

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E URBANISMO E
GEOGRAFIA
MESTRADO EM RECURSOS NATURAIS

MÁRCIO SANTOS ARAUJO

APRENDIZADO PROFUNDO APLICADO EM IMAGENS DE
VANT PARA A DETECÇÃO DE *DIPTERYX ALATA*

Campo Grande - MS

2020

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E URBANISMO E
GEOGRAFIA
MESTRADO EM RECURSOS NATURAIS

MÁRCIO SANTOS ARAUJO

APRENDIZADO PROFUNDO APLICADO EM IMAGENS DE
VANT PARA A DETECÇÃO DE *DIPTERYX ALATA*

Dissertação apresentada à Secretaria do Curso de Pós-Graduação em Recursos Naturais como pré-requisito para obtenção do título de mestre em Recursos Naturais.

Orientador: Prof. Dr. José Marcato Junior

Co-orientadores: Prof. Dr. Hemerson Pistori e Prof.^a Dr.^a. Camila Aoki

Campo Grande – MS

2020

“Hoje me sinto mais forte mais feliz quem sabe, só levo a certeza de que muito pouco eu sei, ou nada sei”

Almir Sater & Renato Teixeira

AGRADECIMENTOS

Agradeço acima de tudo à Deus por todas dificuldades passadas, pois sobre elas, posso ter forças para valorizar os bons momentos;

A minha mãe Dinorá por me auxiliar nos momentos difíceis e a quem dedico essa conquista;

A Universidade Federal de Mato Grosso do Sul – UFMS e a todos seus colaboradores que de alguma forma contribuíram para a realização desse trabalho;

Ao Professor Dr. José Marcato Junior pela orientação, sabedoria, companheirismo e conhecimento transmitido para minha formação;

Aos Professores Doutores Wesley Nunes Gonçalves, Hemerson Pistori, Camila Aoki, Ana Paula Ramos e todos os demais que contribuíram de forma significativa para a formulação desta pesquisa;

Aos colegas do laboratório de geomática, Mauricio de Sousa, Lucas Oliveira, Geazy Menezes, entre outros que por lá passaram e me ajudaram nos projetos;

Aos meus grandes amigos José Amorim Longatto, Cicero de Souza e suas famílias por sempre me ajudarem com uma conversa, um auxílio, uma oportunidade, e se dedicarem na maior demonstração de amizade comigo no desafio que é fazer uma pós graduação.

Enfim, a todos que me ajudaram durante esse período de aprendizado.

SUMÁRIO

RESUMO	6
ABSTRACT	7
1. CAPÍTULO I: CONSIDERAÇÕES GERAIS	8
1.1 JUSTIFICATIVA	8
1.2 CARACTERIZAÇÃO DA INTERDISCIPLINARIDADE	9
1.3 ESPÉCIE ESTUDADA	10
1.3.1 Relevância social e econômica	12
1.4 LICENCIAMENTO AMBIENTAL	13
1.5 INVENTÁRIO FLORESTAL	14
1.6 APRENDIZADO PROFUNDO	15
REFERÊNCIAS.....	16
2. CAPITULO II - APRENDIZADO PROFUNDO APLICADO EM IMAGENS DE VANT PARA A DETECÇÃO DE <i>DIPTERYX ALATA</i>	20
RESUMO	20
ABSTRACT	21
2.1 INTRODUÇÃO	22
2.2 MATERIAIS E MÉTODOS	24
2.2.1 Áreas de Estudo	24
2.2.2 Coletas e Anotações das Imagens com VANT.....	26
2.2.3 Protocolo experimental.....	29
2.3 RESULTADOS E DISCUSSÃO.....	32
2.4 CONCLUSÕES	34
REFERÊNCIAS.....	35

RESUMO

Esta dissertação propõe a investigação de método baseado em aprendizado profundo (*deep learning*) aplicado na classificação de *Dipteryx alata*, popularmente conhecido por Cumbaru, que é uma espécie arbórea de interesse ambiental de Mato Grosso do Sul (MS) a partir de imagens RGB coletadas por VANT (Veículos Aéreos Não-Tripulados). Está organizada em dois capítulos, o primeiro capítulo apresenta considerações gerais a respeito da espécie estudada, sua relevância socioambiental e as legislações pertinentes a licenciamento ambiental e inventário florestal. Também apresenta uma breve abordagem sobre aprendizado profundo (*deep learning*). O segundo capítulo teve como objetivo avaliar o método de detecção de objetos RetinaNet na identificação da espécie de interesse ambiental. Realizou-se a coleta de imagens em locais selecionados com o uso de VANT e gerou-se um banco de imagens com anotações da espécie estudada; Experimentos iniciais foram realizados dentro do campus da UFMS (Universidade Federal de Mato Grosso do Sul) e também em áreas próximas, com foco no mapeamento e monitoramento de *Dipteryx alata*. O período de coleta foi entre agosto de 2018 e dezembro de 2019. As imagens foram divididas em treino, validação e teste na proporção de 60%, 20% e 20%. A abordagem investigada baseia-se no método de detecção de objetos RetinaNet, que utiliza anotações com retângulos envolventes. Posteriormente, realizou-se teste com imagens coletadas em local distante da UFMS, visando avaliar a capacidade de generalização do método empregado. As precisões na detecção foram em torno de 90% para a primeira área e 80% para essa segunda área de teste.

Palavras-chave: *Dipteryx alata*, Sensoriamento Remoto, RetinaNet, VANT.

ABSTRACT

This dissertation proposes the investigation of a method based on deep learning applied in the classification of *Dipteryx alata*, popularly known as Cumbaru, which is an arboreal species of environmental interest from Mato Grosso do Sul (MS) from RGB images collected by UAV (Unmanned Aerial Vehicles). It is organized in two chapters, the first chapter presents general considerations regarding the studied species, its socio-environmental relevance and the pertinent legislation for environmental licensing and forest inventory. It also presents a brief approach to deep learning. The second chapter aimed to evaluate the RetinaNet object detection method in identifying the species of environmental interest. The collection of images was carried out in selected places with the use of UAV and a bank of images was generated with notes of the studied species; Initial experiments were carried out within the UFMS campus (Federal University of Mato Grosso do Sul) and also in nearby areas, with a focus on mapping and monitoring *Dipteryx alata*. The collection period was between August 2018 and December 2019. The images were divided into training, validation and testing in the proportion of 60%, 20% and 20%. The investigated approach is based on the RetinaNet object detection method, which uses annotations with surrounding rectangles. Subsequently, a test was performed with images collected in a distant place from UFMS, aiming to evaluate the generalization capacity of the method employed. Detection accuracy was around 80% for this second test area.

Key words: *Dipteryx alata*, Remote Sensing, RetinaNet, UAV

1. CAPÍTULO I: CONSIDERAÇÕES GERAIS

A dissertação está organizada em dois capítulos. No capítulo 1 apresentam-se tópicos para uma melhor compreensão do tema de estudo. No capítulo 2 apresenta-se um artigo que visa propor uma investigação de método baseado em aprendizado profundo (*deep learning*) aplicado na classificação de *Dipteryx alata* partir de imagens RGB coletadas por VANT (Veículos Aéreos Não-Tripulados). Para a classificação das espécies arbóreas utilizou-se imagens RGB com alta resolução espacial coletadas a partir de VANT Phantom 4 advanced.

1.1 JUSTIFICATIVA

Mato Grosso do Sul é um estado que abrange os biomas Cerrado, Pantanal e Mata Atlântica, ressaltando sua relevante importância para a biodiversidade. É, portanto, um estado com grandes riquezas naturais às quais devem ser preservadas. Segundo a Pesquisa de Indicadores de Desenvolvimento Sustentável, divulgada pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2015), o Cerrado, vegetação predominante de Mato Grosso do Sul, já teve 76,1% da área desmatada até o ano de 2010.

