concepts from marked point processes and template matching for the former to take advantage of a complex geometrical-optical model as mark.

PPMG3D was highly effective in finding and extracting tree crowns from noisy synthetic images having a variety of tree sizes with a success rate of 95% and more. With real images from the WorldView satellite (ground resolution of 50 cm) a total of 304 trees out of 324 were found (94%) and even taking false positive into account a success rate of 89% was still achieved. The PPMG3D also delineates the tree crowns by fitting a circle on them. In this case the average accuracy dropped to 72.1% considering only the synthetic images. This validation was not done yet for the real WV images since this would require field work to be accurate.

We foresee further developments in PPMG3D to concentrate on improving computing efficiency and on improving the estimation of the crown size.

## ACKNOWLEDGMENTS

The authors wish to acknowledge the support of Geosciences Institute of the UFMG for their financial support to allow this work to be presented at the SPIE Remote Sensing 2014 conference. We would also like to thank Professor Dr. Marcelo Fagundes (Faculdade Intercisciplinar em Humanidades da Universidade Federal dos Vales do Jequitinhonha e Mucuri - FIH/UFVJM) for kindly providing the WV-1 imagery used in this study.

## REFERENCES

- [1] J. Östeberg, T. Delshammar, B. Wiström, and A. B. Nielsen, "Grading of parameters for urban tree inventories by city officials, arborists, and academics using the Delphi method," *Environmental Management* **51**, p. 694–708, 2013.
- [2] H. Sander, S. Polasky, and R. G. Haight, "The value of urban tree cover: A hedonic property price model in Ramsey and Dakota Counties, Minnesota, USA," *Ecological Economics* **69**, p. 16461656, 2010.
- [3] Brasil, *Florestas do Brasil em resumo*, Ministério do Meio Ambiente, Servio Florestal Brasileiro, 2009.
- [4] A. L. B. S. S. L. Almeida, *O valor das árvores: árvores e floresta urbana de Lisboa*. PhD thesis, Instituto Superior de Agronomia, Lisboa, 2006.
- [5] R. Pu and S. Landry, "A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species," *Remote Sensing of Environment* **124**, pp. 516–533, 2012.
- [6] M. G. Andreu, M. H. Friedman, S. M. Landry, and R. J. Northrop, "City of tampa urban ecological analysis 2006-2007," *Final Report to the City of Tampa* **24**, 2008.
- [7] Y. Ke and L. J. Quackenbush, "A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing," *International Journal of Remote Sensing* **32**, pp. 4725–4747, 2011.
- [8] G. Shao and K. M. Reynolds, "Computer applications in sustainable forest management: Including perspectives on collaboration and integration," 2006.
- [9] G. Perrin, *Etude du couvert forestier par processus ponctuels marqués*. PhD thesis, Ecole Centrale Paris, 2006.
- [10] M. Erickson, *Segmentation and Classification of Individual Tree Crowns in High Spatial Resolution Aerial Images*. PhD thesis, Swedish University of Agricultural Sciences, Uppsala, October 2004.
- [11] F. A. Gougeon and D. G. Leckie, *Forest information extraction from high spatial resolution images using an individual tree crown approach*, 2003.

- [12] M. F. Gomes and P. Maillard, "Identification of urban tree crown in a tropical environment using worldview-2 data: problems and perspectives," in *SPIE Remote Sensing*, pp. 88930C–88930C, International Society for Optics and Photonics, 2013.
- [13] X. Descombes, *Méthodes stochastiques en analyse d'image: des champs de Markov aux processus ponctuels marqués*. PhD thesis, Université de Nice Sophia-Antipolis, 2004.
- [14] J. Zhou, *Application de l'identification d'objets sur images à l'étude de canopées de peuplements forestiers tropicaux: cas des plantations d'Eucalyptus et des mangroves*. PhD thesis, Université Montpellier II-Sciences et Techniques du Languedoc, 2012.
- [15] M. Larsen, M. Eriksson, X. Descombes, G. Perrin, T. Brandtberg, and F. Gougeon, "Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions," *International Journal of Remote Sensing* **32(20)**, p. 58275852, 2011.
- [16] M. Ortner, *Processus ponctuels marqués pour l'extraction automatique de caricatures de bâtiments à partir de modèles numériques d'élévation*. PhD thesis, Université de Nice Sophia-Antipolis, 2004.
- [17] A. Baddeley and M. V. Lieshout, "Stochastic geometry models in high-level vision," *Journal of Applied Statistics* **20(5-6)**, pp. 231–256, 1993.
- [18] B. St-Onge, *L'apport de la texture des images numériques de haute résolution à la cartographie forestière automatisée*. PhD thesis, Université de Montréal, 1994.

# Identification of urban tree crown in a tropical environment using WorldView-2 data: problems and perspectives

Marília Ferreira Gomes<sup>a</sup> and Philippe Maillard<sup>a,b</sup>

<sup>a</sup>Universidade Federal de Minas Gerais (UFMG), Av. Antônio Carlos, 6627, Belo Horizonte, Brazil;

<sup>b</sup>Laboratoire d'Études en Géophysique et Océanographie Spatiales (LEGOS), 18 av. Edouard Belin, Toulouse, France

## ABSTRACT

With the availability of high-resolution satellite data, much research has been focused on the automatic detection and classification of individual tree crowns. Most of these studies were applied to temperate climates of the northern hemisphere, especially for forests of coniferous. Very few studies have been applied to the detection of trees in the tropical regions, least of all in the urban environment. Urban trees play a major role in maintaining or even improving the quality of life in cities by their contribution to the quality of the air, by absorbing rain water, by refreshing the air through transpiration and providing shadow. In this study we explored the potential of high-resolution WorldView-2 satellite data for the identification of urban individual tree crowns in the city of Belo Horizonte, Minas Gerais, Brazil, through an object-oriented approach. Irrelevant areas were masked (e.g. buildings, asphalt, shadows, exposed soil) using a threshold of NDVI. Three different approaches were tested to isolate and delineate individual tree crowns: region growing, watershed and template matching. For the first two approaches several parameters were tested to find the best result for the isolation of the individual tree crowns. An in-house program has been developed for template matching using a set of seven different templates of different species. A set of 300 individual tree crowns were visually interpreted in the WorldView-2 image to serve as validation and to compare the performance of the three different approaches. Then, the comparison was performed between the visual interpretation and the results of each approach by calculating the difference between the areas as a ratio of the validated area. Our results show that the region growing approach provided the best results, with an accuracy of over 80%.

