

Banco de imagens de lâminas foliares de espécies do Cerrado: técnicas de extração e classificação de imagens por visão computacional

Deborah R. Bambil^{1,*}, Hemerson Pistori², Francielli Bao³ e Ieda M. Bortolotto¹

¹ PPG Biologia Vegetal, Universidade Federal de Mato Grosso do Sul, Câmpus de Campo Grande, 79070-900, Campo Grande, MS Brasil.

² INOVISÃO, Universidade Católica Dom Bosco, 79117-900 , Campo Grande, MS Brasil.

³ Instituto de Biociências, Universidade Estadual Paulista Júlio de Mesquita Filho, Câmpus de Rio Claro, 13506-900, Rio Claro, SP, Brasil.

RESUMO

As características morfológicas das folhas de Angiospermas são importantes para identificar espécies. Variações nessas características podem diferenciar grandes grupos de plantas ou mesmo espécies e variedades. A visão computacional pode auxiliar o trabalho dos taxonomistas na extração de caracteres morfológicos e fazer a integração com métodos convencionais de taxonomistas. O objetivo deste estudo foi verificar a eficácia da visão computacional na classificação de lâminas foliares de espécies arbóreas e arbustivas do Cerrado através de caracteres (atributos) morfológicos. Foram coletadas 40 folhas de cada uma das 30 espécies arbóreas e arbustivas coletadas aleatoriamente na Reserva Particular de Patrimônio Natural, da Universidade Federal de Mato Grosso do Sul - UFMS, localizada no município de Campo Grande – MS. A vegetação nesta região é classificada como Cerrado, Cerradão e Mata de galeria. Foram feitas 80 imagens com câmera do celular e 80 com scanner de ambas as faces (adaxial e abaxial) das folhas, totalizando por espécie 160 imagens. No total o banco de imagens possui 4.800 imagens. Dessas imagens foram extraídos 226 atributos pelo código na linguagem em python desenvolvido pelo grupo Inovisão o python-extrai-atributos distribuídos em cor, forma e textura para fazer a classificação testando diferentes técnicas de aprendizagem de máquina com os algoritmos: *Support vector machine – SVM, Adaptive Boosting – AdaBoost, Random Forest*.

Palavras-chave: Aprendizagem de máquina; Atributos; Cor; Forma; Textura; Algoritmos; Classificação; Morfologia; Taxonomia.

Introdução

Tem sido utilizados métodos de observação de caracteres morfológicos para classificação de plantas, desde Teofrasto (Barroso 1986). Classificar para identificar é obter conhecimento, para um especialista em determinada família contextualizar tal informação é simples tratando do seu conhecimento prévio, todavia, para uma pessoa que não tem conhecimento sobre identificação de plantas essa realidade se torna exclusiva, e mesmo para botânicos saber identificar todas as espécies é incondicional, almejar conseguir esse feito ou parte dele, requer colaboração.

Propomos um método de informatizar esse conhecimento para que seja popularizado e atenda especialistas e não especialistas em botânica, auxiliando botânicos com uma ferramenta de identificação da qual ajudaria realizar os trabalhos florísticos, e incluir um grupo de pessoas que não tem conhecimento prévio sobre botânica mas tem necessidade de utilizar essa ferramenta para saber qual espécie científica dispõe para seu uso alimentício, medicinal, e outras finalidades que possa recorrer desse material, para isso usamos folíolos e folhas simples pensando que não seria preciso ter conhecimento sobre classificar as folhas como simples ou composta.

A taxonomia sempre foi amparada no extenso trabalho de revisão morfológica baseada na visão do observador, muitas vezes pautada por amostras com pouca resolução espacial. O emprego de tecnologia para auxiliar o trabalho dos taxonomistas na observação e extração de caracteres morfológicos é relevante para estudos de biodiversidade, onde uma destas técnicas é a visão computacional.

A área da visão computacional desenvolve bases matemáticas e algorítmicas pelas quais informações do ambiente ou objeto são extraídas de imagens para análise, processamento digital e reconhecimento de padrões por métodos analíticos e estatísticos

(Ponce & Forsyth 2012). São distintas as áreas que vem empregando seu uso. No contexto da biologia vegetal, estão sendo utilizados na classificação de pólenes através da extração de atributos de cor, textura e forma (Gonçalves *et al.* 2016), em estudos fenológicos (Mariano *et al.* 2016), medição automática de área foliar (Machado *et al.* 2016) e classificação de lâminas foliares (Lee & Chen 2006).

O ferramental analítico da visão computacional também é importante na atualidade pela expansão global de redes de pesquisas com parcelas permanentes (Malhi *et al.* 2002, Peacock *et al.* 2007). Nestas redes de pesquisas as amostragens nas parcelas permanentes resultam em uma quantidade enorme de material estéril (Classen-Bockhoff 2001, Hofer *et al.* 2001, Lee & Chen 2006), a integração da visão computacional a taxonomistas se torna um grande desafio para a ciência contemporânea (Hofer *et al.* 2001).

O uso da visão computacional permite o desenvolvimento de técnicas de aferição e extração de informações de forma automatizada de lâminas foliares (Lee & Chen 2006). O estudo foliar implica na coleta de inúmeros atributos como a largura e o comprimento, cor, textura e forma (Filho *et al.* 2014). Porém, a folha pode apresentar grande variação em seu padrão dentro de um mesmo espécie dificultando a taxonomia devido a suas estruturas e fatores ambientais como solo e iluminação (Plotze *et al.* 2005). A variação da presença de luz influencia diretamente no tamanho e na forma de folhas, o que gera inúmeras dificuldades em torno da identificação (Joppa *et al.* 2011). Respostas assimétricas conduzem à plasticidade fenotípica e não somente a luz pode causar este efeito, por conta desta plasticidade até mesmo em folhas de um mesmo indivíduo podem diferir quando situados em determinados ambientes (Guerin *et al.* 2012).

O Cerrado é considerado um *hotspot* de biodiversidade (Myers *et al.* 2000), apresenta uma variedade de fisionomias: Cerrado *sensu strictu*, Cerradão e Mata de Galeria (Simon *et al.* 2009), que são caracterizadas por formações campestres, savânicas e florestais (Durigan *et al.* 2007), onde são encontradas espécies em locais abertos e fechados que recebem diferentes intensidade de luz, o que afeta a forma como as espécies usam este recurso (Ribeiro & Walter 2008), aumentando a variedade morfológica de suas folhas. A elevada diversidade de espécies vegetais no Cerrado são um desafio para os sistemas computacionais (Lee & Chen 2006).

Os bancos de dados sobre folhas coletadas em áreas com grande diversidade biológica, se bem organizados, se constituem num repositório de informações para estudos na área de Botânica. A possibilidade de se formarem bancos de dados com informações de identificação de espécies através da captura de imagens, requer um esforço para elaboração, onde primeiramente deve-se ter conhecimento de técnicas de coleta de imagem, extração e classificação de atributos.

Diante desse preceito, o objetivo deste estudo foi verificar a eficácia da visão computacional na identificação de lâminas foliares de espécies arbóreas e arbustivas do Cerrado. Para tanto buscamos responder às seguintes questões: (i) Existe diferença nos resultados de imagens digitalizadas com scanner e fotos de câmera de celular para aplicação na identificação de espécies com base na classificação de lâminas foliares? (ii) Qual algoritmo de aprendizagem automática (*Support vector machine – SVM, Adaptive Boosting – AdaBoost, Random Forest*) apresenta melhor desempenho para classificar lâminas de folhas usando atributos de cor, forma e textura?