O avanço do desmatamento em Mato Grosso do Sul estimulou a criação da Resolução SEMADE n. 9, de 13 de maio de 2015, que dispõe sobre normas e procedimentos para o licenciamento ambiental estadual (SEMADE, 2015). Segundo Art. 51 da referida resolução, a supressão de floresta ou qualquer outra forma de vegetação nativa existente em Mato Grosso do Sul apenas poderá ser realizada após a obtenção da autorização ambiental. O Art. 52 por sua vez, diz que a supressão da vegetação ou, o corte de árvores nativas isoladas, que tenha em sua composição espécies ambientalmente protegidas dependerá da adoção de medidas mitigatórias e compensatórias as que assegurem a conservação da espécie. No parágrafo 3º do artigo 52, a supressão de espécie ambientalmente protegida listada na Resolução poderá ser autorizada mediante a apresentação pelo requerente, de termo de compromisso, no qual o requerente se responsabiliza pela implantação de medidas compensatórias, como o plantio e condução de tantas mudas quanto às indicadas para o caso concreto.

O número de mudas estipuladas para plantio, segundo Resolução SEMADE n.9, de acordo com a espécie: 20 mudas para cada exemplar de Peroba Rosa (*Aspidosperma polyneuron*); 10 mudas para cada exemplar de Aroeira do Sertão (*Myracrodruon urundeuva*), Baraúna ou Quebracho (*Schinopsis brasiliensis*), Gonçalves Alves (*Astronium fraxinifolium*), Pequi (*Caryocar spp*) e 5 mudas para cada exemplar de Mangaba (*Hancornia speciosa*), Cagaita (*Eugenia dysenterica Dc.*), Cumbaru (*Dipteryx alata*) e Marolo (*Annona crassiflora*). Além dos aspectos ambientais, a vegetação arbórea de Mato Grosso do Sul tem grande importância social.

Diversas populações dependem de seus recursos naturais, incluindo etnias indígenas, ribeirinhos, babaqueiras, vazanteiros e comunidades quilombolas (MMA, 2018). Algumas das espécies descritas são frutíferas, e seus frutos e sementes são regularmente consumidos pela população local e vendidos nos centros urbanos, como os frutos do Pequi, Mangaba, Cagaita, e as castanhas do Cumbaru.

A contribuição deste trabalho se dá pelo desenvolvimento de uma abordagem baseada em aprendizado profundo (*deep learning*) e imagens RGB coletadas por VANT para a detecção de uma espécie arbórea com interesse ambiental e que possui importância social e cultural no estado de Mato Grosso do Sul, o Cumbaru (*Dipteryx alata*). Outra motivação é o sensor para coleta de imagens aéreas de baixo custo utilizado neste trabalho, possibilitando a reprodução da metodologia em larga escala.

1.2 CARACTERIZAÇÃO DA INTERDISCIPLINARIDADE

O Programa de Pós-graduação em Recursos Naturais da Universidade Federal de Mato Grosso do Sul (UFMS) é interdisciplinar e possui como um de seus objetivos a geração de recursos humanos que contribuam para o desenvolvimento regional, profissionais com conhecimento multidisciplinar aptos a atuar no mercado de trabalho, na docência e na pesquisa.

A interdisciplinaridade traz benefícios e a própria necessidade da participação de diversas disciplinas para a elaboração de soluções para as questões atuais são inegáveis (LEMMINK, 2005). Karlsson et al (2008), avaliam que cada disciplina traz uma contribuição separada para elucidar um problema comum e a integração dos conhecimentos podem resultar em um novo campo de pesquisa ou disciplina.

Neste projeto, há a participação entre disciplinas ligadas ao sensoriamento remoto, fotogrametria, ciência da computação e ecologia, que são de extrema importância para o alcance do objetivo proposto. Técnicas de imageamento por meio da utilização de VANT, aliados as novas tecnologias de inteligência artificial se apresentam como ferramenta para diversos campos de aplicação, a se destacar o monitoramento e mapeamento de indicadores de biodiversidade em grandes áreas de difícil acesso e instrumentos que colaborem na fiscalização ambiental.

A pesquisa pretende contribuir com uma ferramenta para identificação das espécies de interesse ambiental auxiliando os levantamentos a título de inventários florestais com maior rapidez. Colaborando, assim, para a preservação e conservação dos recursos naturais em diferentes escalas.

1.3 ESPÉCIE ESTUDADA

A *Dipteryx alata* é nativa da vegetação do cerrado brasileiro e das faixas de transição da mata atlântica para o cerrado (na floresta latifoliada semidecidual). (LORENZZI, 2002). Dependendo da região pode ser conhecida pelos nomes populares Baru e Cumbaru. Ao longo do texto será adotado *Dipteryx alata*. Ocorre nos estados de Minas Gerais (Norte, Noroeste, Triângulo Mineiro), São Paulo (Norte do estado), Mato Grosso, Mato Grosso do Sul e Goiás. Há registros da espécie também em outros países Sul-Americanos, como Bolívia, Paraguai e Peru (LORENZZI, 2002).

É uma árvore frutífera nativa do cerrado brasileiro, pertence à família *Fabaceae*, (Figura 1). Apresenta altura média de 15 m, com caule ereto e ramos lisos, floresce de outubro a janeiro e os frutos amadurecem entre março e agosto (ISA, 2009), produzindo em média de 2000 a 6000 frutos por planta (SILVA et al., 1992). Oliveira e Sigrist (2008) observaram que a espécie é alógama, ou seja, apresenta um sistema reprodutivo de fecundação cruzada, sendo a polinização realizada por diversos insetos e a dispersão dos frutos realizada por animais.

A vegetação arbórea de Mato Grosso do Sul tem grande importância social, cultural e ambiental. Para as comunidades tradicionais e regionais do cerrado, o fruto da *Dipteryx alata* é comercialmente viável e estimula o desenvolvimento local e pode

reativar a economia e toda uma cadeia de qualidade de vida sociocultural e de proteção de recursos naturais (ÁVILA et al., 2001).

A espécie passou a ser considerada protegida por lei no estado de Mato Grosso do Sul em 2011 de acordo com a Resolução SEMAC n.008, de 31 de maio. No ano de 2019 houve a revogação com a Resolução SEMAGRO n. 679 de 09 de setembro.

Art. 1º. Esta Resolução estabelece as normas e procedimentos para o licenciamento ambiental no âmbito do Estado de Mato Grosso do Sul conforme dispõe Lei Estadual n. 2.257, de 09 de julho de 2001, e implanta, na forma de seus anexos, o rol documental básico para cada fase do licenciamento e a tabela de atividades licenciáveis com o respectivo rol documental específico a ser exigido.

A escolha dessa árvore para a pesquisa se deu pela relevância ambiental, econômica e social e, além disso, pela grande quantidade de indivíduos na cidade de Campo Grande e nas proximidades do campus da UFMS, o que facilitou a utilização de equipamentos e os deslocamentos para a obtenção de imagens RGB via utilização de VANT com o propósito de se formar um banco de dados com numerosas imagens da espécie.



Figura 1. Cumbaru (*Dipteryx alata*). Fonte: o autor (2019)

Os frutos (Figura 1) possuem um alto valor nutricional. São fontes de carboidratos, proteínas e óleo, sendo este similar ao óleo de oliva. Na amêndoa o valor energético varia entre 476 a 560 kcal/100g. De acordo com Takemoto et al. (2001) as

sementes de *Dipteryx alata* constituem uma fonte significativa de lipídios, proteínas e, com isso, de calorías, além de fibras alimentares e minerais, recomendando sua utilização na alimentação humana e animal, caso comprovada à inexistência de compostos tóxicos ou alergênicos nas mesmas. As sementes são também fontes de macro e micronutrientes essenciais, como potássio, fósforo e manganês. O óleo da semente de *Dipteryx alata* apresenta teor de α -tocoferol e composição em ácidos graxos semelhantes aos do óleo de amendoim, destacando-se os ácidos oléico e linoléico, este considerado essencial. O elevado grau de insaturação do óleo da semente de *Dipteryx alata* favorece seu uso para fins comestíveis ou como matéria-prima para as indústrias farmacêutica e oleoquímica, se eliminadas eventuais substâncias nocivas à saúde (TAKEMOTO et al., 2001)

Tanto a polpa quanto a amêndoa podem ser utilizadas na alimentação humana, sendo a polpa constituída principalmente de hidratos de carbono (63%), predominantemente por amido, fibras insolúveis e açúcares (ALVES et al., 2010). A amêndoa é consumida in natura ou torrada, apresenta elevados níveis de lipídicos (42%), proteínas (30%), cálcio, fósforo, manganês e potássio, além de ferro, zinco, selênio e consideráveis teores de hidratos de carbono e fibras (SOUSA et al., 2011).