**Keywords:** Urban tree crown, WorldView-2, OBIA, Region growing, Watershed, Template matching

## 1. INTRODUCTION

Urban trees play an important role for the welfare of people and quality of life in cities. They contribute to improving air and water quality, mitigate the carbon dioxide and other pollutants, moderate the microclimate and air temperature, help control soil erosion, reduce the flow of rainwater and provide biodiversity.<sup>1-3</sup> A good knowledge of the species planted in cities and their health allows to enhance the understanding of their role, besides contributing with the inventory, and management of these trees. To fulfill their role in the urban environment, trees need to be looked after throughout maintenance practices like pruning and this includes acquiring various structural parameters of trees. Because field survey techniques are time-consuming, expensive and usually cannot provide complete coverage of large areas, it is worthwhile to carry surveys using aerial methods.<sup>4</sup>

Remote sensing is a cost effective way to extract information about vegetation and, with the increasing availability of high spatial resolution data and computational power to process it, research in forestry has been focusing more on the identification and delineation of individual tree crowns.<sup>5,6</sup> But with increased spatial resolution new forms of information extraction were necessary. One approach is based on the object-oriented

---

Further author information: (Send correspondence to Marília Ferreira Gomes)

M. F. Gomes: E-mail: mariliafgomes@yahoo.com, Telephone: +55 (31) 92 35 06 17

P. Maillard: E-mail: philippe@ufmg.br, Telephone: +33 (0)1 98 76 54 32

Earth Resources and Environmental Remote Sensing/GIS Applications IV, edited by Ulrich Michel, Daniel L. Civco, Karsten Schulz, Manfred Ehlers, Konstantinos G. Nikolakopoulos, Proc. of SPIE Vol. 8893, 88930C · © 2013 SPIE · CCC code: 0277-786X/13/\$18 · doi: 10.1117/12.2029073

Proc. of SPIE Vol. 8893 88930C-1



paradigm, which has the advantage of dealing with groups of pixels instead of isolated pixels like other more traditional classification methods. In working with regions, parameters like size, shape, texture and even the relations between neighboring objects can also be used as descriptors to help classification schemes.<sup>7</sup>

Researchers have developed several automatic and semi-automatic methods for the extraction of individual trees and their characteristics using digital aerial photographs of various types and in high spatial resolution satellite images.<sup>5</sup> Ke and Quackenbush<sup>6</sup> made a review of methods for automatic individual tree-crown detection and delineation methods from passive remote sensing and describe the main algorithms for their identification (local maximum filtering, image binarization, scale analysis and template matching) and their delineation (valley-following, region-growing and watershed-segmentation). However, for all the methods described, most of the studies were applied to temperate climates of the northern hemisphere, especially for forests of coniferous or mixed forests. Very few studies have been applied to the detection of trees in the tropical regions, least of all in the urban environment. In their review<sup>6</sup> the authors found only two studies in tropical environments, both conducted in Australia. In addition to the studies identified by,<sup>6</sup> we have identified only two other studies in tropical environments: 1) Gomes *et al.*<sup>8</sup> that conducted a study of segmentation and classification of forest canopy using Quickbird images in an ecological station in the State of São Paulo, Brazil; and 2) Arasato *et al.*<sup>9</sup> who worked with Palm trees in the Brazilian Amazon. For this reason, many methods were developed based on the characteristics of forests of temperate environments on the assumption that tree crowns having a conical shape and appearing as circular shapes in two-dimensional imagery, with the treetops having the strongest reflectance within the crown area.<sup>6</sup> However, these assumptions are not widely valid for tropical trees, in view of high species richness and the great complexity of crown shapes that cannot be simplified by the conical format. Considering that there are few studies of trees in tropical environments, the same is true for studies of trees in urban environments. Pu and Landry<sup>4</sup> used IKONOS and WorldView-2 for mapping seven urban tree species/groups in the city of Tampa, Florida, jointly with advanced classifiers and an OBIA (Object-Based Image Analysis) approach, and achieved high accuracy for the identification of species, with values between 90 and 100%, and observed that WV-2 has a greater capability for identifying and mapping tree species/groups when compared to IKONOS. Ardila<sup>10</sup> used very high resolution (VHR) imagery and OBIA for mapping and monitoring urban trees in residential areas in the Netherlands, with emphasis to the identification of trees near streets and parks and found low commission and omission errors for tree identification, especially for group of trees and for trees larger than  $> 5m^2$  with a good quality of crown boundary and achieved an overall delineation error  $< 0.24$ . Zhang and Hu<sup>11</sup> analysed longitudinal profiles from VHR images to improve the classification of individual tree species on the York University campus, Ontario, Canada, and found classification accuracy greater than 84%. Cavayas *et al.*<sup>12</sup> examined the feasibility of using WV-2 data for mapping urban vegetation cover in the city of Laval, Quebec, Canada, and the experiments showed that a system for automatic inventory of vegetation cover in urban areas is possible.

In view of all the different approaches possible, the objective of this article is to explore the potential of high resolution WV-2 satellite data for the detection and delineation of individual trees in and around a university campus in the city of Belo Horizonte, Brazil. In doing so we want to test and compare the performance of three different approaches: template matching, region growing and watershed.

## 2. METHODOLOGY

### 2.1 Study area

The Campus of the Federal University of Minas Gerais (UFMG) (Figure 1) in Belo Horizonte, Brazil, was chosen to test the potential of WV-2 data for detection and delineation of crowns of individual trees in an urban environment. The study area is inserted into a tropical climate of altitude, with average temperatures of 20 °C and an average precipitation of about 1200 mm per year. The Campus occupies an area of 334 hectares, partially covered by forest fragments of cerrado and seasonal semi-deciduous forest, as well as planted woodland individual trees alongside roads and parking lots.<sup>13</sup>

Lombardi and Morais<sup>14</sup> performed an extensive sampling of cultivated tree on the Campus of the UFMG and identified a high species richness of 187 species, distributed in 52 families, native and exotic originating from different parts of the world (Asia, Africa, North America, Central America, South America and Oceania).




Figure 1. Location of the study area. The image on the right is a WorldView-2 false color composite.

In the study area trees occur in different contexts: planted along the streets, in the gardens of the buildings, parking lots and forests. Depending on their location, nearby objects are identified as grass, asphalt, concrete or other trees. Single trees, pairs of trees and groups of trees intertwined are all observed indiscriminately. As the variation of species and contexts is high, the size and the distance between crowns also varies. Only the trees planted on public roads, parks and gardens were evaluated.