Material e Métodos

Área de estudo

O estudo foi realizado na Reserva Particular de Patrimônio Natural (20°27'S, 54°37'W) da Universidade Federal de Mato Grosso do Sul - UFMS, localizada no município de Campo Grande, MS - Brasil.. Essa reserva tem área de 40 hectares, e possui diferentes fisionomias: Cerrado, Cerradão e Mata de Galeria (Bueno *et al.* 2013). O clima é AW savanna tropical chuvoso (Koeppen 1948), com temperatura média anual de 23°C (Embrapa 1985).

Coleta das lâminas foliares em campo

Foi delimitada uma área de 0.5 ha, onde foram realizadas coletas de 40 amostras de folíolos e folhas de árvores e arbustos de 30 espécies sendo amostrado um indivíduo por espécie (Fig.1), indivíduos lenhosos com diâmetro à altura do peito (DAP) $\geq 4,77$ cm, as espécies já haviam sido previamente identificadas e exemplares estão depositados no herbário CGMS (Universidade Federal de Mato Grosso do Sul) (Bueno *et al.* 2013). As espécies amostradas foram:

- 1. Anacardiaceae - *Astronium fraxinifolium*;
- 2. Annonaceae - *Annona crassiflora*, *A. coriacea*, *Xylopia aromatica*;
- 3. Bignoniaceae - *Tabebuia aurea*;
- 4. Caryocaraceae - *Caryocar brasiliense*;
- 5. Chrysobalanaceae - *Licania humilis*;
- 6. Combretaceae - *Terminalia argentea*;
- 7. Connaraceae - *Connarus suberosus*;
- 8. Dilleniaceae - *Curatella americana*;
- 9. Fabaceae - *Andira cuyabensis*, *Bowdichia virgilioides*, *Copaifera langsdorffii*,
Dimorphandra mollis, *Diptychandra aurantiaca*, *Stryphnodendron obovatum*;
- 10. Lythraceae - *Lafoensia pacari*;
- 11. Malpighiaceae - *Byrsonima coccolobifolia*, *B. verbascifolia*;

- 12. Malvaceae - *Eriotheca pucescens*, *Pseudobombax* sp.;
- 13. Melastomataceae - *Miconia albicans*;
- 14. Myrtaceae - *Eugenia* sp.;
- 15. Opiliaceae - *Agonandra brasiliensis*;
- 16. Rhamnaceae - *Rhamnidium elaeocarpum*;
- 17. Sapindaceae - *Matayba guianenses*;
- 18. Sapotaceae - *Chrysophyllum marginatum*;
- 19. Vochysiaceae - *Qualea grandiflora*, *Qualea multiflora*, *Salvertia convallariodora*.

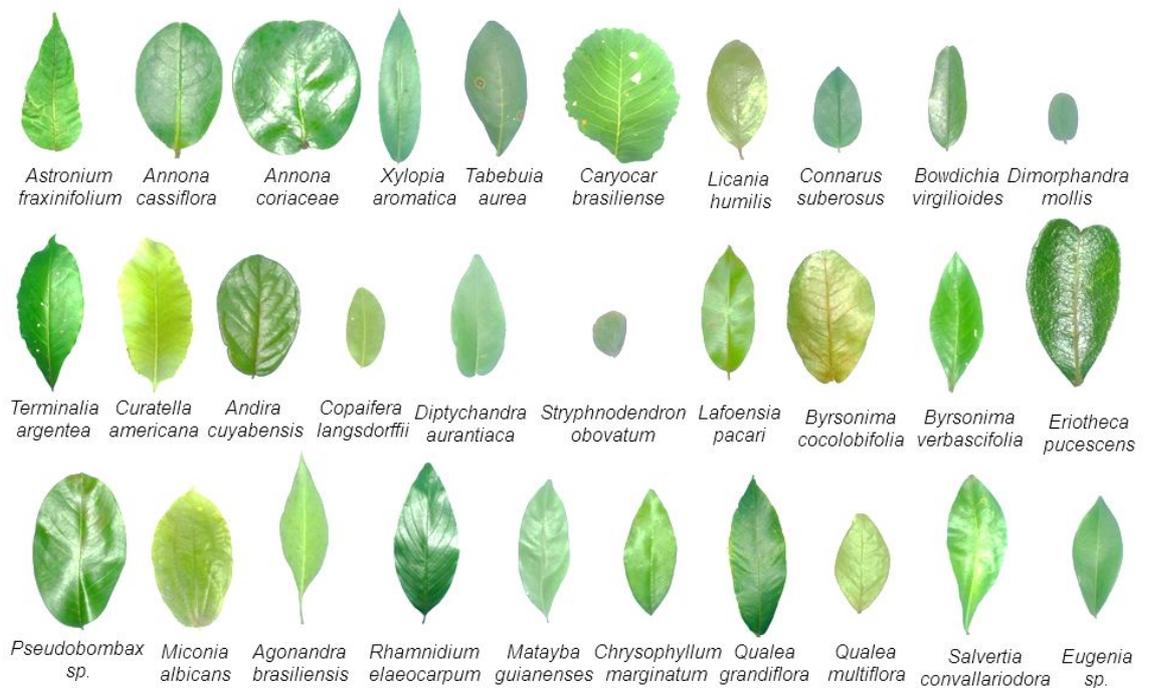


FIGURA 1. Lâminas foliares.

Captura e processamento das imagens

Para avaliação do método de captura de imagens foram utilizados: aparelho de celular (Kumar *et al.* 2012) e scanner (Plotze *et al.* 2005). As imagens foram feitas de ambas as faces das lâminas foliares (adaxial e abaxial). O aparelho de celular (modelo: lumia 820, com câmera de 8 mega pixels), foi instalado em suporte com ângulo de 90° a

20 cm das folhas, com fundo branco, flash do aparelho, a resolução da imagem foi de 2000 x 3552 pixels (Fig.2A). Da mesma forma foi feito com o scanner (modelo: HP Scanjet G2710), ambas as faces das lâminas foliares foram digitalizadas, com fundo branco e resolução de imagem de 2550 x 3510 pixels (Fig.2B). Foram capturadas 160 imagens de cada espécie (80 do aparelho celular e 80 do scanner de ambas as faces). A captura total das amostras resultou em um banco com 4.800 imagens.

