

IDENTIFICAÇÃO DE ESPÉCIES ARBÓREAS A PARTIR DE IMAGEM DE SENSORIAMENTO REMOTO

Caio Hamamura¹, Flávio Henrique Mendes², Jefferson Lordello Polizez³, Demóstenes Ferreira da Silva Filho⁴

¹ Programa de Pós-graduação em Recursos Florestais. Universidade de São Paulo, campus Piracicaba, caio.hamamura@usp.br, ² Programa de Pós-graduação em Recursos Florestais. Universidade de São Paulo, campus Piracicaba, friquemendes@usp.br, ³ Doutor em Geografia, Técnico de Laboratório, Universidade de São Paulo, campus Piracicaba, jlpolize@usp.br, ⁴ Professor Doutor, Departamento de Recursos Florestais, Universidade de São Paulo, campus Piracicaba, dfilho@usp.br.

RESUMO

O planejamento das espécies arborização urbana é essencial para o que os benefícios provenientes das árvores sejam maximizados e para que haja resiliência a mudanças climáticas. Este estudo teve como objetivo identificar árvores a nível de espécie, por meio de sensoriamento remoto com imagem RGB de altíssima resolução (drone 5 cm), datada em setembro de 2018, levando em consideração padrões espectrais, texturais e estruturais da copa. Os resultados mostraram que as palmeiras e as coníferas tiveram melhor diferenciação, com maior confusão entre as folhosas que apresentaram maior variabilidade. Apresentamos um novo tipo de gráfico de radar para análise de dados multivariados, possibilitando melhor compreensão do problema da classificação.

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

ABSTRACT

Urban tree planting planning is essential to maximize benefits from trees and to provide resilience to climate changes. The aim of this study was to identify trees at the species level, by means of remote sensing with very high spatial resolution RGB imagery (drone 5 cm), dated September 2018, considering spectral, textural and structural patterns of the crowns. The results showed that the palm trees and conifers were better characterized, whereas broadleaved presented confusion due to higher variability. We present a novel type of radar plot for analyzing multivariate data, which allows better comprehension over the classification issues.

Key words – Urban forestry, drone, very high-resolution image, spectral patterns, tree canopy.

1. INTRODUÇÃO

A arborização urbana é parte integrante das cidades. Muitas vezes, o tema é esquecido durante o planejamento urbano, o que compromete os benefícios provenientes da vegetação [1], como regulação microclimática, retenção de poluentes, ambientes esteticamente mais agradáveis entre outros [2]. Muitos desses benefícios são sensíveis ao porte e a espécie plantada. No entanto, ainda não se estabeleceram

metodologias robustas para se especializar as espécies de maneira mais rápida e menos onerosa que o inventário.

Neste contexto, o presente trabalho analisa a possibilidade de se classificar espécies arbóreas por meio de imagens aéreas RGB de altíssima resolução.

2. MATERIAIS E MÉTODOS

Foi utilizada uma imagem RGB de alta resolução (5 cm, sobrevoou Drone eBee Classic, num teste de campo da empresa Santiago Cintra), datada de 10 de setembro de 2013, no campus da Escola Superior de Agricultura "Luiz de Queiroz", da Universidade de São Paulo (ESALQ/USP).

Inicialmente, foram identificadas as árvores reconhecíveis na imagem em que se podia identificar os limites de sua copa. A partir dessa amostra, as árvores foram identificadas em campo por reconhecimento de um analista experiente. Do total da amostra, foram escolhidas apenas as árvores de espécies que possuíam pelo menos 5 indivíduos. A Figura 1 demonstra uma faixa de árvores vetorizadas manualmente segundo a metodologia proposta.



Figura 1: Imagem demonstrando a vetorização manual das árvores resultante da metodologia proposta.

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

Das camadas RGB, HSV e PC, também foram calculadas métricas texturais, utilizando a matriz de co-ocorrência de níveis de cinza (GLCM), obtendo-se valores de contraste, homogeneidade, correlação, energia, entropia e dissimilaridade. Para gerar as matrizes de co-ocorrência, não se utilizou janelas de tamanho arbitrários, mas foram

utilizados os pixels dentro da vetorização. Derivamos dados do perfil longitudinal das árvores, a partir do azimute, dados que se mostraram importantes para a classificação de espécies em estudo anterior [3].

