

Inventário de Sobrevivência de povoamento de Eucalyptus com uso de Redes Neurais Artificiais em Fotografias obtidas por VANTs

Marieli Sabrina Ruza^{1*} Ana Paula Dalla Corte¹ Ângela Maria Klein Hentz¹ Carlos Roberto Sanquetta¹ Carlos Alberto Silva² Emerson Roberto Schoeninger³

¹ Departamento de Ciências Florestais da Universidade Federal do Paraná, Avenida Prefeito Lothário Meissner, 632, CEP: 80210-170, Curitiba, Paraná.

² University of Idaho, Moscow, Idaho, Estados Unidos da América.

³ Klabin S.A. Avenida Brasil, 26, CEP: 84275-000, Harmonia, Telêmaco Borba, Paraná.

*Author for correspondence: marielisabrinaruza@yahoo.com.br

Received: 26 September 2016 / Accepted: 23 November 2016 / Published: 31 March 2017

Resumo

O objetivo desse trabalho foi avaliar o desempenho de Redes Neurais Artificiais (RNAs), em ortofotos obtidas por VANTs (Veículo Aéreo Não Tripulado), para a detecção e extração automática de mudas de árvores, que possibilitem determinar a sobrevivência em plantios de eucaliptos. O software Neurodic, baseado em RNAs, foi utilizado para a classificação de mudas de Eucalyptus em talhões pós plantio. A classificação foi realizada em ortofotos aéreas obtidas pelo VANTeBee-Ag. Todo o processamento pós voo para a geração do ortofoto foi executado com o software Postflight Terra 3D. Foi treinada 1 rede do tipo MultiLayer Perceptron (MLP). O treinamento e a classificação das imagens foi executada com o Neurodic, e posteriormente o resultado foi importado no software QuantumGIS. Foram então calculados e comparados os números de mudas a partir de uma classificação manual sobre a ortofoto, a partir da estimativa do número de mudas pelo espaçamento de plantio, e a partir da classificação do Neurodic, baseando-se nesse caso na classificação pós-processada manualmente e na classificação original. Os valores mais próximos à realidade foram obtidos com as RNAs pós-processadas, que apresentaram um erro menor que 2% para a média da área total, enquanto que o pior resultado foi com as RNAs sem edições. A estimativa com base no espaçamento de plantio mostrou superestimar o número de mudas. A utilização de ortofotos por meio de VANTs, com a classificação via RNA, é uma técnica promissora para contagem de mudas, porém o processamento ainda não pode ser feito de forma totalmente automatizada.

Palavras-chave: Neurodic, Ortomosaico, Drone.

Abstract

The objective of this study was to evaluate the performance of Artificial Neural Networks (ANNs) on orthophotos obtained by UAV (Unmanned Aerial Vehicle), to detect and extract tree seedlings automatically, in order to determine the survival rate in Eucalyptus stands. The Neurodic software, based on ANNs, was utilized to classify the Eucalyptus seedlings in stands after planting. This classification was performed using photographs obtained with UAV eBee-Ag. The post flight processing for generating the orthophoto was executed with Postflight Terra 3D software. 1 MultiLayer Perceptron neural networks (MPL) are trained. The training and the classification was performed with Neurodic, and the result was subsequently imported in the QuantumGIS software. The number of seedling was calculated and compared from a manual classification on the orthophoto (real number of seedlings), from the estimated number of seedlings by the planting spacing, and from the classification of Neurodic, based on post classification manually processed and in the original classification. The most accurate values were obtained with the post processed ANNs, which resulted an error lower than

2% in the total area average, while the worst result was obtained by unedited ANNs. The estimates based on planting space showed overestimate the actual number of seedlings. The use of orthophotos by UAV, classified via ANN, is a promising technique to count seedlings, but the processing cannot be done in a fully automated manner.

Keywords: Neurodic, Orthophoto, Drone.

Introdução

Cerca de 91% de toda a madeira utilizada para fins industriais no país advêm de florestas plantadas. Apesar da enorme área de florestas nativas no país, apenas 9% da madeira industrial é produzida de matéria-prima originária de florestas nativas (IBÁ 2016). Isso demonstra que a economia florestal atualmente é totalmente dependente da silvicultura para sua subsistência. O planejamento da produção florestal é composto por diversas etapas, dentre elas, a fase de diagnóstico, onde o inventário florestal está presente (Sanquetta et al. 2014). Os inventários florestais podem ter diferentes abordagens, dentre elas, o levantamento de informação sobre a sobrevivência das mudas. A principal variável do inventário de sobrevivência é o número de plantas remanescente após um período sucessivo ao plantio por unidade de área.

Nos inventários aplicados em florestas já formadas (contínuos e pré-corte) as estimativas são realizadas com base na unidade de área, uma vez que o número de árvores não é constante e conhecido (Oliveira et al. 2014). Ter a sobrevivência de mudas homogênea no talhão garante que o erro do inventário no futuro possa ser menor e, conseqüentemente, que a intensidade amostral possa ser reduzida. Essa é uma das justificativas para qual os inventários florestais de sobrevivência têm importância: identificar previamente a mortalidade e, garantir que a silvicultura possa intervir a tempo, para que no futuro, os plantios sejam mais homogêneos.