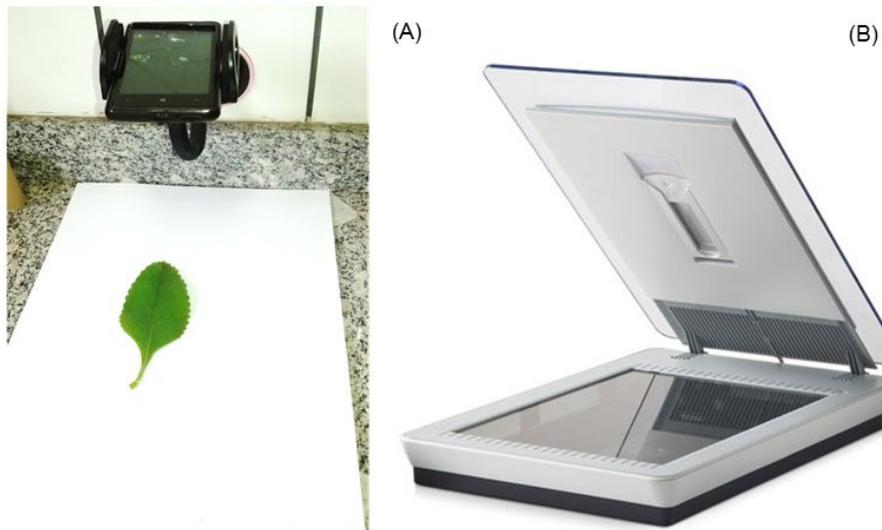


FIGURA 2. Aparelhos para captura de imagens. (A) aparelho de celular Lumia fixo no suporte e (B) Scanner HP Scanjet G2710.

Após a coleta das folhas o material foi processado fresco para manter seus aspectos originais. Após a captura de imagens, foi realizada a extração e a classificação dos atributos.

Extração de Atributos das imagens

A extração dos atributos foi feita através dos valores extraídos de cada pixel das imagens, no total foram extraídos 226 atributos de cada imagem (Tabela 1S) usando o código em python desenvolvido pelo grupo Inovisão o python-extrai-atributos. Para

verificar a classificação das lâminas foliares, nós testamos os atributos referentes à cor, a forma e a textura, detalhados abaixo:

Cor: RGB, HSV e Cielab (Mín., Máx., média e Desvio). RGB: vermelho “R”, verde “G” e azul “B” utilizado para especificar as cores primárias (Kruse *et al.* 2014). HSV: Utiliza para especificar matiz “H” associação das principais cores, como azul, vermelho, amarelo, verde e roxo. Saturação “S” indica que quanto maior a saturação mais viva é a cor. Valor “V” classifica a cor quanto clara ou escura, assim quanto maior o valor, mais clara é a cor (Filho *et al.* 2014).

CIELab: CIE são os padrões de cores criados e Lab são os componentes avaliados (L= tons de branco e preto; +A= tons de amarelo; -A= tons de azul; +B= tons de vermelho; -B= tons de verde (Kruse *et al.* 2014). São criadas elipses em espaços de cores, onde é calculada a distância euclidiana dentro de cada elipse.

Forma: o descritor de forma detectou as bordas para extrair o contorno da imagem. Foram extraídos os 7 momentos de Hu - características invariantes à escala, translação e rotação, a importância de analisar estes 7 momentos invariantes se caracteriza por poder identificar a região independente da escala, translação e rotação.

Orientação por histograma de gradientes orientados – HOG, representa um descritor de conteúdo de imagem que vem sendo usado com a pretensão de encontrar objetos, para isso é feita uma busca por mudanças de tonalidade (Arafat *et al.* 2016). No gradiente os tons mais baixos são mais escuros e os tons mais altos são mais claros, o gradiente da imagem é calculado por vetores selecionados em cada ponto da imagem identificando para onde está a maior inclinação (Barbu 2012).

Os atributos de textura: são os padrões de similaridade compostos por luminosidade, uniformidade, densidade, aspereza, regularidade, frequência, fase, suavidade e granulação (Mattila *et al.* 2013). Foi calculado por matrizes de co-

ocorrência em determinadas distâncias e ângulos em pontos selecionados, contabilizando a co-ocorrência de tons para cada distância e cada ângulo percorrendo a imagem por completo com contrastes, dissimilaridades, homogeneidades, ASM, energias e correlações (Filho *et al.* 2014).

E Padrão binário local – LBP um descritor de textura que pode filtrar bordas usando o conceito de padrão uniforme (Zhou *et al.* 2012). O código de um pixel é obtido por comparação com a intensidade de seus vizinhos por classificar a textura em escala de cinza, o que possibilita lidar com a variação de iluminação (Pahikkala *et al.* 2015).

Classificação da imagem com algoritmos de aprendizagem de máquina

Para classificação dos atributos foram testados três algoritmos de aprendizagem de máquina diferentes no Software Weka 3.7.9, sendo eles: SVM, AdaBoost e Random Forest (Gonçalves *et al.* 2016, Arafat *et al.* 2016). A função do algoritmo é resolver um problema no nosso caso classificar atributos de imagens. Para validar a aprendizagem de máquina usamos validação cruzada – CV (10 dobras) (Gonçalves *et al.* 2016).

SVM: Esse algoritmo resolve problemas de imagens, regiões, otimiza o tempo para aprendizagem, desempenhando uma metodologia iterativa para resolver problemas de programação quadrática da máquina de vetor de suporte – SVM (Mattila *et al.* 2013).

O SVM delimita uma linha chamada hiperplano que separa os dados de duas classes (Fig. 3), a distância desse hiperplano é definida com uma margem estabelecida por vetores de suporte (Fig. 3). A separação entre as classes é feita com melhor desempenho que o hiperplano pode alcançar na separação do conjunto de dados (Kremic & Subasi 2016).

Na classificação de dados de múltiplas classes ele se adapta particionando N classes em dois grupos, um grupo é formado por uma classe e outro grupo por todas as classes restantes. Um classificador é treinado com estes dois grupos e este procedimento é repetido para cada uma das N classes (Arafat *et al.* 2016).

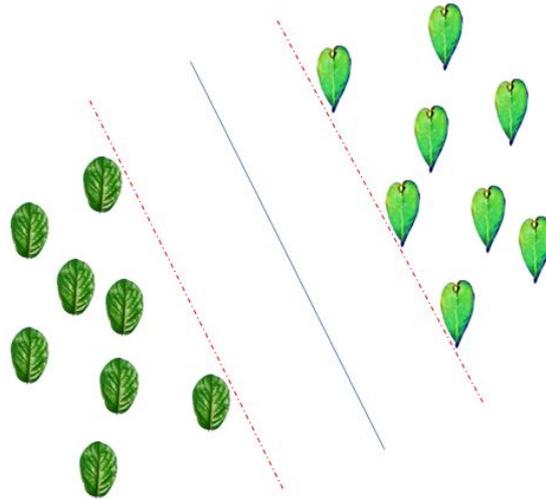


FIGURA 3. Classificador SVM. Hiperplano com margem de separação, as folhas representam os vetores de suporte.

AdaBoost: este algoritmo seleciona os dados particionando em múltiplos conjuntos, por seleção de características constrói múltiplos classificadores, (Kumar *et al.* 2008), se adapta positivamente ao se deparar com instâncias classificadas negativamente em classificações feitas no ciclo anterior (Fig.4) (González *et al.* 2008). Recerbe peso em novas tentativas de classificar corretamente construindo um classificador forte (Malhi *et al.* 2013).