Para selecionar as variáveis mais relevantes realizamos uma seleção em duas fases. Na primeira fase, por meio de análise de autocorrelação, removendo as variáveis que com $R < -0,8$ ou $R > 0,8$, para reduzir a redundância.

Na segunda fase, utilizamos o índice de importância obtido pelo classificador Random Forest, escolhendo as n variáveis melhores posicionadas. Esse algoritmo foi utilizado com base em análises prévias que demonstraram ser o classificador que apresentou menor problema de sobreajustamento (*overfitting*), resultando em melhor acurácia. Para selecionar o número ideal de variáveis para o modelo, analisamos o gráfico de acurácia em relação ao número de variáveis escolhidas, selecionando o menor número de variáveis a partir do qual a acurácia tende a estabilizar. A acurácia foi calculada pela média de 100 corridas de validação cruzada com particionamento aleatório de 70% para as amostras de cada classe para treinamento e 30% para teste.

A partir dessa análise realizamos a classificação dos dados por meio do algoritmo Random Forest. O resultado da classificação então foi analisado com base na matriz de erros e da análise exploratória com a proposição de uma nova modalidade de gráfico proposta neste trabalho que permite uma boa visão geral sobre dados multivariados.

Esse gráfico, une os conceitos do boxplot e do radar. O radar clássico é demonstrado em termos de variação dentro do grupo por meio de áreas de duas cores distintas, uma representando a variação dentro dos percentis 25-75% e outra representando a amplitude total, além disso, assim como o boxplot, apresenta os outliers como pontos. Para que o gráfico tenha maior legibilidade e comparabilidade entre as variáveis, todas as variáveis são padronizadas para valores entre 0,1 a 1, sendo que a amplitude do gráfico vai de 0 a 1, isso para evitar que vários pontos se sobreponham caso diversas variáveis apresentem valores baixos.

3. RESULTADOS

Foram identificadas e mapeadas as seguintes espécies: *Cupressus sempervirens* (Cipreste italiano), *Eugenia uniflora* (Pitangueira), *Plinia cauliflora* (Jaboticaba sabará), *Handroanthus heptaphylla* (Ipê roxo), *Handroanthus roseo alba* (Ipê branco), *Roystonea oleracea* (Palmeira Imperial), *Psidium cattleianum* (Araçá), *Livistona chinensis* (Palmeira leque), *Thuja occidentalis* (Cedrinho), *Lafoensia glyptocarpa* (Mirindiba), *Phoenix sp.* (Palmeira fênix), *Archontophoenix alexandrae* (Seafortia), *Paubrasilia echinata* (Pau-Brasil), *Poincianella pluviosa* (Sibipiruna), *Pachira aquatica* (Munguba), *Syagrus romanzoffiana* (Jerivá).

No total, foram derivadas 84 variáveis da imagem original RGB. Após a filtragem das variáveis com $R < -0,8$ ou $R > 0,8$, restaram 23. Analisando o gráfico de incremento de acurácia com a inclusão das variáveis em ordem de importância (Figura 2), notamos uma tendência de estabilização da após a inclusão de 10 variáveis no modelo. As 10 variáveis escolhidas para gerar o modelo estão descritas

na Tabela 1.