No entanto, a decisão para realizar ou não a intervenção silvicultural de replantio precisa ser alicerçada em valores realistas. Estes valores de mortalidade/sobrevivência geralmente são levantados em campo, por meio de procedimentos de inventário florestal. Existe a possibilidade da aplicação de imagens de satélites de alta resolução espacial para tal finalidade, conforme apresentado por diversos autores (Cunha et al. 2012; Macedo et al. 2012; Macedo et al. 2013; Oliveira et al. 2014). Contudo, o custo de aquisição destas imagens e o mecanismo de obtenção das mesmas, muitas vezes, pode inviabilizar a aquisição para essa finalidade, particularmente em grandes áreas e quando é necessário avaliar as mudanças temporais.

Os veículos aéreos não tripulados (VANTs) têm tido uso recorrente no meio florestal. Uma das aplicações atualmente importantes é na realização de inventário de sobrevivência pós-plantio (Araújo et al. 2006; Favarin et al. 2013; Soares et al. 2015). Problemas, como custo e periodicidade de

obtenção são menores com o uso desta tecnologia para as grandes empresas florestais, quando comparados as imagens de satélites conforme destacados por diversos autores (Rango et al. 2009; Anderson e Gaston 2013; Braz et al. 2015; Chaves et al. 2015).

Apesar do rápido avanço nas atividades de operação dos VANTs e de obtenção das fotografias aéreas, a geração dos produtos de forma automatizada não avançou com a mesma rapidez. Muitos autores destacam que existe um grande desafio no desenvolvimento de procedimento automatizado para a extração de feições de interesse dos ortomosaicos oriundas dos VANTs (Macedo et al. 2012; Henriques et al. 2015; Silva et al. 2015). A técnica que prevalece hoje é a interpretação em tela com a aplicação de técnicas tradicionais de fotointerpretação.

De forma semelhante, no âmbito florestal começou-se a empregar as chamadas Redes Neurais Artificiais (RNAs) para auxiliar na tomada de decisões e na redução de custos nas áreas de manejo e mensuração florestal (Binoti e Binoti 2014). Essas redes foram desenvolvidas em 1943 e são inspiradas nos estudos da maneira como se organiza e como funciona o cérebro humano (Saraiva et al. 2014), compondo-se de um conjunto massivo e paralelamente distribuído de neurônios, que possuem em seu interior funções de ativação, os quais são organizados de diversas maneiras e contêm conexões entre si com diferentes pesos, baseados no conhecimento que a rede adquiriu durante o treinamento (Binoti 2010). Na última década, as redes neurais artificiais têm experimentado um grande interesse e têm sido aplicadas com sucesso no reconhecimento de padrões de imagens de satélite. Uma das principais vantagens das redes neurais é a possibilidade de manipulação eficiente de grandes quantidades de dados, mas a principal razão para o seu uso na classificação de dados de sensoriamento remoto e dados geográficos, é que as redes neurais não assumem nenhuma distribuição (Chagas et al. 2009).

O objetivo do presente estudo foi testar o desempenho da técnica de redes neurais artificiais, em ortofotos obtidas por VANT, para a detecção e extração automática de mudas de árvores, visando subsidiar e/ou substituir o inventário florestal de sobrevivência em campo.

Material e métodos

Área de estudo

Para a execução desse estudo foram utilizadas imagens de um voo realizado sobre um plantio de eucaliptos, situado no município de Telêmaco Borba - PR, Brasil. Os dados pertencem à empresa Klabin S.A.

A Carta Climática, fornecida pelo Instituto Agrônomo do Paraná – IAPAR (2012) caracteriza o clima do município como Cfa, que é definido como subtropical com verões quentes. A área em estudo está localizada a uma altitude de aproximadamente 760 m (Santos 2005), com precipitação média anual variando entre 1.200 e 1.600 mm (IAPAR 2012).

O plantio foi realizado na fazenda Mortandade, no dia 21 de fevereiro de 2014, com o híbrido de *Eucalyptus grandis* e *E. urophylla*, utilizando um espaçamento de 3,75 x 2,4 m, totalizando cerca de 1.111 mudas por hectare. Foram selecionados para o desenvolvimento deste trabalho 4 talhões que totalizam uma área de 9,42 hectares.

Coleta e processamento de dados VANT

As fotografias aéreas foram obtidas em setembro de 2015, aos 18 meses de idade do povoamento, utilizando-se o VANT eBee-Ag (da empresa Sensefly) equipado de uma câmera RGB Canon (S110 RGB), que tem por características 12 Mb de resolução, sensor com tamanho de 7,44 por 5,58 mm e distância focal de 4,37 μ m. Foram obtidas 41

fotografias aéreas. O processamento das fotografias foi realizado com o software Postflight Terra 3D, versão 3.1.45, no qual foram realizadas as etapas de orientação interior e exterior das fotografias aéreas, e a obtenção das ortofotos e do ortomosaico, com resolução espacial de 16 centímetros.

