

Universidade Federal do Paraná  
Setor de Ciências Exatas  
Departamento de Estatística  
Programa de Especialização em *Data Science* e *Big Data*

Marks Melo Moura

# **Deteccção de espécies arbóreas utilizando redes neurais convolucionais**

**Curitiba**  
**2020**

Marks Melo Moura

# **Detecção de espécies arbóreas utilizando redes neurais convolucionais**

Monografia apresentada ao Programa de Especialização em Data Science e Big Data da Universidade Federal do Paraná como requisito parcial para a obtenção do grau de especialista.

Orientador: Luiz Eduardo S. Oliveira

Curitiba  
2020

## Detecção de espécies arbóreas utilizando redes neurais convolucionais

Marks Melo Moura<sup>1</sup>

Luiz Eduardo S. Oliveira<sup>2</sup>

### Resumo

Avaliações precisas da composição das espécies florestais podem ser utilizadas para analisar padrões de biodiversidade, estimar estoques de madeira e melhorar as estimativas de carbono estocado. Portanto, o objetivo deste trabalho foi avaliar a utilização de imagens de alta resolução obtidas por *Unmanned Aerial Vehicle* (UAV) na identificação de espécies florestais em áreas de regeneração florestal na Amazônia. As redes neurais convolucionais (CNN) foram treinadas utilizando o pacote Keras-Tensorflow com o modelo *faster\_rcnn\_inception\_v2\_pets*. Amostras de seis espécies florestais foram utilizadas para treinar a CNN, a partir destas, foram realizados testes com o número de *thresholds* e identificação das espécies confrontando os resultados obtidos com dados obtidos em campo. Os resultados demonstraram que a redução do *threshold* diminui a exatidão na identificação, assim como a sobreposição dos polígonos de identificação das espécies, no entanto, em comparação com os dados coletados em campo, observa-se que há uma alta correlação entre as árvores identificadas pela CNN e às observadas nas parcelas. As métricas estatísticas utilizadas para validar as classificações evidenciaram que a CNN é capaz de identificar as espécies com acurácia acima de 90%. Portanto, as redes neurais convolucionais é uma ferramenta eficaz na classificação de objetos em imagens UAV, demonstrando boa acurácia e precisão na identificação das espécies em estudo.

**Palavras-chave:** *Deep learning*; Drone; Identificação Florestal.

### Abstract

*Precise assessments of forest species composition can be used to analyze biodiversity patterns, estimate wood stocks and improve stock carbon estimates. Therefore, the objective of this work was to evaluate the use of high resolution images obtained by Unmanned Aerial Vehicle (UAV) in the identification of forest species in areas of forest regeneration in the Amazon. Convolutional neural networks (CNN) were trained using the Keras-Tensorflow package with the fas-*

*ter\_rcnn\_inception\_v2\_pets model. Samples of six forest species were used to train CNN, from these, tests were performed with the number of thresholds and species identification comparing the results obtained with field data. The results showed that the reduction of the threshold decreases the accuracy of identification, as well as the overlap of the polygons of species identification, however, in comparison with the data collected in the field, it is observed that there is a high correlation between the trees identified by the CNN and those observed in the plots. The statistical metrics used to validate the classifications showed that the CNN is able to identify species with accuracy above 90%. Therefore, convolutional neural networks are an effective tool in classifying objects in UAV images, demonstrating good accuracy and precision in the identification of species under study.*

**Keywords:** *Deep learning; Drone; Forest identification.*

## 1 Introdução

Sensores ópticos acoplados em *Unmanned Aerial Vehicle* (UAV) são comumente utilizados para aquisição de características geométricas da floresta, como altura e diâmetro das copas das árvores. Adicionalmente, além de informações quantitativas, esses sensores podem gerar atributos qualitativos sobre os ambientes florestais potencializando a possibilidade de caracterização de espécies florestais.

No entanto, para tal caracterização, apenas as ferramentas tradicionais de processamento de imagens obtidas por UAV, não tem se mostrado eficazes, de tal maneira que ainda é necessário o teste e a implementação de ferramentas adicionais ao processamento dessas imagens. Neste âmbito, as Redes Neurais Convolucionais (ou, em inglês, Convolutional Neural Networks – CNN) têm sido amplamente utilizadas em detecções de objetos diversos [1, 2, 3, 4] e também na caracterização de ambientes florestais [5, 6, 7, 8, 9].