## 2.2 Remote sensing data

A WorldView-2 satellite image (DigitalGlobe, Inc., USA), acquired in July 28, 2012 was used for this study. The image had a radiometric resolution of 11 bits but was further reduced to 8 bits. The data comes in nine spectral bands: one panchromatic band (450-800 nm) with a spatial resolution of 50 cm, and eight multispectral bands [Coastal (400-450 nm), Blue (450-510 nm), Green (510-580 nm), Yellow (585-625 nm), Red (630 nm -690), Red Edge (705-745 nm), Near-IR1 (770-895 nm) and Near-IR2 (860-1040 nm)] with spatial resolution of 2 m.<sup>15</sup> The image was already orthorectified to a UTM projection (WGS84 Datum, 23S Zone) and radiometrically corrected by DIGITALGLOBE. The scene was acquired at 10:30 local time, with a average off nadir view angle of 13 degrees.

## 2.3 Detection and delineation of the tree crowns

The first problem is the detection of the tree crown, the second is the delineation and the third is the classification according to the species. This paper addresses only the first two problems, the identification and delineation of the tree crown. All three methods have been tested and evaluated for detection tree crowns. Only region growing and watershed were tested for delineation and classification was used as a means of comparison of the results. The panchromatic band was used as the starting point for all methods in order to take advantage of its higher spatial resolution.

**Template Matching** Template matching is an algorithmic approach to pattern recognition, which allows comparison of the every pixel in an image with a previously stored model. One approach consists in calculating a measure of correlation between the image and the model.<sup>16</sup> This approach was used as a means of detection of

tree crowns. An in-house program was developed in Python 2.7 to perform template matching between any small image (the template) and a gray scale image of any size. Each template is sequentially moved across the image, in a manner similar to a convolution filter, and the statistical correlation is computed at each location.<sup>17</sup> Faced with the impossibility of evaluating all the different species in the study area, seven tree species, considered to be of higher occurrence, were chosen to be analyzed: *Mangifera indica*, *Terminalia catappa* L., *Spathodea campanulata* P.Beauv., *Licania tomentosa* (Benth.) Fritsch, *Samanea tubulosa* (Bentham), *Caesalpinia pluviosa* var. *peltophoroides* and *Pachira aquatica* Aubl. Of these, three species are exotic and four are native. Figure 2 gives the classification of the tree species and shows a ground perspective photograph as well as top views of the crown from the WV-2 panchromatic band and from an aerial photograph with a spatial resolution of 10 cm. The template's size varies with the tree crown size. Correlation is computed using Equation 1:

$$C = \frac{\sum(x_{ij} - \bar{x})(y_{ij} - \bar{y})}{\sqrt{\sum(x_{ij} - \bar{x})^2 \sum(y_{ij} - \bar{y})^2}} \quad (1)$$

where  $x_{ij}$  is the intensity for the pixel at the  $i^{th}$  row and  $j^{th}$  column in the template;  $\bar{x}$  the mean intensity for the template,  $y_{ij}$  is the intensity for the corresponding pixel in the image window, and  $\bar{y}$  the mean intensity for the corresponding image window.

An output image is derived by calculating the correlation between each template and the image. The areas that have the largest correlation values, also have the largest output values in the resulting image and correspond to the locations with the highest probability of being a tree crown. In total seven images were generated, one for each template. Then, for each image, a threshold was set, with the goal of preserving only the values of greater correlation between the model and the image. The resulting raster data was converted to a vector format and the centroid of each polygon was extracted in order to identify just one point by tree crown (optimally its center).

**Region Growing** Initially, the region growing algorithm segments the image using a seed pixel then, neighbouring pixels are examined and added to the region, if they are sufficiently similar to the seed pixel. The statistics of the region are updated with each pixel added. In this paper we used the multiresolution segmentation implemented in eCognition Developer 8.7 software (© 2010, Definiens AG) to create segments (image objects). This algorithm is based on adjustable criteria of homogeneity or spatial and spectral heterogeneity.<sup>18</sup> A multilevel segmentation was performed to account for the different sizes of objects both trees and others. In this scheme, a series of segmentations are overlaid, each with a successively smaller scale parameter for identifying successively smaller objects.<sup>19</sup> To improve the performance of the segmenter, object based image analysis (OBIA) was also used in the rule-based classification: geometry, texture, neighborly relations, spectral characteristics and fuzzy membership functions.

The definition of the rule set is divided in four steps, consisting of four hierarchical levels of image object network: 1) separation of vegetation and non-vegetation, 2) separation of the grass, 3) identification of isolated trees, 4) separation of tree clusters. For all segmentations performed, only the scale parameter was changed while keeping shape (0.3) and compactness (0.7) unchanged (Figure 3). The first segmentation was performed to separate non-vegetation (buildings, water, asphalt, concrete, exposed soil, roofs and some shades), with a scale parameter of 10. An Normalized Difference Vegetation Index (NDVI) threshold  $\leq 0.19$  was defined to classify non-vegetation.

In the second level only unclassified objects (all vegetation theoretically) are used to separate the grass from the trees, which have very similar spectral response. The grass objects are found at two different scales, so two segmentations were made at this stage: the first one with a scale factor of 80, in order to separate the larger lawns, and a second with scale factor 20 to separate smaller areas. The class definition used a NDVI threshold of  $\leq 0.30$  and of grey level co-occurrence matrix (GLCM) homogeneity of  $\geq 0.62$ .<sup>20</sup> For smaller grass patches a NDVI threshold ( $\leq 0.35$ ) was used jointly used with a membership functions (NIR1, red and green).

The third level was used to classify the isolate tree crowns, surrounded by grass or non-vegetation. First, small trees misclassified as grass were classified based on relative border with non-vegetation ( $\geq 0.3$ ) and the elliptical form ( $\geq 0.64$ ). Areas larger than 500 pixels and a length/width relationship of  $\geq 1.7$  were returned to














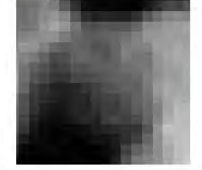
Popular Name / Family / Specie / Origin	Photo	Crown in WV-2	Crown in Aerial Survey
Mango ANACARDIACEAE <i>Mangifera indica</i> Exotic India			
Tropical Almond COMBRETACEAE <i>Terminalia catappa</i> L. Exotic Malaysia			
African Tulip Tree BIGNONIACEAE <i>Spathodea campanulata</i> P.Beauv. Exotic Africa			
Oiti CHRYSOBALANACEAE <i>Licania tomentosa</i> (Benth.) Fritsch Native			
Sete Cascas MIMOSACEAE <i>Samanea tubulosa</i> (Bentham) Native			
Sibipiruna CAESALPINIACEAE <i>Caesalpinia pluviosa</i> var. <i>peltophoroides</i> Nativa			
Munguba (Guiana-chestnut) BOMBACACEAE <i>Pachira aquatica</i> Aubl. Native			

Figure 2. Classification of the trees species evaluated. For each tree there is ground view, a top view from the WV-2 panchromatic band and from an aerial photograph with a spatial resolution of 10 cm.