Para que seja feita a extração da amêndoa é preciso um cuidado especial, que se inicia com a seleção dos frutos. Como a casca é muito dura, sua quebra para obtenção da amêndoa inteira requer técnicas de corte transversal ou por pressão mecânica. Depois, realiza-se a seleção das amêndoas – as podres podem ser utilizadas como adubo, as machucadas servem para a produção da farinha (CARRAZA et al. 2010). As amêndoas inteiras são, então, separadas por tamanho e armazenadas por até 30 dias para serem consumidas in natura ou torradas.

1.3.1 Relevância social e econômica

No aspecto social e econômico, é possível citar as integrantes do grupo Baru, do Assentamento São Manoel, em Anastácio-MS, (Figura 2), que mudaram suas vidas, através de novas perspectivas com o processamento e subprodutos dos frutos. O grupo é informal e as mulheres se associaram a uma cooperativa para que possam comercializar seus produtos em escala regional e nacional.

Segundo Bissoli (2018) a conquista da autonomia econômica a partir do trabalho no grupo Barú promoveu liberdade para que essas mulheres abrissem outras portas, como a inserção e o desenvolvimento de outras atividades profissionais que também trouxeram retorno financeiro, como a participação na feira da agricultura familiar promovida pelo município de Anastácio em Mato Grosso do Sul, a inserção coletiva no (PAA) Programa de Aquisição de Alimentos que possui duas finalidades básicas: promover o acesso à alimentação e incentivar a agricultura familiar e o trabalho com horticultura para entrega na merenda escolar.



Figura 2. Mulheres do grupo Barú na colheita dos frutos. Município de Anastácio – MS e Chocolates Angí - Fonte: Bissoli (2018)

Outro produto que pode ser gerado a base da castanha de *Dipteryx alata* são barras de chocolate que são compostas a partir da mistura de ingredientes base e da extração natural de sabores de frutos silvestres, plantas, cascas de árvores que são colhidas por cooperativas locais do estado de Mato Grosso do Sul. Como exemplo os chocolates Angí, misturam cacau 70% com castanhas e frutos típicos do Cerrado, está em sintonia com o rótulo, ilustrado com fotos exclusivas de árvores do Pantanal, em preto e branco. O próprio nome Angí, é um diminutivo de Angico, uma das árvores de grande importância presente no cerrado e no pantanal (Figura 2).

1.4 LICENCIAMENTO AMBIENTAL

De acordo com a legislação brasileira, o meio ambiente é considerado como patrimônio público, que deve ser preservado para uso comum de toda sociedade. Como “bem de uso comum do povo”, é dever do Poder Público zelar por ele. Por meio das leis, a administração pública estabelece instrumentos, controles, licenças, permissões, autorizações pelas quais regulariza o correto uso do meio ambiente e intervém naquilo que é necessário (ALBANO, 2011).

O Conselho Nacional do Meio Ambiente – CONAMA – através do artigo 1º, inciso I da Resolução nº. 237, de 19 de julho de 1997, dispôs sobre a definição do licenciamento ambiental:

Art. 1º, I: Procedimento administrativo pelo qual o órgão ambiental competente licencia a localização, instalação, ampliação e a operação de empreendimentos e atividades utilizadoras de recursos ambientais consideradas efetiva ou potencialmente poluidoras ou daquelas que, sob qualquer forma, possam causar degradação ambiental, considerando as disposições legais e regulamentares e as normas técnicas aplicáveis ao caso.

O licenciamento ambiental é uma das formas de exteriorizar a função administrativa do poder público, já que se busca controlar as atividades humanas que interferem no meio ambiente, preservando assim o equilíbrio natural e ecológico. Portanto, para que a sociedade goze de um meio ambiente ecologicamente equilibrado, o Poder Público precisa exigir estudo prévio de impacto ambiental antes mesmo de autorizar a instalação de obra ou atividade, que seja potencialmente poluidora.

1.5 INVENTÁRIO FLORESTAL

Um dos objetivos do trabalho é colaborar com a atualização de técnicas para inventário florestal. Que é o procedimento utilizado para obter informações sobre as características quantitativas e qualitativas das florestas (HUNSH et al. 1993). De maneira popular, o inventário é um instrumento de “contagem de árvores” existentes em uma área específica.

Prodan et al. (1997), consideram que os principais fatores que influenciam o delineamento ou o planejamento de um inventário florestal são:

- a) Os objetivos do inventário;
- b) Os recursos disponíveis;
- c) As condições topográficas e a acessibilidade à área;
- d) A tipologia florestal e a sua variabilidade;
- e) A precisão requerida em torno da média.

De acordo com Cunha (2004), a evolução tecnológica e a clara necessidade de melhorar as qualidades das informações obtidas a campo serão adicionadas aos projetos de manejo florestal e estão modificando o modo de se trabalhar com esse tipo de metodologia. Além disso, são consideradas ferramentas utilizadas no diagnóstico potencial produtivo ou protetivo das florestas. Seus resultados ajudam nas tomadas de decisões em empreendimentos que exigem investimentos, seja pela indústria ou pelo agronegócio ou também por órgãos de licenciamento ou fiscalização.

1.6 APRENDIZADO PROFUNDO

A Revolução tecnológica está modificando o dia a dia das pessoas em todo mundo. Tecnologias até pouco tempo tida como distantes já estão inseridas no nosso cotidiano através de computadores, smartphones, aparelhos GNSS (*Global Navigation Satellite System*), dentre outros.

A computação está avançando a passos largos para trazer benefícios e mais facilidades para a sociedade de maneira geral e a inteligência artificial (IA) é um dos campos da ciência da computação que tem esse propósito. Esse campo de estudo teve seu início após a segunda Guerra Mundial, pois foi quando houve o aparecimento dos chamados computadores modernos (Teixeira, 1990). A IA tem como objetivo fazer com que os computadores consigam inteligência aos moldes humanos. Para atingir esses objetivos existem algumas abordagens como Aprendizado de máquina (*Machine Learning*) e Aprendizado profundo (*Deep Learning*).

Aprendizado de máquina é composto por métodos que aprendem por exemplos. Aprendizado profundo se trata de um subcampo de aprendizado de máquina que usa redes neurais que são inspiradas na rede de neurônios (células nervosas) no cérebro biológico. A grande vantagem do aprendizado profundo com relação às técnicas tradicionais de aprendizado de máquina é a não necessidade de se estabelecer características. Em aprendizado de máquina, uma característica é uma propriedade mensurável de um fenômeno de interesse (Christopher, 2006). São úteis transformações de uma representação de dados para outra em um nível conceitual mais alto e que possa ser efetivamente aproveitada por algoritmos de aprendizado (Bezerra, 2016). As melhorias nas fórmulas matemáticas e nos computadores são cada vez mais importantes, e os cientistas de computação conseguem aumentar o número de camadas de neurônios virtuais com mais facilidades do que em tempos atrás (Fernandes, 2017).

O aprendizado profundo está englobado pelo aprendizado de máquina, e tem por vantagem, se comparado aos algoritmos tradicionais de aprendizado de máquina, definir automaticamente as características/feições. As técnicas de aprendizado profundo podem ser divididas em: classificação; detecção de objetos e; segmentação.