CNNs são consideradas como um modelo matemático de classificação inspirado no sistema biológico de processamento de dados visuais. Na literatura, esses algoritmos dispõem de resultados satisfatórios para uma diversidade de problemas envolvendo imagens, incluindo classificação vegetal. Estas classificações utilizam descritores morfológicos como folhas, caule, frutos ou flores [10, 11].

A realização de inventários com sensores remotos e,

<sup>1</sup>Aluno do programa de Especialização em Data Science & Big Data, marksmoura@yahoo.com.br.

<sup>2</sup>Professor do Departamento de Informática - DINF/UFPR, lesoliveira@gmail.com.

consequentemente a composição das espécies florestais utilizando uma plataforma de imagens ao invés de levantamentos de campo, acarreta na redução de custos e tempo de aquisição, além de favorecer a análise da composição das espécies em grandes extensões territoriais [12, 13]. Avaliações precisas da composição das espécies de florestas promovem um ganho na pesquisa e administração dessas áreas, uma vez que pode-se utilizar esse conhecimento para analisar padrões de biodiversidade, estimar estoques de madeira e melhorar as estimativas de carbono estocado.

Entretanto, em uma revisão sobre classificação de espécies florestais [14], evidenciou que o mapeamento de árvores individuais a partir de imagens de sensoriamento remoto é um desafio, principalmente devido à falta de (1) imagens espaciais e espectrais de alta resolução; (2) classificadores de aprendizagem de máquinas sensíveis sofisticados o suficiente para identificar a iluminação, forma, tamanho e padrão das árvores, copas e folhas, bem como a mistura espectral nas próprias copas; e (3) dados espaciais precisos para treinar os classificadores. Contudo, essas dificuldades estão sendo resolvidas aos poucos, com o advento de novas tecnologias, sobretudo as imagens de alta resolução espacial obtidas por meio dos UAVs.

As imagens UAV possuem qualidade adequada para análise e caracterização de áreas florestais (plantadas ou nativas). Por este motivo têm sido amplamente utilizados em detrimento da sua versatilidade e facilidade na aquisição de dados em grandes áreas. Além disso, estas imagens também são utilizadas como suporte no monitoramento e análise visual da vegetação, sobretudo em áreas de florestas nativas e em processo de regeneração na Amazônia legal.

Neste contexto, o sensoriamento remoto está sendo aprimorado continuamente, mas, novas ferramentas de classificação são necessárias para preencher a lacuna entre imagens de sensoriamento remoto e a necessidade de informações de alta resolução sobre as florestas. Portanto, o objetivo deste trabalho foi testar o desempenho de imagens de alta resolução obtidas por UAV para a identificação de espécies florestais em áreas de regeneração florestal na Amazônia através da aplicação de algoritmo de aprendizado de máquinas.

## 2 Materiais e Métodos

### 2.1 Aquisição e pré-processamento das imagens

As imagens foram adquiridas por um UAV *DJI Phantom 4 pro*, utilizando uma câmera RGB, suas características principais estão descritas na Tabela 1. As imagens foram obtidas em novembro de 2017, 2018 e 2019, sempre das 8h às 15h aproveitando a iluminação solar e reduzindo o sombreamento das imagens.

As imagens foram processadas no *software Pix4D mapper*, com intuito de confeccionar o ortomosaico das áreas

Tabela 1: Características das imagens obtidas pelo UAV *DJI Phantom 4 PRO*

Denominação	Tipo
Largura	5.472 pixels
Altura	3.648 pixels
Modelo da câmera	FC6310
Tempo de exposição	1/400s
Valor da abertura	4,97 EV (f/5,6)
Taxa de velocidade (ISO)	100
Tipo de imagem	jpeg
Distância focal	8,8 mm

em questão. Salienta-se que não foram realizadas quaisquer correções de tonalidade e contrastes nas imagens brutas ou mosaicos finais. Estes mosaicos foram utilizados como subsídio para localização das árvores por meio de inventários de campo, onde foram adquiridas as coordenadas cartesianas das árvores (tendo como base as bordas das parcelas), e subsequentemente é realizada a transformação destas em coordenadas geométricas, desta forma, pode-se comparar os dados obtidos em campo com os obtidos pelo UAV.