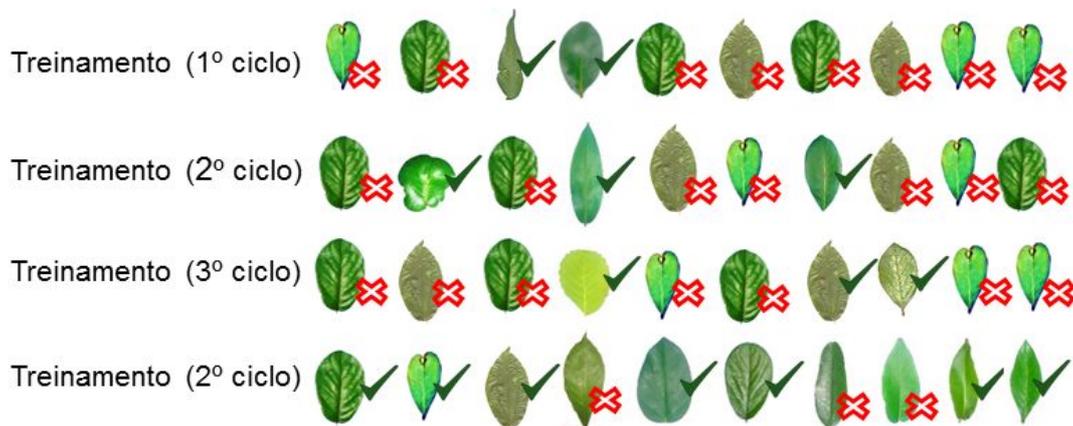


FIGURA 4. AdaBoost treinando seus dados (classificadores negados tentando repetir o ciclo até conseguirem ser classificados positivamente).

Random Forest : O método usado de aprendizagem desse algoritmo proporciona precisão, executa com eficiência quando trabalha com uma base de dados robusta (Manfredi *et al.* 2014). Faz a classificação dividindo os atributos dos dados formando um conjunto de árvores e é escolhida a floresta com a classificação que tem maior número de árvores (Fig.5) (Kremic & Subasi 2016).

Classifica o que for essencial para explorar os dados formando conjuntos de árvores, e mesmo quando ocorre formação de modelos fracos esses são reunidos para aprendizagem da formação de um modelo forte (Corcoran *et al.* 2013).

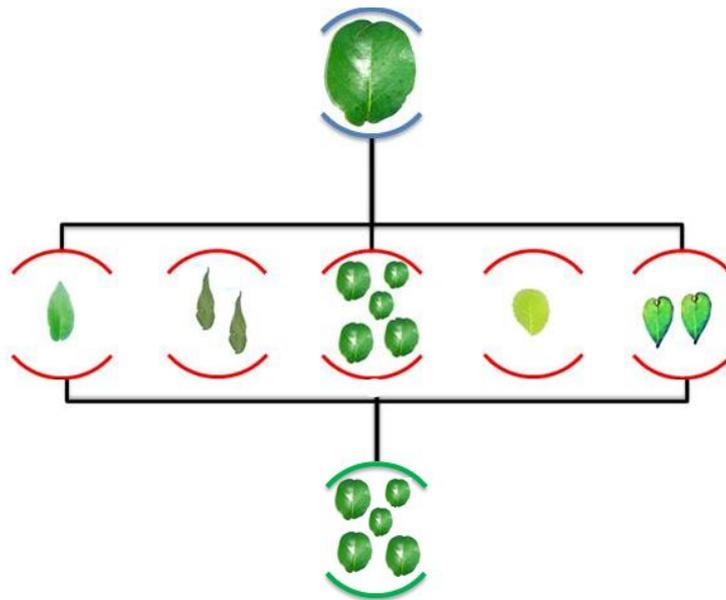


FIGURA 5. Floresta aleatória (Classificando os dados através da seleção da floresta com maior número de árvores).

Análise de dados

Os resultados foram analisados com Percentual de Classificação Correta – PCC que mostrou o resultado geral na classificação dos algoritmos.

Outra métrica usada para avaliar o desempenho dos algoritmos por classe (espécie) foi a medida – F, os resultados são do calculo das classes que foram avaliadas como verdadeiros positivos, falsos positivos e falsos negativos, sua fórmula usa a média de outras duas métricas precisão e recall (López-García *et al.* 2010):

$$F = \frac{2 * \text{precisão} * \text{revocação}}{\text{precisão} + \text{revocação}}$$

a métrica de precisão é a porcentagem de verdadeiro positivo – VP sobre classificações informadas como positivas – VP mais falso positivo – FP (Kruse *et al.* 2014):

$$\text{Precisão} = \frac{VP}{VP + FP}$$

a métrica de revocação é a porcentagem de classes positivas classificadas corretamente sobre o total classes classificadas como positivas (Kruse *et al.* 2014):

$$\text{Revocação} = \frac{VP}{VP + FN}$$

Para avaliar os resultados da medida-F de cada classe foi construído um modelo de estatística ANOVA no ambiente no ambiente R de programação estatística (R Development Core Team 2013), este modelo foi construído para quantificar as variações que ocorreram no experimento e o teste de Tukey para fazer análise de comparações das técnicas em pares (Gonçalves *et al.* 2016).

Outra forma de visualizar o desempenho individual de classificação de cada espécie é por meio da matriz de confusão. Ela apresenta o número de amostras classificadas (Arafat *et al.* 2016) para cada classe (espécie). O número de acerto de cada classe é observado quando a linha da classe informada corresponde a coluna da classe predita, os VP.

É possível encontrar claramente o número de acertos VP de cada classe, localizando a linha diagonal principal da matriz (Arafat *et al.* 2016). No caso da nossa

matriz de confusão a classe que obtiver 80 acertos quer dizer que obteve acerto total das amostras.

Resultados

Verificamos que existe eficácia da visão computacional na identificação de lâminas foliares de espécies arbóreas e arbustivas do Cerrado podendo ser observado com o resultado do Percentual de Classificação Correta (PCC):

Dispositivo de captura de imagem	SVM	Random Forest	AdaBoost
SCANNER	98%	95%	6%
CELULAR	96%	97%	6%

Métodos de captura de imagens: celular e scanner

Não existiu diferença nos resultados de imagens digitalizadas com scanner e fotos de câmera de celular para aplicação na identificação de espécies com base na classificação de lâminas foliares, conforme resultados (dos pares) apresentado análise estatística do teste tukey:

Dispositivo de captura de imagem	Valor de P
Scanner (SVM) – Celular (SVM)	0,2276976
Scanner (Random Forest) – Celular (Random Forest)	0,0977253
Scanner (AdaBoost) – Celular (AdaBoost)	0,9513343

Não houve diferença significativa na classificação das imagens entre os dispositivos de captura das mesmas.

Desempenho dos algoritmos de aprendizagem: Adaboost, Random Forest e SVM para da classificação de imagens usando os de atributos de cor, forma e textura

Apresentaram melhor desempenho para classificar lâminas de folhas os algoritmos Random Forest e SVM (Fig.6). O teste de hipótese da macro-média da medida-F mostrou que houve uma diferença significativa no desempenho de classificação entre os algoritmos (ANOVA: $P < 0,001$).