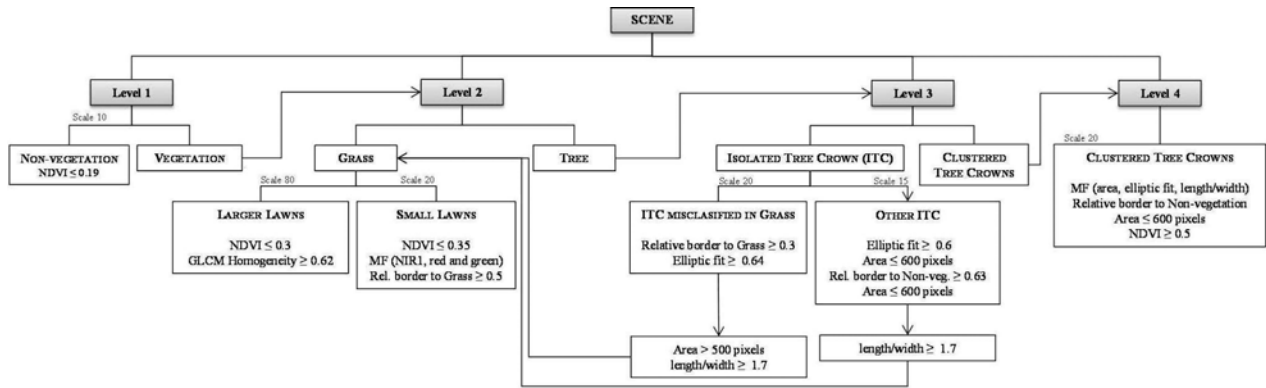


Figure 3. Flow diagram showing the four steps used in the multiresolution region growing approach for detecting and delineating urban trees on the UFMG campus.

the grass class. A new segmentation was performed with scale parameter 15. Regions with an elliptical shape  $\geq 0.6$ ) and an area  $\leq 600$  pixels were reclassified as trees. Objects with relative border to non-vegetation in  $\geq 0.63$  and an area less than 600 pixels were classified as isolated tree crowns. To remove the mislabeled crowns, a length/width  $\geq 1.7$  was used.

The last level was used to separate the crowns clustered. Unclassified objects were segmented with a scale parameter of 20. Membership functions area ( $\leq 700$  pixels), elliptic fit ( $\geq 0.6$ ) and length/width ( $\geq 1.3$ ) was used to classify the crowns. Relative border to non-vegetation and size of objects ( $\leq 600$  pixels) served to select small groups composed of two or three trees. Finally, the remaining objects with  $\text{NDVI} \geq 0.5$  were classified as tree crown.

**Watershed** Watershed is a segmentation technique based on regions, which classifies pixels according to their spatial proximity and the gradient of the gray levels. The image is recognized as a topographic surface where the digital value of each pixel can be considered as an elevation point. The surface is inverted and flooded, from the minimum point, preventing the water in adjacent basins to mix with water from upper levels. The boundary of a relief corresponds to the boundaries of adjacent basins. The gradient image is often used in the watershed transformation, because the main criterion of the segmentation is the homogeneity of the grey values of the objects present in the image.<sup>21</sup>

To conduct the image segmentation we used the watershed algorithm implemented into SPRING software (© 1991-2011, DPI/INPE), a Geographic Information System (GIS) developed by Division of Image Processing of the Brazilian's National Institute for Space Research (Instituto Nacional de Pesquisas Espaciais - INPE). The Sobel edge extraction filter was previously applied on the panchromatic band for better performance of the segmentation. The Sobel filters consists in an operator that computes finite differences, giving an approximation of the gradient of the intensity of the image pixels. The watershed algorithm implemented in SPRING considers the gradients of gray level of the original image to generate an gradient image or edge intensity, resulting in an segmented image with each region having a label.<sup>22</sup>

In order to compare the performance of the segmenter, we performed a supervised classification with Bhat-tacharya classifier.<sup>23</sup> In this object-based classifier, statistical separability is measured between a pair of spectral classes. Three classes were defined: non-vegetation, grass and tree crowns. All WV-2 bands and NDVI were used for the classification.

## 2.4 Detection accuracy

To evaluate the performance of the three different approaches a sample of 300 tree crowns was visually interpreted in the WV-2 panchromatic band in a semi-random manner. Even though the templates were based on seven species of high occurrence, we did not distinguish between the different species in our sample but rather tried to

choose a wide variety of crown shape. It should be noted that the trees sampled are not only isolated and we also picked trees within clusters to account for more difficult situations. To validate the detection phase a simple count of “hit or miss” was performed. First we counted how many of the sampled trees were hit then we took an independent random sample of approximately 114 trees detected by the three method and counted how many of these were not trees (base on a visual interpretation). This approach made it possible to calculate independently a producer’s and a user’s accuracy for each method with an approximation of overall accuracy being somewhere between the two. Because we did not use a truly random sampling scheme, this was the only possible measures of accuracy we could achieved. Further work will be given a more thorough attention to sampling design.

Because many trees are spatially contiguous, the validation of the delineation posed a logical problem: errors of crown overflow (commission errors) would eventually be underestimated if a segment overlapped two crowns. To avoid this problem we first performed an inclusive intersection between the results and our validation sample as shown in Figure 4. This way we were assured to test only the capacity of the segmentation approaches to correctly delineate trees.

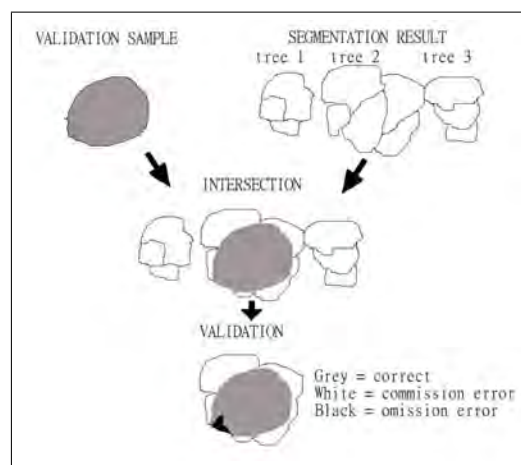


Figure 4. Illustration of the “inclusive intersection” operation.