### 2.2 Treinamento das redes neurais convolucionais

As 683 árvores (amostras) foram inseridas no aplicativo *Labelimg*, o qual possibilita a seleção da região de interesse por meio de polígonos que podem ter formas retangulares e quadradas (subamostras). Ao todo foram obtidas 2.437 subamostras (Tabela 2), sendo que para alcançar tal número foi necessário a seleção de subamostras de uma mesma árvore, de modo que em um único indivíduo eram selecionadas a maior quantidade de amostras possíveis, a depender do tamanho da copa (Figura1).



Figura 1: Representação da seleção de amostras em um indivíduo. O polígono vermelho representa a copa da árvore (*Handroanthus* spp.) e os retângulos azuis representam as subamostras obtidas para esta espécie.

Ao final do processo de seleção das amostras, o aplicativo fornece um arquivo no formato *.csv*, contendo: nome do arquivo, altura, largura, classe, xmin, xmax, ymin e ymax [15]. A partir do arquivo *csv* oriundo do

Tabela 2: Espécies florestais utilizadas e quantidade de amostras para o treinamento das redes convolucionais

Espécies	Amostras		
	Árvores	Teste (30%)	Treino (70%)
<i>Cecropia</i> spp.	157	158	369
<i>Hymenaea</i> spp.	102	126	294
<i>Bauhinia</i> spp.	96	108	252
<i>Anacardium</i> spp.	90	80	186
<i>Handroanthus</i> spp.	106	116	270
<i>Anadenanthera</i> spp.	132	144	336
Total	683	731	1706

*Labelimg* foi possível criar aleatoriamente dois conjuntos de amostras, sendo eles: Treino (70%, ou seja 1.706 amostras) e Teste (30%, ou seja, 731 amostras). Para a validação foram separados das amostras de Treino 487 imagens para serem aplicadas na Validação, garantido assim que o modelo não apresentasse *Overfitting*.

Para implementação das redes neurais convolucionais foi utilizada a linguagem computacional Python, com o pacote *Keras-TensorFlow*. Esse sistema de código aberto do Google é utilizado e implementando nos algoritmos de aprendizagem profunda de redes neurais. Neste pacote foi inserido o modelo *faster\_rcnn\_inception\_v2\_pets*, o qual foi modificado para treinar as amostras das espécies alvo. Inicialmente foi treinado a CNN com um total de épocas ou passos (*Epoch*) alto para garantir que o menor valor da perda (*Loss*) estaria dentro dessa amplitude de passos. Após o primeiro treinamento foi possível determinar a quantidade de passos ideal para se obter a menor perda, a fim de otimizar as análises e repetições que seriam realizadas. O treino do primeiro modelo foi desenvolvido considerando as 6 espécies de árvores, com intuito de analisar a aprendizagem de máquina e índice de acerto da espécie. Em cada etapa do treinamento é possível observar a perda, iniciando com alto valor de perda reduzindo-se à medida que o treinamento avança.

Os *thresholds* são limiares que modificam a saída de acordo com limites de entrada. De forma simplificada, a rede recebe entradas, aplica uma combinação linear e, se essa combinação for maior ou menor que algum valor limite, produzirá uma saída de 1 ou 0, respectivamente. Portanto, resultados com probabilidades baixas seriam rejeitadas. Na Eq. 1 é representado simplificado o funcionamento do *threshold*, o Sigma ( $\Sigma$ ) é o somatório dos pares de entrada ( $x$ ) e peso ( $w$ ).

$$Sada = \begin{cases} 0, & \sum_i w_i x_i < threshold \\ 1, & \sum_i w_i x_i \geq threshold \end{cases} \quad (1)$$

### 2.3 Validação da Classificação

A validação das classificações é essencial para confirmar a veracidade dos resultados. Neste sentido, as amostras reservadas para o teste foram utilizadas para avaliar e testar o desempenho da CNN. Foram utilizadas as métricas especificadas na Tabela 3, das quais são calculadas de acordo com os resultados das classificações.

## 3 Resultados

Posteriormente aos treinamentos iniciais, observou-se que utilizando *threshold* = 0.9 algumas das espécies não foram reconhecidas. Isto levou o retreinamento do modelo com variação do número de espécies e *thresholds*. Todos os resultados obtidos eram comparados com os dados de campo a fim de se obter o modelo que melhor interpretasse as condições reais da área estudada.