No presente trabalho adotou-se técnicas de detecção de objetos, nas quais usam-se retângulos envolventes para detectar o objeto de interesse. Existem diversas técnicas, a se destacar o *Single Shot Multibox Detector - SSD* (Fuentes et al. 2017), *Faster Region-Based Convolutional Neural Network - Faster R-CNN* (Ren et al.2015), o Yolo (Redmon et al, 2018) e o Retina Net (Lin et al 2015). O RetinaNet tem se destacado em aplicações de Sensoriamento Remoto (Santos et al. 2019) e por isso foi adotado no presente trabalho.

REFERÊNCIAS

- ALBANO, M.P. Licença ambiental: ato vinculado ou discricionário?. **Intertem@s**. v. 22, n. 22 (2011)
- ALVES, A.M.; Mendonça, A.L. de.; Caliarri M. e Cardoso-Santiago, R.A (2010) - Avaliação química e física de componentes do baru (*Dipteryx alata* Vog.) para estudo da vida de prateleira. **Pesquisa Agropecuária Tropical**, vol. 40, n. 3, p. 266–273.

ANGÍ. Chocolates. 2019. Disponível em < <https://sebrae.ms/empreendedorismo/casos-de-sucesso/doce-negocio/attachment/12-angi-chocolates-2/#>> Acesso em: 23 de janeiro de 2020.

ÁVILA, V. et al. (Org.) Formação educacional em desenvolvimento local: relato de um estudo em grupo e análise de conceitos. 2.ed. Campo Grande: UCDB, 2001.

BEZERRA, E.. Introdução à aprendizagem profunda. in: eduardo ogasawara, vaninha viera. (org.). tópicos em gerenciamento de dados e informações. 1ed.porto alegre: **sbc**, 2016, v. 1, p. 57-86.

BISSOLI, M. W. de Lima. Empoderamento de agricultoras através da coleta e beneficiamento de frutos do Cerrado no Assentamento São Manoel, Anastácio-MS/ Mayara Winie de Lima Bissoli. 2018. 80 f.:il.

BRASIL. **Resolução Conama n. 237, de 19 de dezembro de 1997**. Dispõe sobre os procedimentos e critérios utilizados no licenciamento ambiental e no exercício da competência, bem como as atividades e empreendimentos sujeitos ao licenciamento ambiental. Diário Oficial da União, Brasília, seção 1, 22 dez. 1997, p. 30841-30843.

CEPPEC. Centro de Produção, Pesquisa e Capacitação do Cerrado. 2019. Disponível em < <https://ecoa.org.br/cerrado/ceppec/>> Acesso em: 23 de janeiro de 2020.

CHRISTOPHER M. B. Pattern Recognition and Machine Learning (information science and statistics). **springer-verlag** New York, inc., secaucus, nj, USA, 2006.

CUNHA, U. S. Dendrometria e inventário florestal. 2004. Disponível em < <https://engenhariaflorestal.jatai.ufg.br/up/284/o/dendroinv.pdf> > Acesso em: 10 de janeiro de 2020.

FERNANDES, W. R Aprendizagem Profunda (deep learning) de máquinas: conceitos, técnicas e bibliotecas. 2017. trabalho de conclusão de curso (graduação em sistema de informação) - Faculdade Avantis.

FUENTES, A.; Yoon, S.; Kim, S.C.; Park, D.S. A Robust Deep-Learning-Based Detector for Real-Time TomatoPlant Diseases and Pests Recognition. **Sensors** 2017, 17. doi:10.3390/s17092022.

HUSCH, B.; MILLER,C.I; KERSHAW, J. **Forest mensuration**. 4. ed. New Jersey: John Willey e Sons, Inc, 2003. 443 p

IBGE. Instituto Brasileiro de Geografia e Estatística. **Indicadores de desenvolvimento sustentável**. Rio de Janeiro, RJ. 2015.

ISA - Instituto Socioambiental. Mangaba. In: Campos Filho, E.M. (2009) - Plante as árvores do Xingu e Araguaia: guia de identificação, vol. 2. São Paulo: **Instituto Socioambiental**. 304p.

KARLSSON, J. *et al.* Reaching beyond disciplines through collaboration: Academics' learning in a national multidisciplinary research programme. **Journal of Workplace Learning**, v. 20, n. 2, p. 98-113. 2008. ISSN 1366-5626.

LEMMINK, J. The need for more multidisciplinary research. **International Journal of Service Industry Management**, v. 16, n. 1, p. 7-9. 2005. ISSN 0956-4233.

LIN, T.; goyal, p.; girshick, r.b.; he, k.; dollár, p. focal loss for dense object detection. arxiv 2017, arxiv:1708.02002.

LORENZI, HARRI: árvores brasileiras: manual de identificação e cultivo de plantas arbóreas do brasil, vol. 1. instituto plantarum, nova odessa, sp, 2002, 4a. edição.

MATO GROSSO DO SUL. **Resolução semac nº 08-2011** - Estabelece normas e procedimentos para o licenciamento ambiental Estadual, e dá outras providências.

MATO GROSSO DO SUL. **Resolução semagro nº 679 DE 09/09/2019** - - Estabelece normas e procedimentos para o licenciamento ambiental Estadual, e dá outras providências.

MATO GROSSO DO SUL.. **Resolução semade n. 9**, de 13 de maio de 2015. 2015.

MINISTÉRIO DO MEIO AMBIENTE (MMA). Cerrado. 2019. Disponível em: <<http://www.mma.gov.br/biomas/cerrado>>. Acesso em: 03 de março de 2019.

OLIVEIRA, M. B. & SIGRIST, M. R. 2008. Fenologia reprodutiva, polinização e reprodução de *Dipteryx alata* Vogel (Leguminosae - Papilionoideae) em Mato Grosso do Sul, Brasil. **Revista Brasileira de Botânica** 31:195-207

PRODAN, M.; PETERS, R.; COX, F.; REAL, P. Mensura forestal. San José, Costa Rica: IICA, 1997, 586 p.

QGIS Development Team. 2017. **QGIS 2.14.11 Essen**. Geographic Information System. Open Source Geospatial Foundation Project. Disponível em <<https://www.qgis.org>>

REDMON, J.; Farhadi, A. YOLOV3: An Incremental Improvement. arXiv 2018, arXiv:1804.02767.

REN, S.; He, K.; Girshick, R.B.; Sun, J. Faster R-CNN: Towards Real-Time Object Detection with RegionProposal Networks. arXiv **2015**, arXiv:1506.01497.

SANO S.M.; Ribeiro, J.F. e Brito, M.A. (2004) - Barú: biologia e uso. Documentos ed. Planaltina: **Embrapa Cerrados**, 52 p.

SANTOS, A.A.; Marcato Junior, J.; Araújo, M.S.; Di Martini, D.R.; Tetila, E.C.; Siqueira, H.L.; Aoki, C.; Eltner, A.; Matsubara, E.T.; Pistori, H.; Feitosa, R.Q.; Liesenberg, V.; Gonçalves, W.N. Assessment of CNN-Based Methods for Individual

Tree Detection on Images Captured by RGB Cameras Attached to UAVs. **Sensors** 2019, 19, 3595.

SILVA, J.A. da; Silva, DB. da; Junqueira, N.T.V. e Andrade, LRM (1992) -Colheita de sementes, produção de mudas e plantio de espécies frutíferas nativas dos Cerrados: informações exploratórias. **Embrapa / CPAC, Planaltina**. 23 p. (Documentos 44).

SOARES, Carlos Pedro Boechat; NETO, Francisco de Paula; SOUZA, Agostinho Lopes de. **Dendrometria e Inventário Florestal**. 2ª. ed. Viçosa: Editora UFV, 2011. 272 p.

SOUSA, A.G.O.; Fernandes, D.C.; Alves, A.M.; Freitas, J.B. e Naves, M.M.V. (2011) - Nutritional quality and protein value of exotic almonds and nut from the Brazilian Savanna compared to peanut. **Food Research International**, vol. 44, n. 7, p. 2319–2325.