Na etapa de orientação interior são encontrados os parâmetros que definem as características da câmera, como distância focal, coordenadas do ponto principal e coeficientes de correção das distorções da câmera (Silva et al. 2014). Com a definição desses parâmetros e da confiabilidade desses, é possível a correção adequada dos erros sistemáticos das medidas no espaço imagem, e, conseqüentemente, permite continuação do processo fotogramétrico sem estes erros (Campos et al. 2015). Já na orientação exterior, são calculados os parâmetros que permitem descrever a trajetória e orientação do sensor no intervalo de coleta da imagem, ou seja, é realizada a orientação (ou o referenciamento) das fotografias em função do sistema de coordenadas desejado (Marcato Junior 2011). Na orientação exterior são definidos 6 parâmetros, dos quais três referem-se à posição do sensor (x , y e z), e três correspondem aos três ângulos de rotação (ω , ϕ , κ) que a aeronave pode sofrer (Riveiro et al. 2013).

O ortomosaico produzido foi utilizado como base para a realização dos testes e processamentos descritos a seguir.

Testemunha – T1

Para a avaliação do desempenho dos algoritmos testados foi necessária a definição de um tratamento testemunha. Para tanto, adotou-se o resultado da interpretação visual em tela realizada sobre o ortomosaico. Esta interpretação foi realizada no software Quantum, versão 2.2.

Estimativa pelo espaço vital médio – T2

Para comparação, também foi realizada uma estimativa média de número de plantas por hectare, tomando como base o espaço vital médio do talhão.

Para tanto calculou-se a área dedicada por cada muda, calculada em função do espaçamento (3,75 x 2,4m). Esse valor é de 9 m² em todos os talhões, ou seja, cerca de 1.111 mudas por hectare. Dessa forma, esse valor foi extrapolado para a área de cada talhão, reproduzindo, portanto, o número de mudas esperado em cada.

Detecção automática pelo algoritmo de RNA do software Neurodic sem pós-processamento – T3

Foi treinada 1 RNA do tipo MultiLayer Perceptron (MLP) no software Neurodic, que é um dos sistemas desenvolvidos pelo projeto Neuroforest. No software utilizou-se do algoritmo de aprendizado Resilient Propagation, constituída por uma camada de entrada onde o número de neurônios dessa camada foi igual ao número de variáveis adicionadas ao treinamento (Red, Green e Blue), 4 neurônios na camada oculta, onde ocorre o processamento, e uma camada de saída correspondendo as classes: 1 – árvore e 2 - não árvore. Foi utilizada a função de ativação Linear na camada de entrada e Tangente Hiperbólica para a camada oculta e de saída, com taxa de aprendizado de 0,01 e 3.000 interações (Binoti e Binoti 2014).

O ortomosaico foi recortado conforme os limites dos 4 talhões e então cada um dos talhões foi importado separadamente no software Neurodic.

De cada talhão foram coletadas 40 amostras de árvores e a mesma quantia para não árvores. A estas amostras foram atribuídos os valores de 0 e 1, para o treinamento da RNA. Com a RNA treinada, a mesma foi utilizada para identificar as classes no restante da imagem. Em seguida, os arquivos em formato raster, resultantes da classificação, foram importados para o software QuantumGIS. Dentro do

software a imagem passou pelo processo de vetorização dos resultados da classificação, e a separação dos polígonos representantes das mudas (classe 1) de *Eucalyptus* em relação ao restante da imagem. Para tanto, baseou-se nos padrões de cor resultantes, dado que o software classificou as mudas com a coloração vermelha e o restante como preto.

Dada a exclusão dos polígonos da classe não árvore, calculou-se os centroides dos polígonos respectivos à classe árvore, de forma que cada polígono representando uma muda fosse computado. Essa etapa foi realizada visando à comparação com os demais enfoques.

Deteção automática pelo algoritmo de RNA do software Neurodic com pós-processamento – T4

Neste tratamento foi realizado o mesmo procedimento descrito para o tratamento T3, diferindo que nesse caso ocorreram alguns procedimentos complementares, descritos a seguir.

Após os procedimentos realizados no Neurodic, a imagem resultante para cada talhão foi exportada e pós-processada com o software QuantumGIS, versão 2.2, realizando-se as mesmas etapas de vetorização e exclusão dos vetores correspondentes à classe 2 (não árvore). Após a separação das duas classes, os polígonos referentes à classe 1 (árvore) foram pós processados. No pós-processamento foram mesclados polígonos que se apresentavam fragmentados, porém que apresentam continuidade espacial, assim como foi realizada a divisão de polígonos que representavam mais de uma planta. Da mesma forma, foram excluídas feições que foram classificadas na classe 1, mas que não correspondiam a mudas (como por exemplo as bordas do limite do talhão).