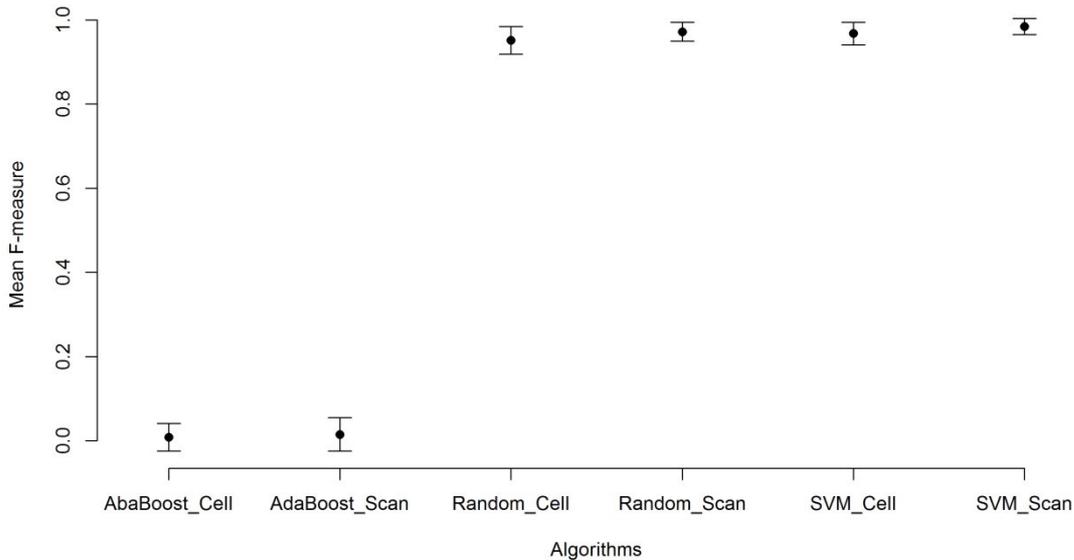


FIGURA 6. Gráfico Medida-F (mostra o desempenho dos algoritmos na classificação dos atributos, em ambos experimentos de captura de imagem).

O teste Tukey apresentou diferença significativa para os pares SVM – AdaBoost, Random Forest – AdaBoost. Para os pares SVM – Random Forest não houve diferença significativa (Tab).

Algoritmos de aprendizagem automatic	Valor de P
SVM – AdaBoost (scanner e celular)	0,00
Random Forest – AdaBoost (scanner e celular)	0,00
SVM – Random Forest (scanner e celular)	> 0,05

O SVM mostra na matriz de confusão acertos por espécie de 74 a 80 amostras (scanner e celular) onde 80 representa acerto total das amostras. As espécies que foram classificadas corretamente em todas as amostras foram:

Scanner (13 espécies): *Annona coriacea*; *Tabebuia aurea*; *Licania humilis*; *Connarus suberosus*; *Dimorphandra mollis*; *Lafoensia pacari*; *Byrsonima coccolobifolia*, *B. verbascifolia*; *Eriotheca pucescens*, *Pseudobombax* sp.; *Rhamnidium elaeocarpum*; *Chrysophyllum marginatum*; *Qualea grandiflora*. Na matriz de confusão é possível ver o desempenho individual de cada algoritmo com cada espécie (Fig.1S)

Celular (6 espécies): *Annona coriacea*; *Bowdichia virgilioides*, *Copaifera langsdorffii*, *Dimorphandra mollis*, *Stryphnodendron obovatum*; *Caryocar brasiliens*. Matriz de Confusão (Fig. 2S).

O algoritmo Random Forest obteve um desempenho semelhante (scanner e celular) variando em acerto das amostras de 74 a 80. As espécies que foram classificadas corretamente em todas as amostras (80) foram:

Scanner (10 espécies): *Annona coriacea*; *Tabebuia aurea*; *Licania humilis*; Fabaceae *Diptychandra aurantiaca*; Lythraceae *Lafoensia pacari*; *Pseudobombax* sp.; *Matayba guianenses*; *Qualea grandiflora*, *Qualea multiflora*; *Byrsonima coccolobifolia*. Matriz de confusão (Fig. 3S).

Celular (3 espécies): *Bowdichia virgilioides*, *Copaifera langsdorffii*, *Dimorphandra mollis*, *Stryphnodendron obovatum*. Matriz de confusão (Fig. 4S).

O AdaBoost classificou com scanner (3 espécies) *Terminalia argenta*, *Pseudobombax* sp. e *Bowdichia virgilioides* (16, 24 e 56 acertos de amostras) para as demais espécies não houve classificação (0) (Fig. 5S).

Com celular classificou (2 espécies) *Pseudobombax sp*; *Fabaceae Bowdichia virgilioides* (ambas com 80 acertos) para as demais não houve classificação (0) (Fig. 6S).

Discussão

O experimento mostrou que existe eficácia da visão computacional na identificação de lâminas foliares de espécies arbóreas e arbustivas do Cerrado, outros estudos testam diferentes métodos que também comprovam essa eficácia com outras espécies em diferentes fitofisionomias, como o LeafSnap, que faz a identificação extraíndo atributos da curvatura a partir das imagens de folhas (Kumar *et al.*2012).

Optamos utilizar 226 atributos distribuídos entre cor, forma e textura, de imagens de dois equipamentos diferentes de capturas de imagens junto a diferentes técnicas de aprendizagem de máquina para encontrarmos um método que fosse significativo para fazer classificações corretas do nosso banco de imagens de espécies do Cerrado.

Assim como, Filho *et al.* (2014) que para classificar de espécies florestais extraiu à variação de forma, disposição, funções e estruturas das folhas, considerando quanto mais atributos maior seria a variabilidade de características para lidar com problemas de classificação, lâminas foliares não são facilmente reconhecidas com apenas um método, mas combinando métodos possibilita o êxito na classificação correta (Mattila *et al.* 2013).

Avaliamos as características morfológicas das espécies do Cerrado de acordo com os atributos e recursos de captura de imagens para obter uma melhor técnica que realizaria com a maior precisão a classificação correta da espécie sem fazer

aproximação de espécie. Diferente de Kumar *et al.* 2012 que usa dados comparando com os já existentes no banco de imagens do aplicativo respondendo com a espécie ou espécies mais próximas, como se buscasse a espécie com a maior similaridade àquela analisada usando um método de aproximação.

Métodos de captura de imagens: celular e scanner

Diante de diferentes métodos de captura de imagens disponíveis no mercado mundial acerca da recorrente evolução tecnológica, ter o conhecimento do desempenho de dispositivos de captura de imagens nos possibilita a escolha adequada de acordo com sua qualidade, resolução de imagem e adaptabilidade (Hasinoff & Kutulakos 2011). Além disso, para associar a tecnologia a pesquisas científicas, o pesquisador deve ter conhecimento do que é preciso para realizar determinado experimento científico e qual a acessibilidade destes equipamentos para comunidade em geral.

As vantagens dos testes realizados com aparelho de celular giram em torno da perspectiva de posteriormente podermos alimentar um banco de dados que será utilizado na elaboração de um aplicativo de identificação de imagens, como leafsnap (Kumar *et al.* 2012), além da vantagem de ser pequeno e ter bateria recarregável, o que oferece ao pesquisador a facilidade de capturar imagens de qualidade no campo. Já o scanner nos ofereceu informações de imagens que devem ser feitas em laboratório, este mecanismo tem as vantagens de que as imagens vão ter sempre a mesma resolução em dpi, a mesma iluminação (mantendo um padrão de coloração para espécies) (Mokhtarian & Abbasi 2004).