To evaluate the results for the delineation of the crowns the validation sample was converted to a raster format, with digital numbers (DN) values 1 and 2; 1 corresponding to no data and 2 to tree crown. The result of the region growing and watershed were also converted to raster values, with DN 3 and 4; 3 corresponding to no data value and 4 to delineated crown. Having the same cell size and coverage, the validation images were then multiplied so that resulting DN values of 3 and 8 were considered success for non-tree and tree crown respectively and DN values of 4 and 6 represent omission and commission errors respectively. This method made it possible to produce a contingency matrix for the delineation results.

### 3. RESULTS AND DISCUSSION

#### 3.1 Detection tree crown

The results of template matching for the detection of tree crowns are presented in Table 1. Using only seven species made it possible to detect a total of 17 635 tree crowns. The method was able to identify 232 of the 300 reference tree crowns for producer’s accuracy (1-omission error) of 77.33%. All templates evaluated were able to detect a significant number of individual tree crowns but several crowns were present on more than one template result. Conversely, several objects detected were not trees. Out of 114 randomly selected detected objects (northeast quadrant of the study area), 47 were not trees for a user’s accuracy (1-commission error) of 58.78% and yielding an overall accuracy approximation of 68% (average between producer’s and user’s accuracies). User’s accuracy had to be calculated this way because we did not have a sample of non-trees and this approach seemed more “fair” than considering a non-tree sample. It should also be highlighted that the template for the species *Licania tomentosa* identified 87% of the detected reference crowns alone. These results are somewhat similar

Table 1. Results of the Template Matching to detect individual tree crowns.

Template	Total Features	Validated
<i>Mangifera indica</i>	2.230	65
<i>Terminalia catappa</i>	2.360	98
<i>Spathodea campanulata</i>	225	21
<i>Licania tomentosa</i>	4.607	200
<i>Samanea tubulosa</i>	1.003	16
<i>Caesalpinia pluviosa</i>	2.516	153
<i>Pachira aquatica</i>	3.794	136
TOTAL	17.635	(77.3%) 232

to that found by Quackenbush et al.,<sup>17</sup> which used the same technique in Huntington Forest, New York State, USA, which used eight different templates and achieved an overall accuracy of 71.2%.

Figure 5(a) shows the distribution of crowns detected by the seven templates used. Note that a single crown can be identified by templates of different species, which means that, even with a large floristic diversity patterns, shape and texture are similar in some species. The larger trees (*Samanea tubulosa* and *Spathodea campanulata*) had the lowest detection score when compared with the other species evaluated (Table 1). Although seven templates from seven tree species were used, there does not appear to be specific characteristics (crown size, tree height, regularity or irregularity of the crown) unique to any species and any template can detect any species.

The two object-based approaches were highly effective in detecting individual tree crowns. The watershed approach made it possible to detect all 300 samples of validation data for a producer's accuracy of 100%, and region growing identified 286 samples for a score of 98.66% (Table 2). Again, the user's accuracy was tested by counting how many object were actually trees within the northeast quadrant of the study area: watershed achieved a score of 91.22% (104 correct out of 114) and region growing 90.35% (103 correct out of 114). Figure 5(b) and (c) show the results for the study area. In both cases, what defines the success or failure to detect a crown is not only the segmentation process, but also success of the classification. If the classification had failed to identify the objects pertaining to the tree crowns class, the overall accuracy would be drastically reduced.

Table 2. Results of the Region Growing and Watershed approaches for the detection of tree crowns.

Approach	Validated Trees	Producer's accuracy	Invalidated Trees	User's accuracy
Region Growing	296(/300)	98.66%	103(/114)	90.35%
Watershed	300(/300)	100%	104(/114)	91.22%

### 3.2 Delineation of individual tree crowns

The results for the individual tree crowns delineation are presented in Table 3. Commission errors occur when a pixel classified as tree crown really belongs to another class and omission errors when the reference crown is not detected.<sup>6</sup>

The region growing approach delineated properly 89.79% of the validation crowns. The commission errors were larger than the omission errors, because it tended, in most cases, to overestimate the size of the objects (crown overflow). Watershed delineated correctly 83.63% of the crowns, with both omission and commission errors about higher by about 50% compared to region growing. Figure 6 presents a comparison between the results obtained by the two methods on a portion of the study area.