TAKEMOTO, E. ET AL. composição química da semente e do óleo de baru (*dipteryx alata* vog.) nativo do município de pirenópolis, estado de goiás. *rev. inst. adolfo lutz*, 60(2):113-117, 2001

TEIXEIRA, J. F.. O que e inteligencia artificial. 1. ed. sao paulo: **editora brasiliense**, 1990. v. 1. 77p .

2. CAPITULO II - MAPEAMENTO DE *DIPTERYX ALATA* POR APRENDIZADO PROFUNDO APLICADO EM IMAGENS RGB COLETADAS POR VANTS."

RESUMO

Este artigo propõe a investigação de método baseado em aprendizado profundo (*deep learning*) aplicado na classificação de *Dipteryx alata* uma espécie arbórea de interesse socioambiental de Mato Grosso do Sul (MS) a partir de imagens RGB coletadas por VANT (Veículos Aéreos Não-Tripulados). Para a classificação da espécie arbórea utilizou-se imagens RGB com alta resolução espacial coletadas a partir de VANT Phantom 4 advanced. Experimentos iniciais foram realizados dentro do campus da UFMS (Universidade Federal de Mato Grosso do Sul) e também em áreas próximas, com foco no mapeamento e monitoramento de *Dipteryx alata*. O período de coleta foi entre agosto de 2018 e dezembro de 2019, totalizando catorze voos e 442 imagens anotadas. As imagens foram divididas em treino, validação e teste na proporção de 60%, 20% e 20%. A abordagem, utilizou-se o método de detecção de objetos RetinaNet, baseado em retângulos envolventes. Obteve-se uma precisão de aproximadamente 90% nas detecções. Posteriormente, realizou-se teste com 73 imagens coletadas em local distante da UFMS, visando avaliar a capacidade de generalização do método empregado. As precisões na detecção foram em torno de 80%. Os resultados obtidos no presente trabalho apresenta relevância prática, contribuindo para fins de fiscalização por parte dos órgãos ambientais do Estado de Mato Grosso do Sul.

Palavras-chave: Aprendizado Profundo, Sensoriamento Remoto, VANT, *Dypteryx alata*.

ABSTRACT

This article offers an investigation of a method based on deep learning, qualified in the classification of Cumbaru *Dipteryx alata* a tree species of socioenvironmental interest from Mato Grosso do Sul (MS) from RGB images collected by UAV (Unmanned Aerial Vehicles)) For the classification of the tree species, RGB images with high spatial resolution collected from UAV Phantom 4 advanced are used. The initial experiments were carried out within the UFMS campus (Federal University of Mato Grosso do Sul) and also in nearby areas, focusing on the mapping and monitoring of *Dipteryx alata*. The collection period was between August 2018 and December 2019, totaling fourteen flights and 442 annotated images. The images were divided into training, validation and testing in the proportion of 60%, 20% and 20%. The approach used the RetinaNet object detection method, based on surrounding rectangles. Detection accuracy of approximately 90% was obtained. Subsequently, a test was performed with 73 images collected in a distant place from UFMS, qualifying the generalization capacity of the method. Detection accuracy was around 80%. The results obtained in the present work producing, contributing to inspection purposes by the environmental agencies of the State of Mato Grosso do Sul.

Key words: *Dipteryx alata*, Remote Sensing, RetinaNet, UAV.

2.1 INTRODUÇÃO

Pesquisas realizadas a níveis globais indicam que as florestas estão diminuindo de tamanho. Hansen et al. (2013) verificaram as alterações nas extensões das florestas entre os anos 2000 e 2012, e notaram que 2,3 milhões de km² de florestas foram extintas durante os 12 anos de estudo, e cerca 0,8 milhões de km² de novas florestas surgiram. O território brasileiro é um dos que mais sofre com reduções em diferentes biomas (IBGE, 2020). Algumas espécies possuem interesse ambiental, cultural e social para diferentes grupos populacionais, assim, as técnicas de sensoriamento remoto estão sendo cada vez mais aplicadas para racionalizar e dar celeridade as pesquisas de campo para avaliar os recursos florestais.

A identificação e classificação de espécies arbóreas são realizadas, em geral, utilizando-se imagens multiespectrais (RGB e Infravermelho) (Landenburger et al., 2008; Sánchez-Azofeifa et al., 2011; Immitzer et al., 2012; Immitzer et al., 2016; Franklin; Ashmed, 2018) e Hiperespectrais (Clark et al., 2005; Dalponte et al., 2013), dados LiDAR (*Light Detection And Ranging*) (Heinzel; Kock, 2011; Korpela et al., 2010; Yao et al., 2012; Garrido et al., 2014; Mizoguchi et al., 2017), e também pela combinação deles (Voss; Sugumaran, 2008; Puttonen et al., 2011; Naidoo et al., 2012; Dalponte et al., 2012; Dalponte et al., 2014; Alonzo et al., 2014).

Imagens hiperespectrais aéreas (161 bandas, 437-2434 nm) foram usadas para a classificação de sete espécies de árvores (CLARK et al., 2005), onde os classificadores de análise discriminante lineares (LDA), máxima verossimilhança (ML) e mapeamento espectral (SAM) foram usados e a maior precisão (88%) foi obtida pelo classificador ML e 60 bandas. Voss e Sugumaran (2008) combinaram dados hiperespectrais e LiDAR (*Light Detection and Ranging*) para classificar sete espécies de árvores (*Gleditsia triacanthos*, *Acer saccharum*, *Tilia Americana*, *Quercus palustris*, *Pinus strobus* and *Picea glauca*) nas estações de verão e outono. Os autores usaram a abordagem orientada a objetos, e a combinação dos dois conjuntos de dados melhorou significativamente (19%) a precisão da classificação.

Immitzer et al. (2012) aplicaram o método de Floresta Aleatória (*Random Forest*) (RF) para classificar 10 espécies de árvores em uma floresta temperada na Áustria usando dados multiespectrais de satélite do WorldView-2 (8 bandas). A

precisão geral da classificação foi de cerca de 82%. Dalponte et al. (2012) investigaram a combinação de imagens hiperespectrais e multiespectrais com dados LiDAR (*Light Detection and Ranging*) para a classificação de espécies arbóreas do sul dos Alpes. Experimentos com RF e Máquinas de vetores de suporte (SVM) foram realizados, e ambos mostraram uma precisão de 76,5% ao considerar dados hiperespectrais. Dalponte et al. (2013) investigaram o uso de sensores hiperespectrais para classificação de espécies arbóreas de florestas boreais. Os experimentos mostraram uma precisão de cerca de 80%, considerando os métodos de SVM e RF.

Immitzeret et al. (2016) usaram imagens orbitais multiespectrais Sentinel 2 para classificar espécies de árvores na Alemanha. O classificador usado foi o RF, obtendo uma precisão geral em torno de 65%. Franklin e Ashmed (2018) realizaram a classificação de espécies de árvores decíduas usando imagens multiespectrais de VANT, análise baseada em objetos e aprendizado de máquina. A precisão alcançada foi de cerca de 78%.

Mizoguchi et al. (2017) utilizaram a redes neurais convolucionais (CNN), técnica de aprendizado profundo aplicada em imagens, para classificar espécies arbóreas usando dados LiDAR terrestre. A precisão foi em torno de 85% a 90%. Nevalainen et al. (2017) combinaram nuvens de pontos fotogramétricas baseadas em VANT e dados hiperespectrais para detecção e classificação de árvores em florestas boreais. O RF e o MultilayerPerceptron (MLP) ou rede Perceptron de múltiplas camadas, conforme Haykin (2001), proporcionaram precisão global de 95%. Berveglieri et al. (2018) desenvolveram um método baseado em Modelo Digital de Superfície (MDS) multi-temporal e superpixels para analisar estágios sucessionais e sua evolução em florestas tropicais remanescentes no Brasil.