Observamos que os dois métodos não diferiram quanto à qualidade das imagens. Este resultado possivelmente é reflexo das imagens terem sido capturadas em níveis próximos de resolução e por ambos os dispositivos terem sido usados em laboratório. O

aparelho de scanner com a lâmpada embutida e fundo branco manteve a mesma iluminação (Mokhtarian & Abbasi 2004, Sicard *et al.* 2015), o flash embutido no aparelho de celular e fundo branco mantiveram um padrão de tratamento de luz. A iluminação é um fator fundamental na captura de imagens para manter um controle preciso (Sicard *et al.* 2015), considerando que um dos objetivos seria comparar dois tipos diferentes de capturas de imagens. Por isso a importância de manter a mesma manipulação de luz para densidade de pixels, e fundo branco, o tratamento de luz influencia diretamente no número de pixels diferenciando nos resultados referentes aos atributos de cor (Hasinoff & Kutulakos 2011).

Com base nos resultados dos experimentos para comparar o desempenho de classificação de imagens de folhas, capturadas com celular e scanner tratadas em laboratório, respaldamos a escolha do dispositivo a critério do objetivo e adaptabilidade do estudo, pois os equipamentos não apresentaram diferença significativa referente à qualidade de imagens aplicadas na classificação de lâminas foliares.

Desempenho dos algoritmos de aprendizagem: Adaboost, Random Forest e SVM com para da classificação de imagens usando os de atributos de cor, forma e textura

Os resultados de desempenho dos algoritmos foram essenciais para mostrarmos a eficácia dos métodos de captura de imagem e salientarmos a classificação de atributos de cor, textura e forma. Comparar as diferentes técnicas de verificação de acertos de classe possibilita diminuir problemas que correspondem a classificação através da escolha do melhor algoritmo (López-García *et al.* 2010). Os melhores resultados obtidos pelo SVM e o Random Forest ao classificar os atributos de cor, forma e textura se deve a capacidade de ambos algoritmos lidarem com números robustos de informações, com agilidade para treinar uma alta quantidade de dados e várias entradas de variáveis (Kremic & Subasi 2016).

O SVM e o Random forest obtiveram resultados de desempenho semelhante todavia trabalham de formas distintas, o SVM combina as classes formando dois grupos para o classificador treinar esses dados em múltiplas classes. E o Random forest separa os exemplos formando conjuntos (árvores) para selecionar a floresta ideal (Kremic & Subasi 2016).

Algumas características podem justificar o melhor desempenho do SVM por cada imagem ter somente uma lâmina foliar delimitando bem o objeto, por nosso banco de dados ter sido composto por imagens que foram tratadas em laboratório, com imagens livres de ruídos, desta forma foi capaz de classificar uma imagem ou regiões (Dua *et al.* 2012). Agrupando dados que pertenciam a mesma classe (Mattila *et al.* 2013).

Em experimento com espécies florestais Filho *et al.* (2014) também utilizaram o SVM para treinar seu conjunto de dados com imagens tratadas em laboratório capturadas por microscópio, com a mesma qualidade e padronização de distância e com SVM adquiriu um bom desempenho para classificar os atributos de cor e forma das folhas. Os resultados adquiridos do desempenho do algoritmo Random Forest foram extremamente próximos ao do SVM, com a diferença que o Random Forest tem o potencial de lidar com alta quantidade de variáveis de entrada e selecionar as que considera significativa, atribuindo importância a cada variável (Manfredi *et al.* 2014).

O Random Forest também é apto a resolver problemas de classificação, pois consegue equilibrar os erros nos conjuntos de dados que tem classificações erradas e não faz um bom trabalho quando contém ruídos nos conjuntos de dados (Kremic & Subasi 2016). Característica igual do SVM (Dua *et al.* 2012), fator este, que também não foi um problema, já que nosso banco não possuía imagens com ruídos.

O Adaboost tem como característica um bom desempenho com imagens com efeitos como vento e sombreamento, fatores que dificultam o reconhecimento das classes (Kazmi *et al.* 2015). As imagens com ruídos que podem ser um problema para outros algoritmos o AdaBoost consegue trabalhar com facilidade (González *et al.* 2008). Desta forma nosso banco de imagens não foi pressuposto de problemas interessantes, Porque seu foco é investir em classificadores fracos (imagens difíceis de classificar) para formar um classificador forte e conseguir realizar sua função (Kumar *et al.* 2008).

A importância de avaliar o desempenho dos algoritmos na classificação individual das espécies mostrou que o SVM obteve destaque no seu desempenho alcançando um bom número de acertos com todas as classes com base nos atributos de cor, forma e textura. Esses atributos podem ser semelhantes entre as espécies, dificultando o reconhecimento e classificação por pesquisadores (Kazmi *et al.* 2015), isso mostra o bom desempenho do SVM para lidar com variabilidade fenotípica, e diversas variáveis (Kremic & Subasi 2016).

Conclusões

A identificação de uma espécie vegetal com uso de técnicas tradicionais da taxonomia vegetal feitas pelas pessoas pode requerer um indivíduo completo com flores, frutos e caule, e isso nem sempre é possível. Usar aprendizagem automática com conhecimento botânico fazendo a interação humana com a visão computacional pode se constituir numa solução desse problema.

No método apresentado concluímos que a diferença dos dispositivos de captura de imagens não foi significativa, e o algoritmo SVM mostrou melhor desempenho para classificar os atributos de cor, forma e textura do banco de imagens.

Consideramos dar continuidade com a técnica de aprendizagem automática usando o algoritmo SVM para classificar os atributos de cor, forma e textura das imagens de lâminas foliares e testar a redução de atributos para verificar possibilidades de manter eficiência com atributos reduzidos.

A identificação vegetal através da visão computacional é uma difícil tarefa dada a diversidade de espécies. Pensando nisso, sugerimos que nosso experimento apresentou resultados que vão incentivar iniciativas para compartilhar dessa metodologia em que a visão computacional facilitará a classificação de espécies vegetais, com base na alimentação de banco de dados de distintas regiões.

REFERÊNCIAS (Normas da revista Biotropica)

- ARAFAT, S. Y., M. I. SAGHIR, M. ISHTIAQ, and U. BASHIR. 2016. Comparison of Techniques for Leaf Classification. 3–8.
- BARBU, T. 2012. Using a Novel N -Step Search Algorithm and HOG Features. 328–336.
- BARROSO, G. M. 1986. Sistemática de angiospermas do Brasil. *In* Viçosa: Universidade Federal de Viçosa. pp. 88–94.
- BUENO, M. L., D. R. M. NEVES, A. F. SOUZA, E. OLIVEIRA JUNIOR, G. A. DAMASCENO-JUNIOR, V. PONTARA, V. A. LAURA, and J. A. RATTER. 2013. Influence of edaphic factors on the floristic composition of an area of cerradão in the Brazilian central-west. *Acta Bot. Brasilica* 27: 445–455.
- CLASSEN-BOCKHOFF, R. 2001. Plant morphology: The historic concepts of Wilhelm Troll, Walter Zimmermann and Agnes Arber. *Ann. Bot.* 88: 1153–1172.
- CORCORAN, J. M., J. F. KNIGHT, and A. L. GALLANT. 2013. Influence of multi-

source and multi-temporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in northern Minnesota. *Remote Sens.* 5: 3212–3238.

DUA, S., U. RAJENDRA ACHARYA, P. CHOWRIAPPA, and S. VINITHA SREE. 2012.

Wavelet-based energy features for glaucomatous image classification. *IEEE Trans. Inf. Technol. Biomed.* 16: 80–87.