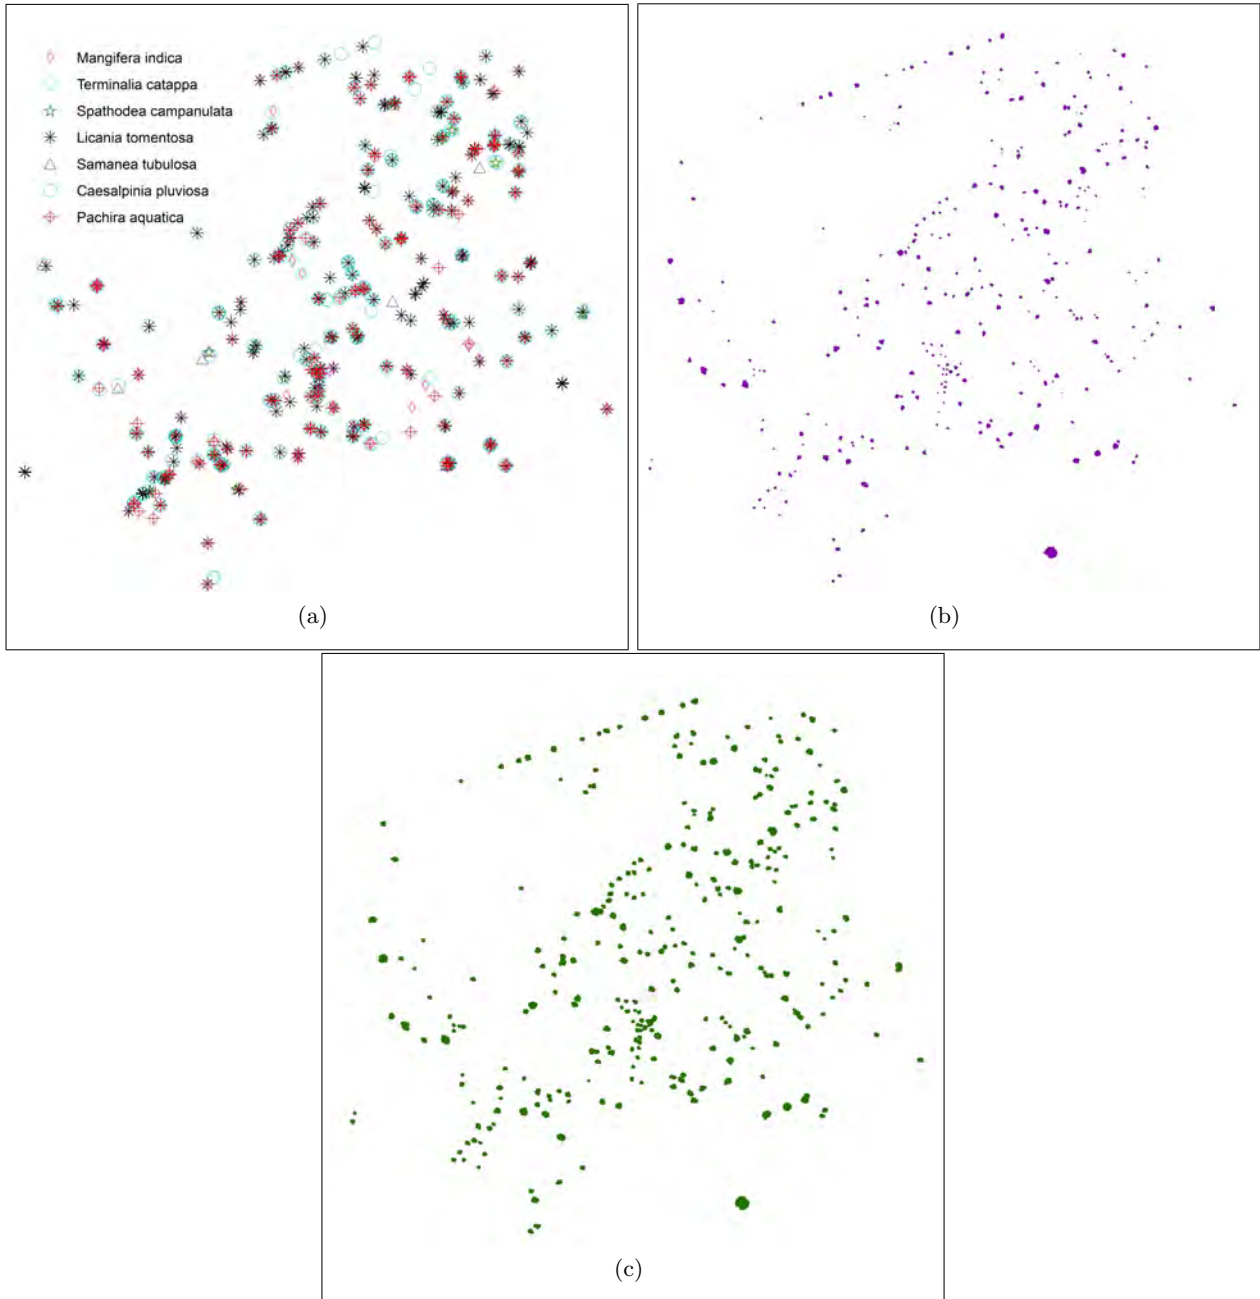


Figure 5. Results of the detection of individual tree crowns with (a) Template Matching, (b) Region Growing and (c) Watershed.



Table 3. Results of the Region Growing and Watershed approaches to delineation individual tree crowns.

Approach	Tree Crown Delineated	Omission Errors	Commission Errors
Region Growing	106.413 pixels	12.097 pixels	17.394 pixels
	89.79%	10.20%	14.68%
Watershed	99.080 pixels	19.430 pixels	25.405 pixels
	83.60%	16.40%	21.44%




Figure 6. Results for delineation with Region Growing (a) and Watershed (b), with omission and comission errors.

The watershed approach had problems with subtle edges, such as where the branches of the tree are less dense and irregularly shaped and where the background (shade and ground) response is greater. This produced irregular boundaries that were incorporated into much larger segments, usually corresponding to the grass. This consequently generated confusion between tree crown and grass, increasing omission errors, or commission errors when portions of grass are classified as tree crown. Conversely, even the smallest crowns were usually identified, segmented and classified correctly.

For the region growing approach, a combination of different levels and features were used to delineate tree crowns. A single rule would not have been able to properly delineate the crowns without the contribution of several measures like geometry, texture, neighborly relations and spectral characteristics. Isolated tree crowns tended to be formed by only one or two image object (sunlit and shaded portion) and showed greater success in

being delineated properly. The commission errors were larger and usually were due to the inclusion of part of the shadow cast by the tree as a crown. The fact that shadows creates very compact objects in the segmentation process might contribute to this problem. With the high diversity of shape the sunlit and shaded areas of the tree crown often create a complex pattern not easily simplified by a model. Pu and Landry<sup>4</sup> performed this separation by using the NDVI, but in our case, due to the richness, the NDVI values for the illuminated area and shaded area were often the same for different crowns.

Figure 7 shows a comparison of the image objects created by the two approaches. With the region growing the shape of objects is usually well defined with a good correspondence to a visual interpretation. However, as already reported by several authors in the literature, the watershed approach tend to produce an over-segmentation of the objects. In this case, we can say that without the validation data, it would be very difficult to correctly determine the proper delineation of the tree crowns.




Figure 7. Results of the segmentation process with Region Growing (a and b) and Watershed (c and d).

Because the coarser spatial resolution of the multispectral bands (two metres instead of 50 cm) we could not take full advantage of this information for the segmentation and this was perceived as a strong limiting factor in the classification process. This is especially true for the distinction between species or group of species spectrally similar.

#### 4. CONCLUSIONS

In this study we compared the performance of different methods for the detection and delineation of individual tree crowns in a tropical urban environments using WV-2 satellite data. WV-2 data proved adequate for the study, but we could not take adequate advantage of the eight multispectral bands for the segmentation/classification process, because of its coarser spatial resolution.

All three methods were able to identify most tree crowns but the two region growing approaches were superior to the template matching approach with producer's and user's accuracies over 90%. For the crown delineation, the e-Cognition OBIA approach using multilevel segmentation with adjustment of the scale parameter and the ability to use not only spectral, textural and complex features like size and shape for classification, but also rule-based relationships between objects brings a new dimension in the possibilities of advanced classification.

The challenge for the study of tree crowns in tropical environments lies in dealing with high floristic diversity with evergreen, semi-deciduous and deciduous species, and structural (size and shape) variability of the crowns. Still, preliminary results were very encouraging and we foresee the possibility to use a combination of methods to achieve similar or better results with an increased efficiency and agility.

This research is still in development and we hope to bring new contributions to the study of urban trees in tropical environments. We intend to take better advantage of the OBIA approach in order to improve the detection of small and clustered crowns. A floristic survey will be conducted, making it possible to identify not only the contour of crowns but also conduct a specie-based analysis. Despite the lower rates of overall accuracy of the template matching, we envision a potential for int integration with a region growing approach to serve as seed or as markers for improving the process of delineation.