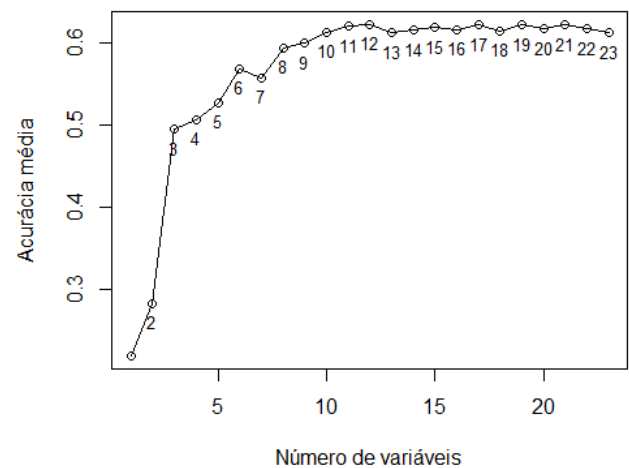


Figura 2: Gráfico demonstrando o incremento de acurácia em relação ao número de variáveis utilizando o classificador Random Forest

Tabela 1: Tabela de variáveis mais importantes escolhidas para gerar o classificador Random Forest

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

Utilizando as variáveis selecionadas é possível analisar o comportamento delas dentro de cada classe por meio do gráfico radar-boxplot (Figura 3). O gráfico apresenta uma área em vermelho que demonstra a distribuição dos percentis 25-85% e uma área em azul representando a amplitude, além dos outliers como definido em um boxplot e representado por pontos.

A classificação Random Forest atingiu acurácia geral de 61,87%, com um índice Kappa de 0,5887. A análise detalhada da confusão entre as classes e as acurácias de cada uma pode ser realizada pela matriz de erros da Figura 2.

4. DISCUSSÃO

A metodologia apresentada mostrou-se eficiente para classificar cinco espécies das 16 encontradas, obtendo mais de 80% de acurácia na determinação destas. A acurácia geral foi baixa, se situando em torno de 60%. Este fato pode ter decorrido da limitação no tamanho amostral, devido a baixa repetição de espécies dentro do campus, além disso, algumas árvores da mesma espécie apresentavam em estados fisiológicos bem distintos, conforme podemos observar em relação as Mirindibas na Figura 1, algo semelhante ocorreu