DURIGAN, G., M. F. DE SIQUEIRA, and G. A. D. C. FRANCO. 2007. Threats to the cerrado remnants of the state of Sao Paulo, Brazil. *Sci. Agric.* 64: 355–363.

FILHO, P. L. P., L. S. OLIVEIRA, S. NISGOSKI, and A. S. BRITTO. 2014. Forest species recognition using macroscopic images. *Mach. Vis. Appl.* 25: 1019–1031.

GONÇALVES, A. B., J. S. SOUZA, G. G. DA SILVA, M. P. CEREDA, A. POTT, M. H. NAKA, and H. PISTORI. 2016. Feature extraction and machine learning for the classification of Brazilian Savannah pollen grains. *PLoS One* 11: 1–20.

GONZÁLEZ, G., F. FLEURET, and P. FUA. 2008. Automated delineation of dendritic networks in noisy image stacks. *In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. pp. 214–227.

GUERIN, G. R., H. WEN, and A. J. LOWE. 2012. Leaf morphology shift linked to climate change. *Biol. Lett.* 8: 882–886.

HALL, M., E. FRANK, G. HOLMES, B. PFAHRINGER, P. REUTEMANN, and I. H. WITTEN.

2009. The WEKA data mining software. *ACM SIGKDD Explor. Newsl.* 11: 10–18.

HASINOFF, S. W., and K. N. KUTULAKOS. 2011. Light-efficient photography. *IEEE Trans. Pattern Anal. Mach. Intell.* 33: 2203–2214.

HOFER, J., C. GOURLAY, and N. ELLIS. 2001. Genetic Control of Leaf Morphology: A Partial View. *Ann Bot* 88: 1129–1139.

- JOPPA, L. N., D. L. ROBERTS, and S. L. PIMM. 2011. How many species of flowering plants are there? *Proc. R. Soc. B* 278: 554–559.
- KAZMI, W., F. GARCIA-RUIZ, J. NIELSEN, J. RASMUSSEN, and H. J. ANDERSEN. 2015. Exploiting affine invariant regions and leaf edge shapes for weed detection. *Comput. Electron. Agric.* 118: 290–299.
- KOEPPEN, W. 1948. *Climatologia: con un estudio de los climas de la tierra.*
- KREMIC, E., and A. SUBASI. 2016. Performance of Random Forest and SVM in Face Recognition. 13: 287–293.
- KRUSE, O. M. O., J. M. PRATS-MONTALBÁN, U. G. INDAHL, K. KVAAL, A. FERRER, and C. M. FUTSAETHER. 2014. Pixel classification methods for identifying and quantifying leaf surface injury from digital images. *Comput. Electron. Agric.* 108: 155–165.
- KUMAR, N., P. N. BELHUMEUR, A. BISWAS, D. W. JACOBS, W. J. KRESS, I. C. LOPEZ, and J. V. B. SOARES. 2012. Leafsnap: A computer vision system for automatic plant species identification. *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)* 7573 LNCS: 502–516.
- KUMAR, N., P. BELHUMEUR, and S. NAYAR. 2008. FaceTracer: A search engine for large collections of images with faces. *In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics).* pp. 340–353.
- LEE, C. L., and S. Y. CHEN. 2006. Classification of leaf images. *Int. J. Imaging Syst. Technol.* 16: 15–23.
- LÓPEZ-GARCÍA, F., G. ANDREU-GARCÍA, J. BLASCO, N. ALEIXOS, and J. M. VALIENTE. 2010. Automatic detection of skin defects in citrus fruits using a multivariate image analysis approach. *Comput. Electron. Agric.* 71: 189–197.
- MACHADO, B. B., J. P. M. ORUE, M. S. ARRUDA, C. V SANTOS, D. S. SARATH, W. N.

- GONCALVES, G. G. SILVA, H. PISTORI, A. R. ROEL, and J. F. RODRIGUES-JR. 2016. BioLeaf: A professional mobile application to measure foliar damage caused by insect herbivory. *Comput. Electron. Agric.* 129: 44–55.
- MALHI, Y. ET AL. 2002. An international network to monitor the structure, composition and dynamics of Amazonian forests (RAINFOR). *J. Veg. Sci.* 13: 439–450.
- MALHI, Y. ET AL. 2013. Introductory Plant Biology. *Comput. Electron. Agric.* 88: 287–301.
- MANFREDI, M., C. GRANA, S. CALDERARA, and R. CUCCHIARA. 2014. A complete system for garment segmentation and color classification. *Mach. Vis. Appl.* 25: 955–969.
- MARIANO, G. C., L. P. C. MORELLATO, J. ALMEIDA, B. ALBERTON, M. G. G. DE CAMARGO, and R. DA S. TORRES. 2016. Modeling plant phenology database: Blending near-surface remote phenology with on-the-ground observations. *Ecol. Eng.* 91: 396–408.
- MATTILA, H., P. VALLI, T. PAHIKKALA, J. TEUHOLA, O. S. NEVALAINEN, and E. TYYSTJÄRVI. 2013. Comparison of chlorophyll fluorescence curves and texture analysis for automatic plant identification. *Precis. Agric.* 14: 621–636.
- MOKHTARIAN, F., and S. ABBASI. 2004. Matching shapes with self-intersections: Application to leaf classification. *IEEE Trans. Image Process.* 13: 653–661.
- MYERS, N., R. A. MITTERMEIER, C. G. MITTERMEIER, G. A. B. DA FONSECA, and J. KENT. 2000. Biodiversity hotspots for conservation priorities. *Nature* 403: 853–858.
- PAHIKKALA, T., K. KARI, H. MATTILA, A. LEPISTÖ, J. TEUHOLA, O. S. NEVALAINEN, and E. TYYSTJÄRVI. 2015. Classification of plant species from images of overlapping leaves. *Comput. Electron. Agric.* 118: 186–192.

- PEACOCK, J., T. R. BAKER, S. L. LEWIS, G. LOPEZ-GONZALEZ, and O. L. PHILLIPS. 2007. The RAINFOR database: monitoring forest biomass and dynamics. *J. Veg. Sci.* 18: 535–542.
- PLOTZE, R. DE O., M. FALVO, J. G. PÁDUA, L. C. BERNACCI, M. L. C. VIEIRA, G. C. X. OLIVEIRA, and O. M. BRUNO. 2005. Leaf shape analysis using the multiscale Minkowski fractal dimension, a new morphometric method: a study with *Passiflora* (Passifloraceae). *Can. J. Bot.* 83: 287–301.
- PONCE, J., and D. FORSYTH. 2012. *Computer vision: a modern approach*
- R DEVELOPMENT CORE TEAM. 2015. *R Software*. R A Lang. *Environ. Stat. Comput.*
- RIBEIRO, J. F., and B. M. T. WALTER. 2008. As principais fitofisionomias do bioma Cerrado. *In Cerrado: Ecologia e flora*. pp. 151–212.
- SICARD, C., C. GLEN, B. AUBIE, D. WALLACE, S. JAHANSHAHI-ANBUHI, K. PENNINGS, G. T. DAIGGER, R. PELTON, J. D. BRENNAN, and C. D. M. FILIPE. 2015. Tools for water quality monitoring and mapping using paper-based sensors and cell phones. *Water Res.* 70: 360–369.
- SIMON, M. F., R. GREYER, L. P. DE QUEIROZ, C. SKEMA, R. T. PENNINGTON, and C. E. HUGHES. 2009. Recent assembly of the Cerrado, a neotropical plant diversity hotspot, by in situ evolution of adaptations to fire. *Proc. Natl. Acad. Sci.* 106: 20359–20364.
- SORIANO, B. M. A. 1997. *Caracterização climática de Corumbá*. 25.
- ZHOU, S., Q. LIU, J. GUO, and Y. JIANG. 2012. ROI-HOG and LBP Based Human Detection via Shape Part-Templates Matching. 109–115.