## ACKNOWLEDGMENTS

The authors wish to acknowledge the support of SPIE Remote Sensing and the Geosciences Institute of the UFMG for their financial support to allow this work to be presented at the SPIE Remote Sensing 2013 conference. We would also like to thank Geraldo Motta, official of the Division of Green Areas of UFMG, for his assistance in identifying the tree species.


## REFERENCES

- [1] Östeberg, J., Delshammar, T., Wiström, B., and Nielsen, A. B., “Grading of parameters for urban tree inventories by city officials, arborists, and academics using the Delphi method,” *Environmental Management* **51**, 694–708 (2013).
- [2] Sander, H., Polasky, S., and Haight, R. G., “The value of urban tree cover: A hedonic property price model in Ramsey and Dakota Counties, Minnesota, USA,” *Ecological Economics* **69**, 16461656 (2010).
- [3] Almeida, A. L. B. S. S. L., *O valor das árvores: árvores e floresta urbana de Lisboa*, PhD thesis, Instituto Superior de Agronomia, Lisboa (2006).
- [4] Pu, R. and Landry, S., “A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species,” *Remote Sensing of Environment* **124**, 516–533 (2012).
- [5] Larsen, M., Eriksson, M., Descombes, X., Perrin, G., Brandtberg, T., and Gougeon, F., “Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions,” *International Journal of Remote Sensing* **32(20)**, 58275852 (2011).
- [6] Ke, Y. and Quackenbush, L. J., “A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing,” *International Journal of Remote Sensing* **32**, 4725–4747 (2011).
- [7] Hay, G. J. and Castilla, G., [*Object-Based Image Analysis. Spatial concepts for knowledge-driven remote sensing applications*], ch. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline?, 75–89, Springer-Verlag, Berlin (2008).
- [8] Gomes, P., Ferreira, M. C., Lingnau, C., Bolfe, E., and Siqueira, M., “Segmentação e classificação de dossel florestal em imagens Quickbird,” *Ambiência* **4**, 35–46 (2008).
- [9] Arasato, L. S., Amaral, S., and Rennó, C. D., “Detecting individual palm trees (arecaceae family) in the amazon rainforest using high resolution image classification,” in [*Anais XV Simpósio Brasileiro de Sensoriamento Remoto*], *Proc. SBSR*, 7628–7635 (2011).
- [10] Ardila, J. P., *Object-based methods for mapping and monitoring of urban trees of multitemporal image analysis*, PhD thesis, University of Twente, Enschede (June 2012).
- [11] Zhang, K. and Hu, B., “Individual urban tree species classification using very high spatial resolution airborne multi-spectral imagery using longitudinal profiles,” *Remote Sensing* **4**, 1741–1757 (2012).
- [12] Cavayas, F., Ramos, Y., and Boyer, A., “Mapping urban vegetation cover using worldview-2 imagery,” in [*Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII*], Sylvia S. Shen, P. E. L., ed., *Proc. of SPIE* **8390**, 01–10 (2012).
- [13] de Melo Franco, V. S., [*Gerenciamento da Arborização na Área do Campus da UFMG Utilizando Ferramentas SIG*], Universidade Federal de Minas Gerais, Belo Horizonte (2006).


- [14] Lombardi, J. A. and Morais, P. O., “Levantamento florístico das plantas empregadas na arborização do campus da Universidade Federal de Minas Gerais, Belo Horizonte-MG,” *Lundiana* **4(2)**, 83–88 (2003).
- [15] DIGITALGLOBE, [*The Benefits of the 8 Spectral Bands of WorldView-2*] (March 2010). [[http://www.digitalglobe.com/downloads/WorldView-2\\_8-Band\\_Applications\\_Whitepaper.pdf](http://www.digitalglobe.com/downloads/WorldView-2_8-Band_Applications_Whitepaper.pdf)].
- [16] Caves, R. G., Harley, P. J., and Quegan, S., “Matching map features to synthetic aperture radar (SAR) images using template matching,” *IEEE Transactions on Geoscience and Remote Sensing* **30(4)**, 680–685 (1992).
- [17] Quackenbush, L. J., Hopkins, P. F., and Kinn, G. J., “Developing forestry products from high resolution digital aerial imagery,” *Photogrammetric Engineering and Remote Sensing* **66(11)**, 1337–1346 (2000).
- [18] Trimble Documentation, München, Germany, *eCognition Developer user guide* (2011).
- [19] Baatz, M. and Schäpe, A., “Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation,” in [*Angewandte Geographische Informationsverarbeitung XII*], Strobl, J., ed., 12–23 (2000).
- [20] Haralick, R. M., Shanmugam, K., and Dinstein, I., “Textural features for image classification,” *IEEE Trans. Sys. Man Cybern* **3**, 610–621 (1973).
- [21] Beucher, S., “The watershed transformation applied to image segmentation,” in [*10th Pfefferkorn Conf. on Signal and Image Processing in Microscopy and Microanalysis*], **6**, 299–314 (1992).
- [22] Câmara, G., Souza, R. C. M., Freitas, U. M., and Garrido, J., “SPRING: Integrating remote sensing and GIS by object-oriented data modelling,” *Computers & Graphics* **20(3)**, 395–403 (1996).
- [23] Richards, J. A., [*Remote Sensing digital image analysis: an introduction*], Springer-Verlag (1993).

## **Apêndice C**


### **Estatísticas globais do processamento das imagens VHR**



(a)




(b)




(c)

Figura C.1: Estatísticas globais para a imagem do Campus da UFMG, Belo Horizonte, Minas Gerais: divisões 1 a 3.




(a)




(b)

Figura C.2: Estatísticas globais para a imagem do Campus da UFMG, Belo Horizonte, Minas Gerais: divisões 4 e 5.




(a)




(b)

Figura C.3: Estatísticas globais para a imagem do Parque Ecológico da Pampulha, Belo Horizonte, Minas Gerais: divisões 1 e 2.