A Figura 2 demonstra a aplicação da rede neural após o treinamento com 6 espécies com variação do *threshold*. Com o valor deste parâmetro igual a 0.9, os valores de exatidão de reconhecimento das espécies foram maiores, entretanto, houve apenas a identificação de 2 espécies, quando o mesmo valor é reduzido para 0.8 a rede identifica 3 espécies, o mesmo acontece para os valores de 0.7 e 0.6.

A redução do *threshold* diminui a exatidão na identificação, assim como a sobreposição dos polígonos de identificação das espécies, no entanto, ao compararmos os resultados obtidos pela rede neural aos dados coletados em campo, observa-se que há uma relação entre as árvores identificadas pela CNN e às observadas em campo. Observa-se que nas áreas com maior quantidade de sombras ou sobreposição das copas das árvores há uma maior incerteza na classificação, em comparação as espécies que possuem copas mais altas e sem sombra.




Figura 2: Aplicação do modelo incluindo as 6 espécies no treinamento, sendo: A - *threshold* = 0.9, B - *threshold* = 0.8, C - *threshold* = 0.7, D - *threshold* = 0.6.

A variação das perdas (*loss*) em relação às épocas (*epoch*) é demonstrado na Figura 3, a partir desta, foi possível observar que para o treinamento de apenas 1 espécie foram necessários 494 épocas, 2 espécies (541 épocas), 3 espécies (892 épocas), 4 espécies (976 épocas), 5 espécies (993 épocas) e 6 espécies (1.042 épocas). Assim como a alteração do *threshold* a inclusão de mais espé-

Tabela 3: Índices estatísticos utilizados para verificação da classificação

Índice Estatístico	Fórmula	Descrição	Referências
Kappa	$\text{kappa} = \frac{\text{ACC}_{\text{overall}} - \text{RACC}_{\text{overall}}}{1 - \text{ACC}_{\text{overall}}}$	Varia de 1 a -1, onde 1 indica uma classificação perfeita e -1 representa uma classificação não confiável.	Cohen (1960)
Acurácia	$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$	Número de classificações corretas de todas as predições realizadas.	Sammut and Webb, (2010)
F-score	$\text{AGF} = \sqrt{\left[5 \times \frac{\text{PPV} \times \text{TPR}}{(4 \times \text{PPV}) + \text{TPR}}\right] \times \left[\frac{1 + 0.5^2 \frac{\text{NPV} + \text{TNR}}{(0.5^2 \times \text{NPV}) + \text{TNR}}}{1 + 0.5^2 \frac{\text{NPV} + \text{TNR}}{(0.5^2 \times \text{NPV}) + \text{TNR}}}\right]}$	Utilizada para usar todos os elementos da matriz de confusão e fornecer mais pesos às amostras que estão corretamente classificadas na menor classe.	Maratea et al. (2014)
Coefficiente de Correlação de Mathews	$\text{MCC} = \frac{\text{TP} \times \text{TN} - \text{FN}}{\sqrt{(\text{TP} + \text{FP}) \times (\text{TP} + \text{FN}) \times (\text{TN} + \text{FP}) \times (\text{TN} + \text{FN})}}$	Coefficiente de correlação de classificações binárias observadas e previstas, onde: Negligenciável - <0.3 Fraco - 0.3 - 0.5 Moderado - 0.5 - 0.7 Forte - 0.7 - 0.9 Muito forte - >0.9	Matthews, (1975)

Onde: ACCoverall - conformidade relativa observada entre os classificadores; RACCoverall - conformidade hipotética de probabilidade utilizando os dados observados para calcular as probabilidades de cada classificador identificar aleatoriamente cada categoria; TP - verdadeiro positivo; TN - verdadeiro negativo; FP - falso positivo; FN - falso negativo; PPV - valor preditivo positivo; TPR - taxa positiva verdadeira; NPV - valor preditivo negativo; TNR - verdadeira taxa negativa.

cies (características) aumenta relativamente o tempo do treinamento da rede, tornando este processo mais demorado.

A Figura 4 demonstra a variação da perda na validação do modelo ajustado utilizando todas as espécies. Tal modelo convergiu ao seu menor valor de perda com 439 épocas.

Observou-se que o treinamento com o *threshold* = 0.7, apresentou resultados satisfatórios em relação ao tempo de processamento e reconhecimento das espécies, portanto, foi utilizado esse valor para o cálculo da matriz de confusão com todas as espécies, obtendo uma exatidão global de 91.80%. Houve falsos reconhecimentos das características em todas as espécies, contudo, o maior erro de classificação (falso positivo) concentrou-se entre a *Cecropia* spp. e *Handroanthus* spp. com a *Bauhinia* spp., na qual houve falsa caracterização em 26 ocasiões (Tabela 4).