Após esse pós-processamento foram extraídos os centroides de cada polígono, que representavam, portanto, a localização aproximada de cada muda.

Análise comparativa entre os enfoques

Visando à comparação dos tratamentos aplicados, adotaram-se como métrica as diferenças absolutas e relativas. Desta forma, todos os desempenhos dos métodos foram comparados com a testemunha. As equações utilizadas estão apresentadas a seguir:

$$\text{Diferença Absoluta} = \text{ND} - \text{NO} \quad (1)$$

$$\text{Diferença Relativa} = ((\text{ND} - \text{NO})/\text{NO}) * 100 \quad (2)$$

Onde:

NO= número de mudas observadas;

ND= número de mudas pelo método avaliado em cada caso.

Resultados e discussão

No tratamento testemunha (T1) foram contabilizadas 1.771 árvores para a área total do talhão 1, 2.171 árvores para a área total do talhão 2, 1.321 árvores para a área total do talhão 3 e 4.712 árvores para a área total do talhão 4. Deste modo, foram contabilizadas 9.975 árvores pelo levantamento (Tabela 1).

Tabela 1. Resultado da quantificação do número de mudas em cada talhão.

Talhão	Área (ha)	Número real (T1)	Espaço vital (T2)	RNA original (T3)	RNA pós proc. (T4)
1	1,77	1.771	1.966	1.719	1.813
2	2,04	2.171	2.266	3.117	2.215
3	1,31	1.321	1.456	1.399	1.338
4	4,30	4.712	4.777	2.890	4.769
Total/Média	9,42	9.975	10.465	9.125	10.135

Aplicando-se o espaçamento médio vital observado nos talhões, tratamento T2, a estimativa de número de árvores

para o talhão 1 é de 1.966, no talhão 2 de 2.266 árvores, no talhão 3 de 1.456 árvores e no talhão 4 de 4.777 árvores, totalizando 10.465 árvores, valor este que representa 4,9 % superior ao real contabilizado nos talhões.

A estimativa de mudas com base no espaçamento de plantio mostrou superestimar o número real de mudas, resultado já esperado, devido à mortalidade inicial de plantas ser um evento comum. Valores de mortalidade de mudas para a mesma espécie variaram entre 3 e 6% (Silva et al. 2015), portanto a diferença média entre número mudas estimadas e o real (decorrente da mortalidade), de cerca de 5%, está coerente.

As diferenças entre os números de mudas calculados pelas RNAs, para os tratamentos T3 e T4, e os valores reais, podem ser observados na Tabela 2. Os dados obtidos pela RNA de forma bruta (T3) não demonstrou ser um método eficaz, sendo que este tratamento apresentou os resultados mais divergentes, com erros de até 43%.

Tabela 2. Diferenças absoluta e relativa entre a estimativa de mudas e o número real contabilizado.

Talhão	Espaço vital (T2)		RNA original (T3)		RNA pós proc. (T4)	
	Absoluta	%	Absoluta	%	Absoluta	%
1	195	-11,01	-52	2,94	42	-2,37
2	95	-4,38	946	-43,57	44	-2,03
3	135	-10,22	78	-5,90	17	-1,29
4	65	-1,38	-1.822	38,67	57	-1,21
Total	490	-4,91	850	8,52	160	-1,60

Já a RNA pós-processada (T4) foi a que resultou em valores mais próximos ao número real de mudas, apresentando erro inferior a 2% na média área total, e erro máximo de 2,37% (no talhão 1). Esse resultado, quando comparado com outros trabalhos semelhantes, mostra que o tratamento T4, que consiste no emprego das RNAs pós-processamento, foi satisfatório, pois o erro médio de 1,6% encontrado é inferior ao erro médio de 5% encontrado por She et al. (2014), aos 2,7% de erros de omissão observados em árvores menores de 1 metro por Vepakomma e Cormier (2015), e ao intervalo entre 10,0% e 79,2% encontrado por Soares et al. (2015), assim como aproximadamente 10% encontrado por Favarin et al. (2013), em todos os casos considerando-se árvores adultas.

Apesar de apresentar o erro menor, os valores observados com o tratamento T4 tenderam a superestimar o número de mudas. Essa superestimativa, conforme análise visual, deve-se à identificação de outros objetos como sendo mudas, como por exemplo sombras, plantas invasoras, entre outras. Apesar disso, esse erro é bastante inferior às diferenças entre os valores estimados pelos demais tratamentos (T2 e T3).

No caso das RNAs sem pós-processamento (T3), alguns talhões também apresentaram casos com predomínio de superestimativa (talhões 2 e 3), e em outros casos subestimativa (talhões 1 e 4). O resultado obtido com as RNAs sem nenhum pós-processamento apresentou os piores valores de estimativa conforme já relatado, quando comparado com o número real de mudas em cada talhão, e estes resultados devem-se principalmente a dois tipos de erros: a) inclusão errônea de mudas, e; b) exclusão de mudas, pelo agrupamento de várias mudas em um único polígono ou ainda a falha de classificação.