Existe uma escassez de estudos usando apenas imagens RGB com alta resolução, coletadas por câmeras embarcadas em VANT para detecção ou classificação de espécies de árvores usando aprendizado profundo. Barré et al. (2017) desenvolveram um sistema de aprendizado profundo para classificar imagens foliares baseadas em espécies de plantas usando redes neurais convolucionais (CNN). Em relação à classificação de espécies de plantas e detecção de doenças com base em imagens foliares, vários trabalhos foram desenvolvidos (LEE et al., 2015; GRIMBLAT et al.,

2016; SLADOJEVIC et al., 2016; FUENTES et al., 2017; POUND et al., 2017; LEE et al., 2017; FERENTINOS, 2018).

Fuentes et al. (2017) desenvolveram um detector baseado em aprendizado profundo para o reconhecimento de doenças e pragas de plantas de tomate em tempo real, considerando três CNN: *Faster Region-Based Convolutional Neural Network* (Faster R-CNN), *Region-Based Fully Convolutional Network* (R-FCN) e *Single Shot Multibox Detector* (SSD).

Os trabalhos acima mencionados não se concentraram no desenvolvimento de uma metodologia para detecção ou classificação de árvores baseadas em aprendizado profundo e imagens RGB com alta resolução coletadas por VANT. O objetivo geral desse trabalho é investigar o uso de técnicas de aprendizado profundo para classificar uma espécie de árvore de importância ambiental em Mato Grosso do Sul conhecida como *Dipteryx alata* (Fabaceae) usando imagens (RGB) de VANT.

De modo a atingir o objetivo geral, têm-se as seguintes etapas:

- Realizar a coleta de imagens em locais selecionados com o uso de VANT;
- Disponibilizar um banco de imagens com anotações da espécie estudada;
- Avaliar o método de detecção de objetos RetinaNet na identificação de *Dipteryx alata*.

2.2 MATERIAIS E METÓDOS

2.2.1 Áreas de Estudo

Foram selecionados três locais para os voos em Campo Grande, capital de Mato Grosso do Sul. A coleta de imagens foi no período de 18 meses nas proximidades da UFMS. A escolha dos três primeiros locais se deve, em primeiro lugar, a quantidade de *Dipteryx alata*, entre 50 a 70 indivíduos presentes nas áreas, dessa maneira o objetivo de se fazer voos regulares praticamente um voo por mês foi facilitado e também há de ressaltar a proximidade em relação ao campus da UFMS. Evitando, assim, grandes deslocamentos dos pesquisadores e dos equipamentos. Pode-se observar na Figura 3, o

mapa com a visão geral das três áreas de coleta de imagens RGB de estudo mais próximas ao campus da UFMS.



Figura 3 – Mapa geral das três áreas próximas ao campus da UFMS para coleta de imagens para treino, teste e validação. Fonte: o autor (2020)

Posteriormente, outra localidade foi selecionada distante cerca de sete quilômetros das áreas de coleta e formação do *dataset*, com a finalidade ser uma área de teste para verificação da capacidade de generalização do método aplicado, assim, sendo possível uma análise mais condizente com a realidade de campo. Dois voos foram realizados nessa área (Figura 4), o primeiro em agosto de 2019 (período seco) e o segundo voo em novembro de 2019 (período de chuvas).

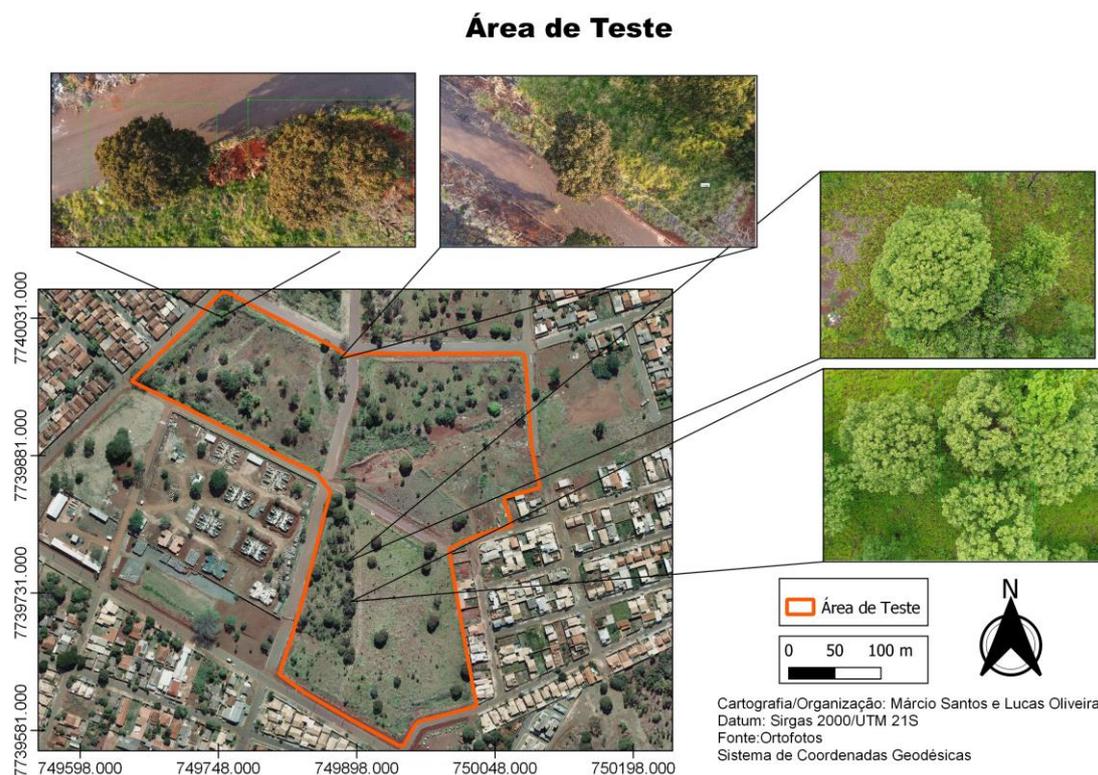


Figura 4 – Mapa da área de teste com anotações da *Dipteryx alata* em outra localidade de Campo Grande, MS, em dois períodos diferentes. Seco e Chuvoso. Com o objetivo de testar o método treinado com as amostras coletadas próximas a UFMS. Fonte: o autor (2020)

2.2.2 Coletas e Anotações das Imagens com VANT

O VANT utilizado nesta exploração foi um Phantom 4 Advanced que é um modelo multi-rotor, produzido pela empresa (DJI, 2017) (ver especificações no quadro 1)

Quadro 1. Especificações do VANT e câmera.

Aeronave	Sensor	Lente	Tamanho da imagem
DJI Phantom4 Advanced	20MP de 1”	FOV 84° 8.8mm/24mm	3:2 Aspect Ratio: 5472x3648

Fonte: Adaptado de (DJI, 2017)

As coletas das imagens foram realizadas entre agosto de 2018 e dezembro de 2019, com doze sobrevoos do VANT nas áreas de estudo representada na Figura 3. A altura de voo média de coleta das imagens foi de 30 metros, com uma variação de até 10

metros pela altimetria do terreno. Obteve-se um total de 369 imagens anotadas com retângulo envolvente para esse período específico.



(a)



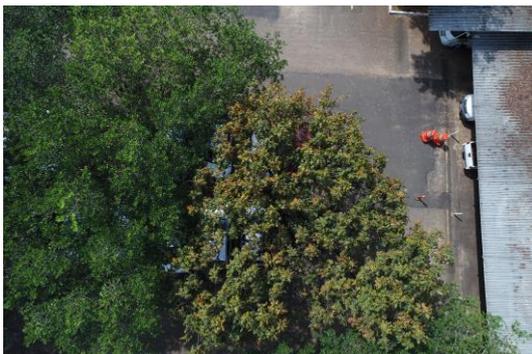
(b)



(c)



(d)



(e)



(f)



(g)



(h)



(i)



(j)



(k)



(l)

Figura 5: Exemplos de imagens capturadas em: (a) 18 de agosto de 2018, (b) 26 de agosto de 2018, (c) 31 de agosto de 2018, (d) 13 de setembro de 2018, (e) 21 de setembro de 2018, (f) 22 de setembro de 2018, (g) 14 de abril de 2019, (h) 15 de maio de 2019, (i) 30 de maio de 2019, (j) 9 de julho de 2019, (k) 13 de agosto de 2019, (l) 06 de dezembro de 2019. As figuras (a,b, c, d,e, g) pertencem a área de coleta 1, as figuras (f,k, l) pertencem a área de coleta 2, as figuras (i, j, h) pertencem a área de coleta 3.