A matriz de confusão demonstrou que os menores valores observados para a acurácia do produtor e usuário foram respectivamente 79.76% e 87.01%, para a *Bauhinia* spp. Contudo, os maiores valores observados para a acurácia do produtor foram das espécies *Cecropia* spp. (96.48%) e *Hymenaea* spp. (95.58%) e para a acurácia do usuário, *Hymenaea* spp. (94.30%) e *Anadenanthera* spp. (93.81%).

Na Tabela 5 são demonstrados todos os índices estatísticos utilizados pra validação das classificações, o índice Kappa calculado foi de 0.9006, o que indica boa classificação, resultados semelhantes foram verificados nas métricas de Acurácia e F-score ajustado. Contudo, na correlação de Matthews as espécies *Bauhinia* spp. e *Handroanthus* spp. obtiveram classificação forte, enquanto para as demais espécies esta estatística foi muito forte.

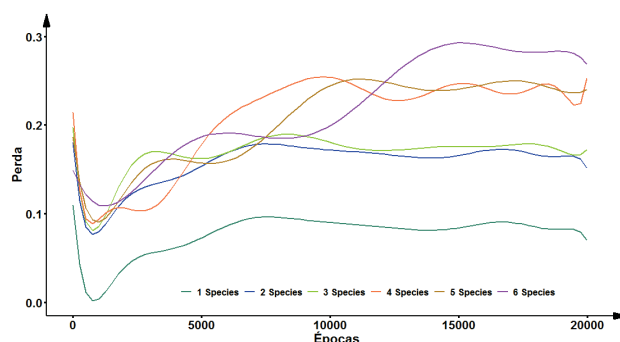


Figura 3: Variação da perda em relação às épocas e quantidade de espécies utilizadas no treinamento.




Figura 4: Variação da perda do modelo ajustado com as 6 espécies.

## 4 Discussão

O reconhecimento de espécies ou gêneros florestais em campo ou utilizando as técnicas de sensoriamento remoto é um grande desafio para pesquisadores da área florestal.

Tabela 4: Matriz de confusão com inserção das 6 espécies na rede neural convolucional com  $\text{threshold} = 0.7$ 

	<i>Cecropia</i>	<i>Hymenaea</i>	<i>Bauhinia</i>	<i>Anacardium</i>	<i>Handroanthus</i>	<i>Anadenanthera</i>	Total	Usuário
<i>Cecropia</i>	356	0	26	4	0	0	386	92,23%
<i>Hymenaea</i>	0	281	0	0	5	12	298	94,30%
<i>Bauhinia</i>	4	12	201	4	5	5	235	87,01%
<i>Anacardium</i>	4	0	8	171	0	1	184	92,93%
<i>Handroanthus</i>	0	1	12	7	240	9	269	89,22%
<i>Anadenanthera</i>	5	0	5	0	11	318	335	93,81%
Total	369	294	252	186	261	345	1707	-
Produtor	96,48%	95,58%	79,76%	91,94%	91,95%	92,17%	-	1567
Exatidão global	91,80%	-	-	-	-	-	-	-

No entanto o treinamento da rede neural convolucional utilizando o modelo *faster\_rcnn\_inception\_v2\_pets* apresentou resultados satisfatórios na identificação de características das espécies estudadas.

As particularidades relacionadas com a estrutura da copa e folhas das espécies foram determinantes para boa acurácia do modelo, das árvores em estudo suas características dendrométricas foram determinantes para as caracterizações satisfatórias. Como relatado em [16], as características das copas influenciam diretamente no classificador, a *Cecropia* e a *Bauhinia* possuem as menores copas das espécies em estudo, contudo, os indicadores estatísticos demonstraram resultados acima de 0.9, pois, sua copa possui uma desuniformidade em relação aos galhos e folhas. A *Hymenaea* e a *Anadenanthera* possuem folhas menores e copas mais amplas, destacando-se em relação as demais. O *Anacardium* e *Handroanthus*, possuem maior quantidade de folhas e copas que também se destacam no dossel da floresta, e por isso, o classificador foi eficientemente capaz de as distinguirem das demais.