Os erros do tipo “a” causam a superestimativa do número real de mudas, e devem-se a identificação de algum padrão de mudança de cor como sendo uma muda, como por exemplo, sombras ou a borda da área recortada, conforme observado nas Figuras 1 e 2 (regiões destacadas com letra “a”). Os erros de exclusão por sua vez são mais comuns, e se caracterizam por contabilizar em um único polígono mais que uma muda, que, portanto, precisa ser dividido

manualmente, como pode ser observado pelos itens destacados com a letra “b” na Figura 1.

O agrupamento de mudas é um padrão comumente observado em classificações, principalmente em formações mais densas, dificultando a individualização em nível de árvore (Sousa et al. 2010). O agrupamento pode ocorrer também em povoamentos novos, principalmente se observada a presença de mato competição ou outro tipo de vegetação no entorno das mudas que possam interferir no contraste do objeto-entorno, dificultando a identificação correta das bordas destas (Araújo et al. 2006; Torres-Sánchez et al. 2015).

Deve-se destacar, porém que esse erro pode ser minimizado utilizando-se plantios em idade mais jovem, pois na idade considerada neste trabalho, de 18 meses, as copas já estão em contato umas com as outras. Esse contato entre as copas é esperado nessa idade, considerando-se que em trabalhos com *Eucalyptus* sp. aos 20 meses, Wink et al. (2012) encontraram diâmetros de copa variando entre 3,02 e 4,16 m², de forma que no espaçamento e idade utilizados no presente estudo, o contato entre as copas é considerado normal. Pode-se sugerir que uma idade recomendada para esse tipo de análises seja aos 6 meses de idade, pois nessa idade Araújo et al. (2006) encontraram resultados satisfatórios quanto a coleta de informações para inventário de sobrevivência assim como de qualidade (considerando área de copa entre outras medidas), apesar de destacarem que nesta idade é possível a existência de problemas devido à mato competição.

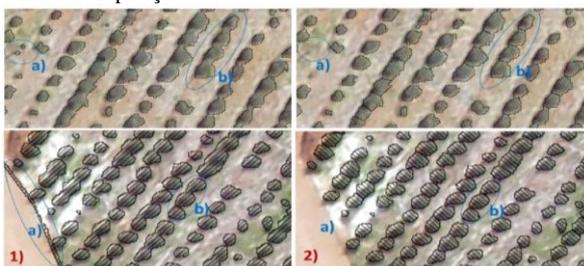


Figura 1. Identificação de erros resultantes da classificação pelas RNAs que podem ser minimizados com pós processamento. Em 1 estão representados os resultados da classificação antes do pós processamento (T3), e em 2 após as edições (T4). As áreas delimitadas com a letra “a” apresentam erros que causam superestimativa do número de mudas, e em “b” erros que causam subestimativa.

Outro fator que causa subestimativa, menos comum que o agrupamento de várias mudas, é que em alguns casos ocorre a não classificação de algumas mudas pelas RNAs. Isso acontece principalmente em áreas onde a ortofoto encontra-se pouco nítida, ou em áreas nas bordas, como pode ser verificado nas regiões demarcadas como “b” na Figura 2. Esse tipo de efeito em ortomosaicos ocasionam problemas que dificultam a identificação de objetos, como também observado por Ezequiel et al. (2015), que encontraram dificuldades na identificação de coqueiros onde as imagens apresentava-se borrada ou com sombras. Os autores apontam que uma alternativa para minimizar efeitos como esse é encontrar um horário do dia com as condições ideais para a obtenção das fotografias.

As principais condições climáticas que devem ser avaliadas para a tomada de fotografias com máxima qualidade são referentes ao vento e a iluminação. Quanto ao vento pode-se dizer que voos realizados em dias com uma velocidade de vento alta podem apresentar imagens turvas assim como alterar a posição da tomada das fotos (Luz 2015), pois o vento interfere na estabilidade da aeronave, principalmente das menores, e em muitos casos pode até eliminar a possibilidade de realização do voo. Portanto

recomenda-se a realização de voos em dias ou horário do dia com ventos fracos (Gonçalves e Henriques 2015). Já quanto a iluminação, os principais problemas referem-se a presença de sombras nas imagens, que ocorrem principalmente no início e fim do dia, portanto sugere-se a realização de voos no meio do dia, apesar de que em algumas topografias muito inclinadas esse horário pode variar (Stark e Chen 2014).

De forma similar, Lehmann et al. (2015), observaram dificuldade em classificar pequenos objetos em algumas situações de luminosidade. Segundo estes autores, os efeitos de iluminação (em excesso ou em escassez) tem efeitos negativos sobre a acurácia de classificações, assim o recomendado é que os voos devem ser realizados no meio dia solar (para dias ensolarados) ou em dias com céu parcialmente coberto.