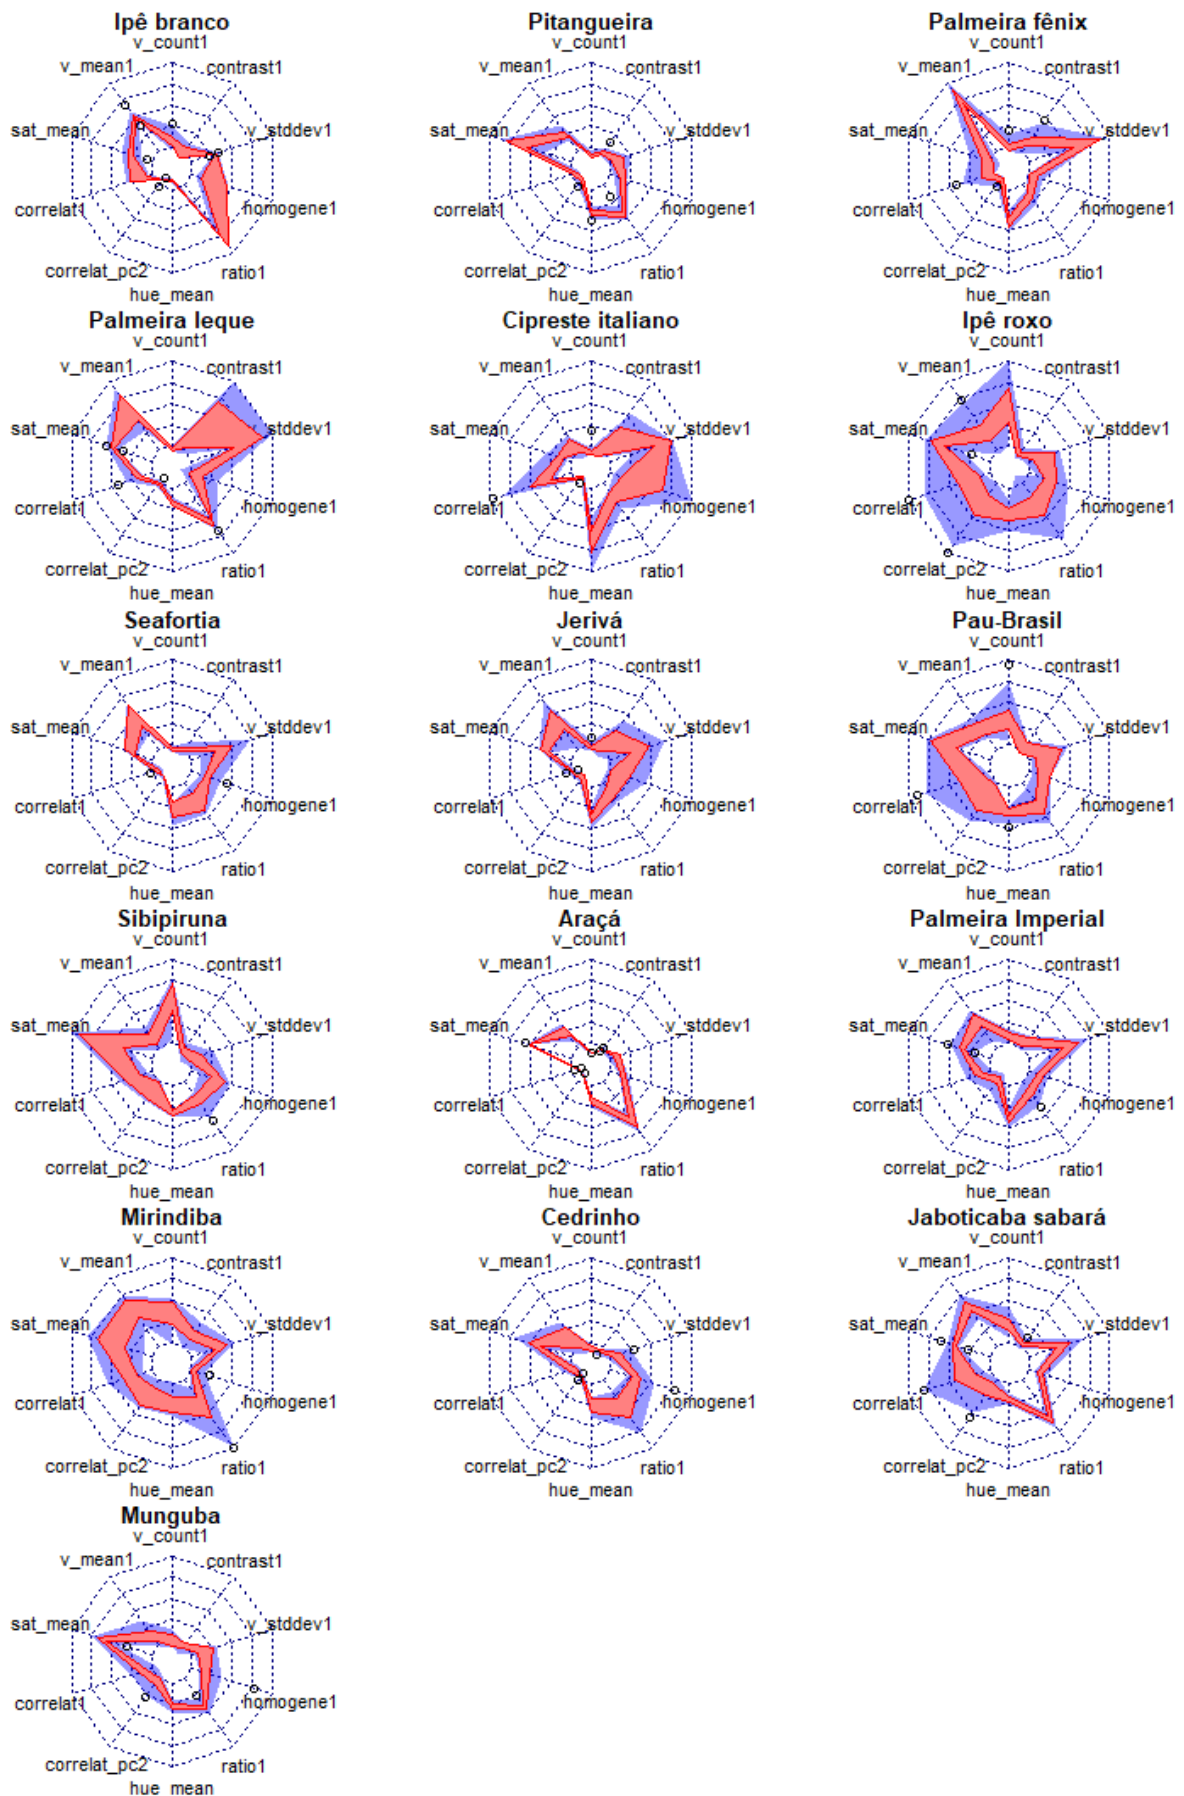


Figura 3: Gráfico de radar-boxplot. A área em rosa mostra-se a variabilidade da variável dentro dos percentis 25-75%. a área em

Tabela 2: Matriz de erros, as classes correspondem a: A - Araçá, Ce - Cedrinho, Ci - Cipreste italiano, Ib - Ipê-branco, Ir - Ipê-roxo, Ja - Jaboticaba-sabará, Je - Jerivá, Mi - Mirindiba, Mu - Mulunguba, Pf - Palmeira-fênix, Pi - Palmeira imperial, Pl - Palmeira-leque, Pb - Pau-brasil, Pt - Pitanga, Se - Seafortia, Si - Sibipiruna

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

com o Ipê-roxo. Isso pode ser atribuído a uma estiagem no mês anterior de Agosto de 2013, com precipitação de apenas 2,5mm acumulados durante todo o mês [4].

O gráfico radar-boxplot (Figura 3) proposto, mostra-se bastante interessante para entender o comportamento das espécies quanto a múltiplas variáveis simultaneamente, permitindo compreender os resultados da classificação e da matriz de erros. A exemplo da Pitangueira, que a apresentou acurácia do usuário de apenas 20% e acurácia do produtor de 25%, é possível apreender pelo gráfico que o seu comportamento em relação as variáveis apresentadas é muito semelhante ao do Araçá. Nota-se uma grande variabilidade em relação ao comportamento do Ipê-roxo e do Pau-brasil, tanto é que foram as duas espécies que apresentaram menor acurácia do usuário.

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