Na quarta área, os voos foram realizados em agosto de 2019, um período com poucas chuvas e em que a *Dipteryx alata* apresenta características mais seca. O segundo voo foi realizado em novembro de 2019, um período em que a chuvas ocorrem com mais frequência e as árvores apresentam características mais viçosas. Para esta área obteve-se um total de 73 imagens anotadas.



(a)



(b)



(c)



(d)

Figura 6: exemplos de imagens capturadas em 21 de agosto de 2019 (a,b) período seco e 28 de novembro de 2019 (c,d) período chuvoso para a formação de outro *dataset* em localidade distante das três primeiras áreas.

2.2.3 Protocolo experimental

Os modelos foram treinados e testados em um computador de mesa com uma CPU Intel (R) Xeon (E) E3-1270@3.80GHz, memória de 64 GB e placa gráfica NVIDIA Titan V (núcleos CU20 (5120 Compute Unified Device Architecture) e 12 GB

de memória gráfica). Os algoritmos de detecção foram codificados usando o Keras-Tensorflow no sistema operacional Ubuntu 18.04.

Os experimentos foram conduzidos da seguinte maneira, primeiro, as imagens foram adquiridas em diferentes épocas do ano por uma câmera RGB em uma plataforma VANT, posteriormente as árvores da espécie *Dipteryx alata* foram anotadas nas imagens com um retângulo envolvente (*Bounding box*). Na etapa seguinte, o método RetinaNet foi treinado para detectar as instâncias da árvore em um conjunto de treinamento e validação. Na terceira etapa, as imagens não utilizadas para treinamento e validação, foram submetidas às redes treinadas, que previam as ocorrências de *Dipteryx alata* por meio de retângulo na árvore detectada. Por fim, as métricas de precisão foram calculadas.

Santos et al. (2019) verificou que o método de detecção RetinaNet se comparado ao Faster R-CNN (Faster Region-based Convolutional Neural Network) e YOLOv3 foi o que apresentou resultados mais acurados na detecção de *Dipteryx alata*, e por esse motivo optou-se por utilizar esse método no presente estudo. Uma contribuição da pesquisa é prover um conjunto de dados (*dataset*) e aprimorar o mesmo proposto por Santos et al. (2019), pois novas imagens foram adicionadas e uma nova localidade para captação de imagens de teste também.

Nas três primeiras áreas, as imagens foram utilizadas para treino, teste e validação. No segundo conjunto de imagens usou-se uma quarta área, com a finalidade apenas de teste. Dando uma noção de realidade em um local oposto de como seria a detecção em ambiente diferente do estudo inicial.

O RetinaNet é um detector de objeto de um estágio, mas soluciona o desequilíbrio de classe ao reduzir a perda atribuída a imagens bem classificadas (SANTOS et al.,) O desequilíbrio de classe ocorre quando o número de exemplos de *background* é muito maior que os exemplos do objeto de interesse *Dipteryx alata*. Usando essa nova função de perda, o treinamento se concentra em exemplos concretos e evita que o grande número de exemplos de *background* atrapalhe o aprendizado do método. A arquitetura RetinaNet consiste em um *backbone* e duas sub-redes específicas de tarefas como espinha dorsal, o RetinaNet adota a *Feature Pyramid Network* de Lin et al. (2017) responsável por computar um mapa de recursos em toda uma imagem de entrada. A primeira sub-rede é responsável por prever a probabilidade de presença do

objeto em cada posição espacial. Essa sub-rede é uma pequena rede totalmente convolucional (cinco camadas convolucionais) conectada ao *backbone*. A segunda sub-rede, paralela à sub-rede de classificação de objetos, executa a regressão da caixa delimitadora, e realiza a classificação. O design dessas sub-rede é idêntico ao primeiro, exceto pelo fato de estimar as coordenadas da caixa para cada localização espacial no final.

O otimizador Adam foi usado para treinar o método de detecção de objetos. Definimos a taxa de aprendizado como 0,00001. A rede foi treinada através de várias épocas até a perda estabilizar nos conjuntos de treinamento e validação. O número de épocas foi definido em 250.

O desempenho é relatado na próxima seção por curvas de precisão-revocação e a precisão média (AP) (Evirhigham et al., 2015). Para estimar a precisão e o recall, calculamos a Intersecção sobre União (IoU), que é dada pela área sobreposta entre as caixas delimitadoras da verdade prevista e do terreno, divididas pela área de união entre elas. Seguindo competições conhecidas na detecção de objetos, uma detecção correta (Verdadeiro Positivo, TP) é considerada para $\text{IoU} \geq 0,5$ e uma detecção incorreta (Falso Positivo, FP) para $\text{IoU} < 0,5$. Um Falso Negativo (FN) é atribuído quando nenhuma verdade de terra correspondente é detectada. Dadas as métricas acima, a precisão e a revocação são estimadas usando as Equações (1) e (2), respectivamente. Considerou-se além do IoU 0,5, também os valores de 0,6, 0,7 e 0,8. A precisão média é dada pela área sob a curva de recuperação de precisão.

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

O experimento foi feito considerando as três áreas similares ao trabalho de (Santos et al., 2019). Entretanto foi adicionada uma quarta área em uma localidade diferente com a intenção de ser um teste independente em relação às três primeiras. Nesse foram utilizadas 73 imagens de dois períodos diferentes a época seca em agosto de 2019 e a época chuvosa em novembro de 2019.

2.3 RESULTADOS E DISCUSSÃO

A Tabela 2 apresenta os resultados das detecções, considerando diferentes valores de IoU (0,5; 0,6; 0,7 e; 0,8). Na medida em que se aumenta o valor do IoU exigido, tem-se uma redução na precisão, conforme pode ser verificado na Tabela 1.

Tabela 1: Precisão obtida na detecção considerando diferentes valores de IoU.

CONJUNTO	IoU			
	0,5	0,6	0,7	0,8
Áreas de Coleta (1,2,3)	90,88	88,25	70,30	57,56
Área de teste	80,42	77,09	58,89	33,27

Fonte: Próprio autor

Os resultados mostram que nas áreas de coleta que envolvem as três próximas ao campus da UFMS, uma acurácia de 90% foi obtida nas imagens de teste, considerando um IoU de 0,5. Ao considerar a segunda área de teste, distante da UFMS, têm-se resultados inferiores, atingindo cerca de 80% para o mesmo IoU. Esse resultado indica a necessidade de experimentos adicionais voltados para adaptação de domínio. Ao considerar uma área completamente diferente da área usada para treino, tem-se uma redução de 10% na precisão.

O método foi capaz de detectar árvores de *Dipteryx alata*, mesmo em imagens capturadas sob diferentes condições de iluminação, conforme pode ser verificado nas Figuras 7 e 8.

A Figura 7 mostra os resultados da detecção em diferentes estações do ano, pois as árvores de *Dipteryx alata* têm cores e aparência diferentes. As que foram detectadas em agosto possuem castanhas e características secas, enquanto as detectadas em novembro apresentam a *Dipteryx alata* viçosa e com flores. Voss e Sugumaran (2008) mostraram que métodos treinados em imagens capturadas no outono apresentam resultados mais consistentes para aqueles treinados com imagens capturadas no verão. Por outro lado, o método utilizado neste trabalho não precisa ser treinado separadamente para cada estação e apresentam precisão consistente em comparação aos métodos da literatura.



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)

Figura 7 - Exemplos de resultados de detecção em imagens com diferentes luminosidades na área de teste: (a, c, e, g) no dia 21 de agosto de 2019 e; (b, d, f, h) no dia 28 de novembro de 2019. Em verde tem-se a anotação e em vermelho a detecção pelo método.