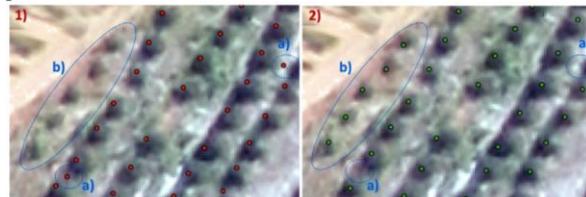


Figura 2. Destaque para erros da classificação com as RNAs. Em 1, resultado da classificação pelas RNAs (T3), e em 2 classificação manual das mudas (T1). As regiões delimitadas com a letra “a” representam erros que causam superestimativa do número de mudas, e em “b” erros que causam subestimativa.

Da mesma forma, a resolução do ortomosaico, de 16 cm, pode também ter corroborado na dificuldade de identificação de mudas menores, pois autores como Torres-sánchez et al. (2015) observaram dificuldades na reconstrução 3D de mudas de oliveiras em algumas situações, dentre elas quando o voo foi realizado em maior altitude, e, portanto, com menor resolução espacial. Portanto, acredita-se que exista uma resolução espacial mínima necessária para a identificação de árvores, ou outros objetos, de tamanhos menores.

Apesar de essa ser uma possibilidade a ser considerada, a resolução utilizada nesse trabalho é considerada adequada, pois estudos como de Sakari et al. (2015) apontam que resoluções muito altas podem ser inclusive prejudiciais. Ainda sobre essa questão, Sakari et al. (2015) destacam que a extração de feições deve ser realizada considerando-se uma escala (referindo-se à resolução espacial) coerente com o tamanho dos objetos de interesse, portanto essa escala é variável. No caso desses autores (Sakari et al. 2015), para a extração de copas de árvores adultas, a resolução de 10 cm foi considerada muito alta, e, portanto, o ortomosaico foi reamostrado para as resoluções de 20 e 50 cm antes da etapa de extração das feições, e os resultados encontrados foram satisfatório com as duas resoluções. Da mesma forma, Torres-Sánchez et al. (2015) concluem que a classificação de mudas com a OBIA, aplicada em ortofotos apresenta uma acurácia elevada, mesmo em diferentes altitudes (e, portanto, diferentes resoluções de pixel), demonstrando o potencial dessa tecnologia.

No caso das superestimativas, destaca-se a identificação de outros objetos e áreas de borda como mudas, assim como pode ser levantada a questão da presença de “ruídos” nas classificações pixel a pixel, que se configuram como pixels isolados classificados para uma classe diferente do seu entorno, e que ocorrem principalmente em imagens de alta resolução (Resende et al. 2012). Esses “ruídos” da classificação podem favorecer o cálculo de um número superior ao real de mudas, pois mesmo esses pequenos objetos serão classificados e contabilizados como um indivíduo. Dessa forma, parte das superestimativas de mudas encontrada neste trabalho podem ser reflexo da presença

desses ruídos, característicos do tipo de classificação utilizada. Uma alternativa que pode ser utilizada é a aplicação de filtros (normalmente de moda) para a eliminação de pixels isolados (Eberhardt et al. 2015), ou ainda a aplicação de uma filtragem por tamanho no resultado vetorial, de forma a excluir vetores com áreas muito pequenas (como por exemplo, que corresponda a área de 1 ou 2 pixels, e, portanto, não representaria uma muda). Outra alternativa que pode ser avaliada em estudos futuros é a utilização da nuvem de pontos, gerada durante o processamento das fotografias para a obtenção da ortofoto, como um produto a parte que possa ser utilizado na classificação de objetos em três dimensões. A maior parte dos atuais softwares de processamento de fotografias aéreas permite a exportação da nuvem de pontos gerada durante o processo de aerotriangulação em uma forma densificada, ou seja, em uma alta densidade de pontos. Essas nuvens de pontos apresentam informações tridimensionais dos elementos encontrados sobre a superfície do solo, assim como os valores de cor originais das ortofotos, sendo, portanto, possíveis de processamentos para extração de informações de forma semelhante ao que é feito com nuvens LiDAR.

Adicionalmente, essa técnica apresenta a possibilidade de obtenção de outros parâmetros da população, que tradicionalmente são estimados a partir da aplicação de técnicas de amostragem, como densidade de mudas, área de copa, indicativos de sanidade de floresta, entre outros. Portanto, recomenda-se que futuros trabalhos versem sobre o custo entre técnicas tradicionais de amostragem e manipulação de produtos obtidos por meio de VANT.

Conclusões

A identificação de mudas de *Eucalyptus* a partir da aplicação de redes neurais artificiais, utilizando-se o software Neurodic, em ortofoto obtida por veículo aéreo não tripulado (VANT) mostrou-se possível, desde que os resultados sejam pós-processados. O pós-processamento é necessário devido principalmente à ocorrência de alguns erros como a agregação de várias mudas em um único polígono, causando subestimativa, assim como da classificação errônea de feições como plantas competidoras e áreas na borda da imagem.