Diferentemente do padrão estabelecido no trabalho de Zhang e Hu [3], neste caso não foi possível verificar ganhos para a classificação utilizando a análise do perfil longitudinal das espécies arbóreas. Este fato pode ter ocorrido pelo fato de a imagem utilizada não ter sido ortorretificada. Além disso, o estudo foi realizado em Toronto, Canadá, apresentando espécies coníferas e de climas temperados que costumam apresentar copas com formas que ressaltam mais as diferenças de reflectância entre a face voltada para o Sol e a face

sombreada.

É importante salientar que o estudo foi realizado com fotografias RGB simples e, ainda assim, obteve resultados que indicam a possibilidade de se aplicar essa metodologia, sobretudo se utilizar mais dados como dados multitemporais para analisar os diferentes estados da fenologia das espécies.

5. CONCLUSÕES

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

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

6. REFERÊNCIAS

- [1] BUCKERIDGE, M. Árvores urbanas em são paulo: planejamento, economia e água. *estudos avançados*, SciELO Brasil, v. 29, n. 84, p. 85–101, 2015.
- [2] BURDEN, D. *Urban Street Trees 22 Benefits*. Orlando, USA, 2006. Disponível em: <http://www.walkable.org/download/22_benefits.pdf>.
- [3] ZHANG, K.; HU, B. Individual Urban Tree Species Classification Using Very High Spatial Resolution Airborne Multi-Spectral Imagery Using Longitudinal Profiles. *REMOTE SENSING*, v. 4, n. 6, p. 1741–1757, jun 2012. ISSN 2072-4292.
- [4] LEB - ESALQ - USP. *Série de Dados Climatológicos do Campus Luíz de Queiroz de Piracicaba, SP*. Piracicaba, SP: Universidade de São Paulo, 2018.