MATERIAL SUPPLEMENTAR

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	aa	ab	ac	ad	Classes/Espécies	
80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a	<i>Pseudobombax sp</i>
0	79	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	b	<i>Bowdichia virgilioides</i>	
0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	c	<i>Annona coriacea</i>	
0	1	0	74	0	0	0	0	0	0	1	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	d	<i>Diptychandra aurantiaca</i>	
0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	e	<i>Licania humilis</i>	
0	0	0	0	0	77	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	f	<i>Miconia albicans</i>	
0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	g	<i>Qualea grandiflora</i>	
0	0	0	0	0	0	0	78	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	h	<i>Terminalia argentea</i>	
0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i	<i>Chrysophyllum marginatum</i>	
0	0	0	0	0	0	0	0	0	79	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	j	<i>Qualea multiflora</i>	
0	0	0	1	0	0	0	0	0	0	77	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	k	<i>Copaifera langsdorffii</i>	
0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	l	<i>Byrsonima coccolobifolia</i>	
0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	m	<i>Stryphnodendron obovatum</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	n	<i>Andira cuyabensis</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	o	<i>Tabebuia aurea</i>	
0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	76	0	0	0	0	0	0	0	0	0	0	0	0	p	<i>Eugenia sp</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	0	0	0	0	0	1	0	q	<i>Salvertia convallariodora</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	r	<i>Rhamnidium elaeocarpum</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	s	<i>Byrsonima verbascifolia</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	77	0	0	0	0	0	0	0	0	t	<i>Annona cassiflora</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	u	<i>Dimorphandra mollis</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	v	<i>Connarus suberosus</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	w	<i>Caryocar brasiliense</i>	
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	x	<i>Matayba guianenses</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	78	0	0	0	y	<i>Xylopia aromatica</i>	
0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	77	0	0	z	<i>Curatella americana</i>	
0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	77	0	0	aa	<i>Astronium fraxinifolium</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	ab	<i>Eriotheca pucescens</i>	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	ac	<i>Lafoensia pacari</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	ad	<i>Agonandra brasiliensis</i>	

FIGURA 1S. Matriz de Confusão SVM (scanner) (traço seleciona os valores classificados corretamente).

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	aa	ab	ac	ad	Classes/Espécies
80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a	<i>Bowdichia virgilioides</i>
0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	b	<i>Annona coriacea</i>
0	0	76	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	c	<i>Diptychandra aurantiaca</i>
0	0	0	79	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	d	<i>Licania humilis</i>
0	0	0	0	77	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	e	<i>Miconia albicans</i>
0	0	0	2	0	71	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	2	0	0	0	0	3	0	1	f	<i>Qualea grandiflora</i>
0	0	0	0	0	0	78	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	g	<i>Terminalia argentea</i>
0	0	0	0	0	0	0	79	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	h	<i>Chrysophyllum marginatum</i>
0	0	0	1	0	0	0	0	78	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i	<i>Qualea multiflora</i>
0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j	<i>Copaifera langsdorffii</i>
0	0	0	0	0	0	0	1	0	0	79	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	k	<i>Pseudobombax sp</i>
0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	l	<i>Byrsonima coccolobifolia</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m	<i>Stryphnodendron obovatum</i>
0	0	0	0	0	0	0	0	0	1	0	0	2	74	0	0	0	0	0	0	0	1	0	0	2	0	0	0	0	n	<i>Andira cuyabensis</i>
0	0	0	0	0	0	2	0	0	0	1	1	0	76	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	o	<i>Tabebuia aurea</i>
0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	77	0	0	1	0	0	0	0	0	0	0	0	1	0	p	<i>Eugenia sp</i>
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	0	0	0	0	0	0	0	0	q	<i>Salvertia convallariodora</i>
0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	78	0	0	0	0	0	0	0	0	0	0	0	r	<i>Rhamnidium elaeocarpum</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	0	0	1	0	0	0	0	0	s	<i>Byrsonima verbascifolia</i>
0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	78	0	0	0	0	0	0	0	0	0	t	<i>Annona cassiflora</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	0	0	u	<i>Dimorphandra mollis</i>
0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	76	0	0	0	2	0	0	v	<i>Connarus suberosus</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	80	0	0	0	0	0	w	<i>Caryocar brasiliense</i>
0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	72	6	0	0	0	x	<i>Matayba guianenses</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	76	0	0	0	0	y	<i>Xylopia aromatica</i>
0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	78	0	0	0	0	z	<i>Curatella americana</i>
0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	4	0	0	0	74	0	0	0	aa	<i>Astronium fraxinifolium</i>
0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	79	0	0	ab	<i>Eriotheca pucescens</i>
0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	78	0	ac	<i>Lafoensia pacari</i>
0	0	3	0																											

TABELA 1S. Atributos de Cor, Forma e Textura.

COR	FORMA	TEXTURA
cor_rmin	hu_0	glcm_cont_1_0
cor_rmax	hu_1	glcm_cont_1_45
cor_rmediame	hu_2	glcm_cont_1_90
dia	hu_3	glcm_cont_2_0
cor_rdesvio	hu_4	glcm_cont_2_45
cor_gmin	hu_5	glcm_cont_2_90
cor_gmax	hu_6	glcm_diss_1_0
cor_gmedia	hog_0 À 127	glcm_diss_1_45
cor_gdesvio		glcm_diss_1_90
cor_bmin		glcm_diss_2_0
cor_bmax		glcm_diss_2_45
cor_bmedia		glcm_diss_2_90
cor_bdesvio		glcm_homo_1_0
cor_hmin		glcm_homo_1_45
cor_hmax		glcm_homo_1_90
cor_hmedia		glcm_homo_2_0
cor_hdesvio		glcm_homo_2_45
cor_smin		glcm_homo_2_90
cor_smax		glcm_asm_1_0
cor_smedia		glcm_asm_1_45
cor_sdesvio		glcm_asm_1_90
cor_vmin		glcm_asm_2_0
cor_vmax		glcm_asm_2_45
cor_vmedia		glcm_asm_2_90
cor_vdesvio		glcm_ener_1_0
cor_cielmin		glcm_ener_1_45
cor_cielmax		glcm_ener_1_90
cor_cielmedia		glcm_ener_2_0
cor_cieldesvio		glcm_ener_2_45
cor_cieamin		glcm_ener_2_90
cor_cieamax		glcm_corr_1_0
cor_cieamedia		glcm_corr_1_45
cor_cieadesvio		glcm_corr_1_90
cor_ciebmin		glcm_corr_2_0
cor_ciebmax		glcm_corr_2_45
cor_ciebmedia		glcm_corr_2_90
cor_ciebdesvio		lbp_0 à 17