A classificação pelas redes neurais artificiais pós-processadas foi mais próxima à realidade em relação aos valores estimados a partir do espaçamento vital, portanto essa técnica fornece melhorias em relação às estimativas tradicionais do número de mudas em um talhão.

Agradecimentos

A empresa Klabin S.A. pela disponibilização dos dados utilizados neste trabalho.

Referências

- Araújo MA, Chavier F, Domingos JL (2006) Avaliação do potencial de produtos derivados de aeronaves não tripuladas na atividade florestal. *Ambiência*, 2: 69-82.
- Anderson K, Gaston KJ (2013) Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment*, 11(3): 138-146.
- Binoti MLMS (2010) *Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto*. Dissertação, Universidade Federal de Viçosa. 54p.
- Binoti DHB, Binoti MLMS (2014) *Redes Neurais Artificiais aplicadas à ciência florestal*. Instituto de Inovação em Engenharia e Meio Ambiente – AMBINOVA: Material de apoio. Viçosa, Minas Gerais. 1ª revisão. 83p.
- Braz AM, Borges JPS, Bernardes DCS, Terezan LH (2015) Análise da aplicação de VANT na atualização de cadastro florestal com uso de pontos de controle. In: *Simpósio brasileiro de sensoriamento remoto – SBSR, 17*, João Pessoa, Brasil.
- Campos MB, Tommaselli AMG, Moraes MVA de, Marcato JJ (2015) Análise Comparativa dos Resultados Obtidos pelos Métodos de Calibração de Campo Tridimensional e Bidimensional. *Boletim de Ciências Geodésicas*, 21(2): 308-328.
- Chagas CS, Vieira CAO, Fernandes Filho EI, Junior WC (2009) Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. *Revista Brasileira de Engenharia Agrícola Ambiental*, 13(3): 319-327.
- Chaves AA, Scalea RAL, Colturato AB, Kawabata CLO, Furtado EL, Branco KRLJC (2015) Uso de VANTs e processamento digital de imagens para a quantificação de áreas de solo e de vegetação. In: *Simpósio brasileiro de sensoriamento remoto, – SBSR, 17*, João Pessoa, Brasil.
- Cunha JEBL, Rufino IAA, Silva BBS, Chaves IB (2012) Dinâmica da cobertura vegetal para a Bacia de São João do Rio do Peixe, PB, utilizando-se sensoriamento remoto. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 16(5): 539–548.
- Eberhardt IDR, Luiz AJB, Formaggio AR, Sanches ID (2015) Detecção de áreas agrícolas em tempo quase real com imagens Modis. *Pesquisa Agropecuária Brasileira*, 50(7): 605-614.
- Ezequiel CAF, Cua M, Libatique N, Tangonan G, Honrado JL, Favila C, Novilla J, Ilaga EJ, Alampay R, Canos V, Labugen R, Devaney C, Loreto A, Bacusmo J, Lasquites JJ, Bencure JC, Palma BA, Raga-as M (2015) Aerial imaging consortium: augmenting ground observation with UAS remote sensing for environmental resource management. *Journal of the Philippine Geoscience and Remote Sensing Society*, 1: 12 - 20.
- Favarin JAS, Pereira RS, Pegoraro AJ, Lippert DB (2013) Obtenção de fotografias aéreas de um povoamento de *Pinus taeda* L. com o VANT Microdrone MD4-1000. In: *Simpósio brasileiro de sensoriamento remoto - SBSR, 16*, Foz do Iguaçu, Brasil.
- Gonçalves JA, Henriques R (2015) UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104: 101-111.
- Henriques MJ, Manta J, Marnoto J (2015) Avaliação da qualidade posicional: aplicação a um levantamento realizado em Coimbra utilizando VANT. *Atas das I Jornadas Lusófonas de Ciências e Tecnologias de Informação Geográfica*, 10(43): 722-747.
- INSTITUTO AGRONÔMICO DO PARANÁ (IAPAR). *Cartas climáticas do Estado do Paraná*. 2012. Disponível em: <http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=677>. Acesso em: 15/02/2016.