(a)




(b)

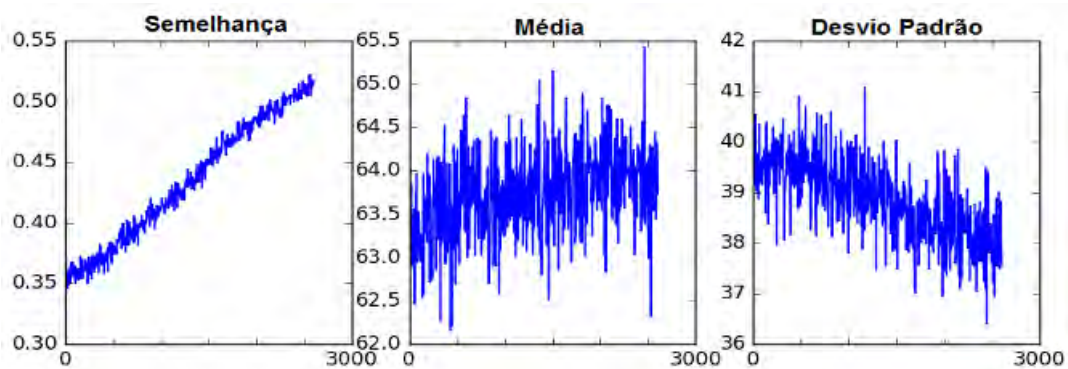


(c)


Figura C.4: Estatísticas globais para a imagem do Jardim Botânico Real de Sydney, Austrália: divisões 1 a 3.



(a)



(b)



(c)

Figura C.5: Estatísticas globais para a imagem do Jardim Botânico Real de Sydney, Austrália: divisões 4 a 6.

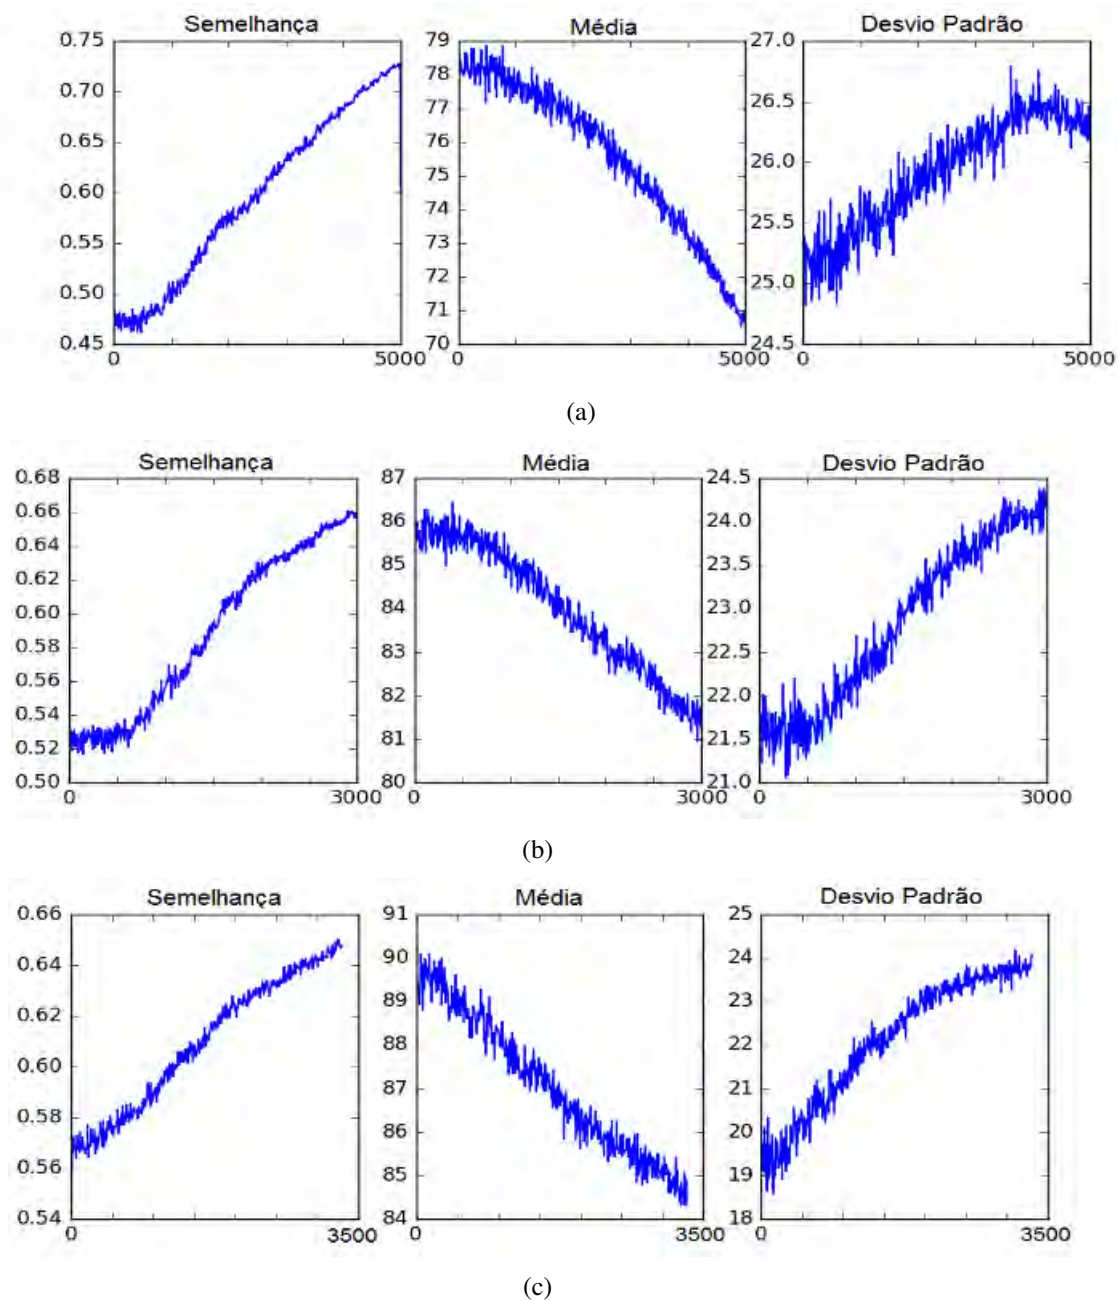




Figura C.6: Estatísticas globais para a imagem da plantação de abacateiros em Morro Bay, Califórnia: divisões 1 a 3.




(a)




(b)

Figura C.7: Estatísticas globais para a imagem em vegetação de cerrado *sensu stricto* no Parque Nacional de Brasília, Distrito Federal: divisões 1 e 2.




(a)



(b)

Figura C.8: Estatísticas globais para a imagem em vegetação de cerrado *sensu stricto* no Parque Nacional de Brasília, Distrito Federal: divisões 3 e 4.



(a)

Figura C.9: Estatísticas globais para a imagem em remanescente florestal de mata seca, Itacarambi, Minas Gerais.