Em comparação à experimentos realizados em ambientes com menos espécies arbóreas, tais como [5] e [17], as métricas de classificação foram superiores se comparados com este estudo, pois, há menores possibilidades de confusão nas características das espécies. No entanto, limitados trabalhos têm relatado suas experiências em detecção de objetos em relação à seleção do *threshold*, [18] utilizou tal parâmetro com valor 0.5 para detecção de palmeiras, resultando em um F-score variando de 0.875 a 0.957, valores próximos aos observados nesta pesquisa.

Neste âmbito, [19] compararam a altura do sensor com a variação do *threshold* na predição de variáveis dendrométricas, os autores concluíram que com o aumento da distância do sensor em relação ao objeto alvo, era necessário retreinar a CNN com aumento do *threshold*, assim obtiveram resultados melhores na acurácia e erro. [20], relata que não há valor predeterminado deste limiar e argumenta que o valor mais adequado depende diretamente da base de dados e método computacional utilizado.

Ao analisar as classificações com diferentes *thresholds*, os resultados demonstraram uma sobreposição dos polígonos de detecção da CNN, resultado semelhante foi observado por [21] e [22], nestes trabalhos foram relatados problemas na interpretação das bordas das árvores em relação às vizinhas. Por este motivo, a redução do valor do *threshold* foi crucial para que esta incerteza fosse

notada, entretanto, tal fator não influenciou na correta identificação da espécie, somente alterou a visualização do polígono de identificação e reduziu o valor referente à probabilidade de acerto na caracterização da espécie. No tocante a quantidade de épocas, estudos sugerem que este valor é proporcional a quantidade de características que são inseridas no modelo [1, 23, 17, 24].

As métricas estatísticas utilizadas para determinar a acurácia do modelo apontaram correlações muito fortes entre as detecções das espécies, entretanto, os resultados da *Bauhinia* spp. demonstram que a existência de poucas amostras de uma determinada espécie, acarreta menores valores de Acurácia, F-score ajustado, Correlação de Matthews (Tabela ??). Contudo, a espécie *Hymenaea* spp. possuía menos amostras que a *Cecropia* spp. e obteve melhores resultados, o que está relacionado, principalmente, ao tamanho reduzido das copas e folhas da *Cecropia* spp. em comparação às outras espécies. Por possuir galhos mais longos e folhas somente nas pontas destes, as copas das árvores vizinhas se entrecruzam nestes galhos, ocasionando imprecisão na detecção e falsa caracterização da espécie, tal característica também foi relatada em [25], os autores demonstram resultados da acurácia semelhantes a desta pesquisa ao comparar o consórcio de espécies no bioma Mata Atlântica, das quais, possuem características fisionômicas parecidas com a Amazônia.

A Correlação de Matthews é uma métrica de classificação considerada pouco tendenciosas quanto ao uso de múltiplas variáveis de entrada, pois incorporam tanto o desequilíbrio do conjunto quanto a quantidade de dados referentes às classes [26]. Neste aspecto, a inclusão das espécies ocasionou menores valores das métricas citadas em comparação à Acurácia e F-score, visto que, estas possuem bias (viés) relacionados a quantidade de características incluídas e especificamente o F-score independe dos verdadeiros negativos (TN). A alta Similaridade demonstra que o classificador é capaz de identificar satisfatoriamente os verdadeiros negativos, assim como a alta Sensitividade indica que o classificador conseguiu identificar bem os verdadeiros positivos [27].

Os UAVs operam geralmente a baixa altitude e podem adquirir imagens em resoluções espaciais melhores do que as imagens captadas via satélite, possibilitando informações mais detalhadas não só da floresta, mas também a nível individual de espécie. Em relação aos custos, as operações com UAVs são menores se comparados com

Tabela 5: Índices estatísticos obtidos no processo de classificação do conjunto de dados do treinamento

Índices	<i>Cecropia</i>	<i>Hymenaea</i>	<i>Bauhinia</i>	<i>Anacardium</i>	<i>Handroanthus</i>	<i>Anadenanthera</i>
Kappa				0,9006		
Acurácia	0,9748	0,9824	0,9525	0,9836	0,9707	0,9718
F-score ajustado	0,9706	0,9667	0,9135	0,9587	0,9594	0,9589
Correlação de Matthews	0,9272 <sup>1</sup>	0,9387 <sup>1</sup>	0,8057 <sup>2</sup>	0,9151 <sup>1</sup>	0,8884 <sup>2</sup>	0,9123 <sup>1</sup>

Onde: <sup>1</sup> - Very strong e <sup>2</sup> - Strong.

imageamento aerotransportado tradicional ou aquisição de alta resolução de sensores orbitais em. Assim, é possível adquirir imagens com maior frequência, favorecendo o monitoramento periódico da floresta e estudo da sua dinâmica.