- INDUSTRIA BRASILEIRA DE ÁRVORES (IBÁ). *Relatório IBÁ 2016*. 2016. Disponível em: http://iba.org/images/shared/Biblioteca/IBA_RelatorioAnual2016_.pdf. Acesso em: 17/10/2016.
- Lehmann JRK, Nieberding F, Prinz T, Knoth C (2015) Analysis of unmanned aerial system-based CIR images in forestry - A new perspective to monitor pest infestation levels. *Forests*, 6: 594-612.
- Luz CC (2015) *Avaliação da exatidão absoluta de ortofoto obtida por meio de dados brutos oriundos de veículos aéreos não tripulados (SISVANT)*. Dissertação, Universidade Federal do Paraná. 118p.
- Macedo RC, Santos JR, Fonseca LM, Almeida CM, Soares JV (2012) Delimitação de copas em florestas clonais de *Eucalyptus sp.* através de classificação baseada em objeto. *Revista Técnica do IEP*, 5: 37 – 43.
- Macedo RC, Santos JR, Soares JV (2013) Treex (tree extractor) – uma ferramenta para análise de dossel florestal e contagem de árvores a partir de dados lidar. *Revista Brasileira de Cartografia*, 6(4): 627-634.
- Marcato Júnior J (2011) *Fototriangulação em bloco de imagens orbitais com modelos rigorosos baseados em pontos e retas*. Dissertação, Universidade Estadual de São Paulo. 119p.
- Oliveira LT, Oliveira TCA, Carvalho LMT, Batista VTFP, Ferreira MZ (2014) Influência da idade na contagem de árvores de *Eucalyptus sp.* com dados de LiDAR. *Cerne*, 20(4): 557-565.
- Rango A, Laliberte A, Herrick JE, Winters C, Havstad K, Steele C, Browning D (2009) Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. *Journal of Applied Remote Sensing*, 3(1): 033542. Doi: 10.1117 / 1.3216822.
- Resende MR, Bernucci LLB, Quintanilha JA (2012) Classificação híbrida: Pixel a pixel e baseada em objetos para o monitoramento da condição da superfície dos pavimentos rodoviários. *Boletim de Ciências Geodésicas*, 18(3): 397 - 420.
- Riveiro B, González-Jorge H, Varela M, Jauregui DV (2013) Validation of terrestrial laser scanning and photogrammetry techniques for the measurement of vertical underclearance and beam geometry in structural inspection of bridges. *Measurement*, 46(1): 784–794.
- Sakari T, Balazs A, Saari H, Polonen I, Sarkeala J, Viitala R (2015) Unmanned aerial system imagery and photogrammetric canopy height data in area-based estimation of forest variables. *Silva Fennica*, 49(5): 1-19.
- Sanquetta CR, Corte APD, Rodrigues AL, Watzlawick LF (2014) *Inventários florestais: planejamento e execução*. 3th Edition. Curitiba: Multi-Graphic Gráfica e Editora. 406p.
- Santos JC (2005) *Plano Diretor de Desenvolvimento de Telêmaco Borba*. Assessoria de Planejamento Urbano, p. 122.
- Saraiva SV, Amorim RF, Carvalho FO, Domingues L (2014) Prognóstico de Radiação Solar Através Modelos que Combinam as Técnicas Wavelet e Redes Neurais. *Revista Brasileira de Geografia Física*, 7(5): 808-817.
- She T, Ehsani R, Robbins J, Leiva JN, Owen J (2014) Applications of Small UAV Systems for Tree and Nursery Inventory Management. In: *12th International Conference on Precision Agriculture*. Sacramento, EUA.
- Silva SLA, Tommaselli AMG, Artero A (2014) Utilização de Alvos Codificados do tipo Aruco na Automatização do Processo de Calibração de Câmaras. *Boletim de Ciências Geodésicas*, 20(3): 636-656.
- Silva CA, Souto MVS, Duarte CR, Bicho CP, Sabadia JAB (2015) Avaliação da acurácia dos ortomosaico e modelos digitais do terreno gerados pelo MVANT/DNPM. *Revista Brasileira de Cartografia*, 67(7): 1479-1495.
- Silva PHM, Poggiani F, Silva AA, Prada Neto I, Paula RC (2015) Mortalidade, crescimento e solução do solo em eucalipto com aplicação de fertilizante de liberação lenta. *Cerne*, 21(3): 473-481.
- Soares P, Firmino P, Tomé M, Campagnolo M, Oliveira J, Oliveira B, Araújo J, Câmara F (2015) A utilização de Veículos Aéreos Não Tripulados no inventário florestal – o caso do montado de sobro. In: *Conferência Nacional de Cartografia e Geodesia-CNCG*, 8, Lisboa, Portugal.
- Sousa AMO, Gonçalves AC, Silva JRM, Mesquita P (2010) Segmentação e classificação de tipologias florestais a partir de imagens Quickbird. *Ambiência*, 6: 57-66.
- Stark B, Chen Y (2014) Optimal Collection of High Resolution Aerial Imagery with Unmanned Aerial Systems. In: *International Conference on Unmanned Aircraft Systems*, Orlando, Estados Unidos da América.
- Torres-Sánchez J, López-Granados F, Serrano N, Arquero O, Peña JM (2015) High-throughput 3-D monitoring of agricultural-tree plantations with unmanned aerial vehicle (UAV) technology. *Plos ONE*, 10(6), e 0130479.
- Vepakomma U, Cormier D (2015) Inventorying the forest: Laser scanning vs close range photogrammetry on a UAV. In: *14th conference in a series focusing on Lidar Applications for assessing and Managing Forest Ecosystems – SilviLaser*, La Grande Motte, França.
- Wink C, Monteiro JC, Reinert DJ, Liberalesso E (2012) Parâmetros da copa e a sua relação com o diâmetro e altura das árvores de eucalipto em diferentes idades. *Scientia Forestalis*, 40(93): 57-67.