## 5 Conclusões

A CNN demonstrou-se uma ferramenta eficaz na classificação de objetos em imagens UAV, sem a necessidade de modificação nas propriedades das imagens. Neste sentido, o treinamento da CNN demonstrou boa acurácia e precisão na identificação das espécies em estudo, entretanto, a inserção das espécies tornou o treinamento moroso.

Há maior erro de classificação quando as copas das espécies se sobrepõem umas sobre as outras, assim como a presença de sombreamento nas imagens.

A qualidade das imagens oriundas do UAV é fundamental para a obtenção de padrões característicos das espécies e sobretudo para o treinamento das redes, do mesmo modo que a frequência na obtenção das imagens, ampliando o número de amostras que podem ser adquiridas, neste sentido a quantidade de amostras utilizadas no treinamento da CNN foi suficiente para reconhecimento das características e padrões intrínsecos às espécies escolhidas.

A identificação de árvores individuais fornece subsídios a novas informações sobre ecossistemas florestais. No entanto, trabalhos devem ser desenvolvidos visando obter informações a respeito de distinções na caracterização florestal em relação às estações do ano, fenologia da vegetação durante os meses do ano, condições atmosféricas, bem como utilização de outros sensores, adicionando mais informações ao modelo.

## Agradecimentos

M.M.M. agradece ao Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Laboratório de Estatística e Geoinformação (LEG) da Universidade Federal do Paraná (UFPR) pelo suporte financeiro a esse projeto.

## Referências

- [1] Danyang Cao, Zhixin Chen, and Lei Gao. An improved object detection algorithm based on multi-scaled and deformable convolutional neural networks. *Human-centric Computing and Information Sciences*, 10(1), 2020.
- [2] Yuancong Wu, J. J. Wang, Kun Qian, Yanchen Liu, Rui Guo, S. G. Hu, Q. Yu, T. P. Chen, Y. Liu, and Limei Rong. An energy-efficient deep convolutional neural networks coprocessor for multi-object detection. *Microelectronics Journal*, 98(December 2019), 2020.
- [3] Qunli Yao, Xian Hu, and Hong Lei. Multiscale Convolutional Neural Networks for Geospatial Object Detection in VHR Satellite Images. *IEEE Geoscience and Remote Sensing Letters*, pages 1–5, 2020.
- [4] Miaohui Zhang, Yunzhong Chen, Xianxing Liu, Bingxue Lv, and Jun Wang. Adaptive Anchor Networks for Multi-Scale Object Detection in Remote Sensing Images. *IEEE Access*, 8:57552–57565, 2020.
- [5] Michael Fromm, Matthias Schubert, Guillermo Castilla, Julia Linke, and Greg McDermid. Automated detection of conifer seedlings in drone imagery using convolutional neural networks. *Remote Sensing*, 11(21), 2019.
- [6] Rui Qiao, Ali Ghodsi, Honggan Wu, Yuanfei Chang, and Chengbo Wang. Simple weakly supervised deep learning pipeline for detecting individual red-attacked trees in VHR remote sensing images. *Remote Sensing Letters*, 11(7):650–658, 2020.
- [7] Zhafri Roslan, Zalizah Awang Long, Mohd Nizam Husen, Roslan Ismail, and Robiah Hamzah. Deep Learning for Tree Crown Detection in Tropical Forest. *Proceedings of the 2020 14th International Conference on Ubiquitous Information Management and Communication, IMCOM 2020*, 2020.
- [8] Vasileios Syrris, Paul Hasenohr, Blagoj Delipetrev, Alexander Kotsev, Pieter Kempeneers, and Pierre Soille. Evaluation of the Potential of Convolutional Neural Networks and Random Forests for Multi-Class Segmentation of Sentinel-2 Imagery. *Remote Sensing*, 11(8):907, apr 2019.

- [9] Changlin Xiao, Rongjun Qin, and Xu Huang. Tree-top detection using convolutional neural networks trained through automatically generated pseudo labels. *International Journal of Remote Sensing*, 41(8):3010–3030, 2020.
- [10] Jiuxiang Gu, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy, Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai, and Tsuhan Chen. Recent advances in convolutional neural networks. *Pattern Recognition*, 77:354–377, 2018.
- [11] Timothy John Jassmann. *Mobile Leaf Classification Application Utilizing A CNN*. PhD thesis, 2015.
- [12] Juha Hyyppä, Hannu Hyyppä, Mikko Inkinen, Marcus Engdahl, Susan Linko, and Yi Hong Zhu. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. *Forest Ecology and Management*, 128(1-2):109–120, 2000.
- [13] Mike Wulder. Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. *Progress in Physical Geography*, 22(4):449–476, 1998.
- [14] Fabian Ewald Fassnacht, Hooman Latifi, Krzysztof Stereńczak, Aneta Modzelewska, Michael Lefsky, Lars T. Waser, Christoph Straub, and Aniruddha Ghosh. Review of studies on tree species classification from remotely sensed data. *Remote Sensing of Environment*, 186:64–87, 2016.
- [15] Tzotalin. Git code, 2020.
- [16] Matheus Pinheiro Ferreira, Fabien Hubert Wagner, Luiz E.O.C. Aragão, Yosio Edemir Shimabukuro, and Carlos Roberto de Souza Filho. Tree species classification in tropical forests using visible to shortwave infrared WorldView-3 images and texture analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 149:119–131, mar 2019.
- [17] Nurulain Abd Mubin, Eiswary Nadarajoo, Helmi Zulhaidi Mohd Shafri, and Alireza Hamedianfar. Young and mature oil palm tree detection and counting using convolutional neural network deep learning method. *International Journal of Remote Sensing*, 40(19):7500–7515, 2019.
- [18] Maximilian Freudenberg, Nils Nölke, Alejandro Agostini, Kira Urban, Florentin Wörgötter, and Christoph Kleinn. Large scale palm tree detection in high resolution satellite images using U-Net. *Remote Sensing*, 11(3):1–18, 2019.
- [19] Christoph Gollob, Tim Ritter, Clemens Wassermann, and Arne Nothdurft. Influence of scanner position and plot size on the accuracy of tree detection and diameter estimation using terrestrial laser scanning on forest inventory plots. *Remote Sensing*, 11(13):1–30, 2019.
- [20] Dan Wang, Yingdong Feng, Kristopher Attwood, and Lili Tian. Optimal threshold selection methods under tree or umbrella ordering. *Journal of Biopharmaceutical Statistics*, 29(1):98–114, 2019.
- [21] Ricardo Sarabia, Arturo Aquino, Juan Manuel Ponce, Gilberto López, and José Manuel Andújar. Automated identification of crop tree crowns from uav multispectral imagery by means of morphological image analysis. *Remote Sensing*, 12(5):1–23, 2020.
- [22] Juntao Xiong, Zhen Liu, Shumian Chen, Bolin Liu, Zhenhui Zheng, Zhuo Zhong, Zhengang Yang, and Hongxing Peng. Visual detection of green mangoes by an unmanned aerial vehicle in orchards based on a deep learning method. *Biosystems Engineering*, 194:261–272, 2020.
- [23] Geoffrey A. Fricker, Jonathan D. Ventura, Jeffrey A. Wolf, Malcolm P. North, Frank W. Davis, and Janet Franklin. A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery. *Remote Sensing*, 11(19), 2019.
- [24] Lucas Prado Osco, Mauro dos Santos de Arruda, José Marcato Junior, Neemias Buceli da Silva, Ana Paula Marques Ramos, Érika Akemi Saito Moryia, Nilton Nobuhiro Imai, Danillo Roberto Pereira, José Eduardo Creste, Edson Takashi Matsubara, Jonathan Li, and Wesley Nunes Gonçalves. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 160(December 2019):97–106, 2020.
- [25] Fabien H. Wagner, Alber Sanchez, Yuliya Tarabalka, Rodolfo G. Lotte, Matheus P. Ferreira, Marcos P.M. Aidar, Emanuel Gloor, Oliver L. Phillips, and Luiz E.O.C. Aragão. Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. *Remote Sensing in Ecology and Conservation*, 5(4):360–375, 2019.
- [26] Milla Shin. Applications of computer vision to population dynamics : detecting flowering trees in high-resolution cube-sat imagery. (May), 2020.
- [27] Amalia Luque, Alejandro Carrasco, Alejandro Martín, and Ana de las Heras. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91:216–231, 2019.