É válido destacar que as anotações em imagens de espécies arbóreas quando feitas somente na parte interna da copa, costumam gerar mais de uma detecção na mesma árvore como pode ser visto no exemplo da Figura 8. Para solucionar esse problema, realizou-se experimento com a anotação em toda a árvore (retângulo envolvente), mesmo que nela, pequenas amostras de grama, terra ou diferentes espécies também estivessem inseridas. No entanto, ao fazer experimentos nesse sentido, verificou-se uma degradação dos resultados. Para a área de teste, obteve-se uma precisão de aproximadamente 76% para o IoU 0,5. Portanto, sugere-se considerar retângulos internos às árvores.



Figura 8: Exemplos de imagens com mais de uma detecção na mesma árvore (21 de agosto de 2019).

Os resultados da pesquisa se mostram acurados, na mesma ordem aos obtidos nos trabalhos de Immitizer et al. (2012) que apresentou em geral, a precisão maior para as 5 espécies de árvores decíduas (89%). Franklin et al. (2018) relataram que uma amostra de validação independente de 23 copas de árvores foi, no geral, aproximadamente 78% correta, e Dalponte et al. (2013) retrataram precisão geral de 88,1%, índice kappa de 75,7% e precisão média de classe de 61,5%.

2.4 CONCLUSÕES

Neste trabalho, propusemos e avaliamos uma abordagem para a detecção de *Dipteryx alata* com base na rede neural convolucional e imagens de alta resolução

capturadas por câmeras RGB em uma plataforma VANT. Foi testado o método RetinaNet, que compõe o estado da arte em detecção de objetos. Nos experimentos realizados em um conjunto de dados composto por 369 imagens, o RetinaNet alcançou uma precisão de 90,88%. No teste realizado com um conjunto de 73 imagens em uma área oposta e diferente da de treino, o RetinaNet forneceu uma precisão de 80,42%. Sugere-se para trabalhos futuros que abordagens de adaptação de domínio sejam empregadas para melhoria dos resultados.

Os resultados experimentais indicam que as câmeras RGB conectadas aos VANT e algoritmos de detecção baseados em CNN constituem uma abordagem promissora para o desenvolvimento de ferramentas operacionais para estimativas populacionais de espécies arbóreas, bem como para o monitoramento demográfico de árvores, fundamental para integrar o desenvolvimento econômico e a conservação dos Recursos Naturais.

REFERÊNCIAS

- ALONZO, M.; BOOKHAGEN, B.; ROBERTS, D. A. Urban tree species mapping using hyperspectral and lidar data fusion. **Remote Sensing of Environment**, v. 148, p. 70-83, 2014.
- ANDERSEN, H. E.; REUTEBUCH, S. E.; MCGAUGHEY, R. J. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. **Canadian Journal of Remote Sensing**, v. 32, n. 5, p. 355-366, 2006.
- BARRÉ, P. *et al.* LeafNet: A computer vision system for automatic plant species identification. **Ecological Informatics**, v. 40, p. 50-56, 2017.
- BERVEGLIERI, A. *et al.* Successional stages and their evolution in tropical forests using multi-temporal photogrammetric surface models and superpixels. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, p. 548-558, 2018.
- BERVEGLIERI, A.; TOMMASELLI, A. M. G. Reconstruction of cylindrical surfaces using digital image correlation. **Sensors (Switzerland)**, v. 18, n. 12, 2018.
- BRANDTBERG, T. Classifying individual tree species under leaf-off and leaf-on conditions using airborne lidar. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 61, n. 5, p. 325-340, 2007.
- BRASIL. Constituição Federal de 1988. Diário Oficial da União, Brasília, 5 out. 1988.

BRASIL. **Decreto nº7830, de 17 de outubro de 2012.** Dispõe sobre o Sistema de Cadastro Ambiental Rural, o Cadastro Ambiental Rural, estabelece normas de caráter geral aos Programas de Regularização Ambiental, de que trata a Lei no 12.651, de 25 de maio de 2012, e dá outras providências. 2012.

BRASIL. **Resolução Conama n. 237, de 19 de dezembro de 1997.** Dispõe sobre os procedimentos e critérios utilizados no licenciamento ambiental e no exercício da competência, bem como as atividades e empreendimentos sujeitos ao licenciamento ambiental. Diário Oficial da União, Brasília, seção 1, 22 dez. 1997, p. 30841-30843.

CARRAZA, L. R. **Manual Tecnológico de Aproveitamento Integral do Fruto do Baru.** Brasília – DF. Instituto Sociedade, População e Natureza (ISPN). Brasil, 2010.56 p.; il. - (Série Manual Tecnológico) ISBN: 978-85-63288-02-8

C.L. Zitnick and S.B. Kang, “Stereo for Image-Based Rendering Using. Image Over-Segmentation,” *Int’l J. Computer Vision*, vol. 75, pp. 49-65, Oct. 2007.

CHO, M. A. *et al.* Mapping tree species composition in South African savannas using an integrated airborne spectral and LiDAR system. **Remote Sensing of Environment**, v. 125, p. 214-226, 2012.

CLARK, M. L.; ROBERTS, D. A.; CLARK, D. B. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. **Remote Sensing of Environment**, v. 96, n. 3-4, p. 375-398, 2005.

DALPONTE, M. *et al.* Tree crown delineation and tree species classification in boreal forests using hyperspectral and ALS data. **Remote Sensing of Environment**, v. 140, p. 306-317, 2014.

DALPONTE, M. *et al.* Tree species classification in boreal forests with hyperspectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 5, p. 2632-2645, 2013.

DALPONTE, M. *et al.* Unsupervised selection of training plots and trees for tree species classification. **International Geoscience and Remote Sensing Symposium (IGARSS)**, 2013. Conference Paper. p.2095-2098.

DALPONTE, M.; BRUZZONE, L.; GIANELLE, D. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. **Remote Sensing of Environment**, v. 123, p. 258-270, 2012.

EVERINGHAM, M.; Eslami, S.M.A.; Van Gool, L.;Williams, C.K.I.;Winn, J.; Zisserman, A. The Pascal Visual Object Classes Challenge: A Retrospective. *Int. J. Comput. Vis.* 2015, 111, 98–136.

- FENG, Q.; LIU, J.; GONG, J. UAV Remote sensing for urban vegetation mapping using random forest and texture analysis. **Remote Sensing**, v. 7, n. 1, p. 1074-1094, 2015.
- FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, v. 145, p. 311-318, 2018.
- FERREIRA, A.S. *et al* Weed detection in soybean crops using ConvNets, **Computers and Electronics in Agriculture**, Volume 143, 2017, Pages 314-324, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2017.10.027>.
- FRANKLIN, S. E.; AHMED, O. S. Deciduous tree species classification using object-based analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, v. 39, n. 15-16, p. 5236-5245, 2018. ISSN 0143-1161.
- FUENTES, A. *et al*. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. **Sensors (Switzerland)**, v. 17, n. 9, 2017.
- GARRIDO, M. *et al*. Active optical sensors for tree stem detection and classification in nurseries. **Sensors (Switzerland)**, v. 14, n. 6, p. 10783-10803, 2014.
- GRINBLAT, G. L. *et al*. Deep learning for plant identification using vein morphological patterns. **Computers and Electronics in Agriculture**, v. 127, p. 418-424, 2016.
- HANSEN, M. C.; *et al*. High-resolution global maps of 21st-century forest cover change. **Science**, v. 342, n. 6160, pp. 850-853, 2013.
- HAYKIN, S. Redes neurais: princípios e prática. Tradução de Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001.
- HEINZEL, J.; KOCH, B. Exploring full-waveform LiDAR parameters for tree species classification. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 1, p. 152-160, 2011.
- IMMITZER, M. *et al*. Use of WorldView-2 stereo imagery and National Forest Inventory data for wall-to-wall mapping of growing stock. **Forest Ecology and Management**, v. 359, p. 232-246, 2016.
- IMMITZER, M.; ATZBERGER, C.; KOUKAL, T. Suitability of WorldView-2 data for tree species classification with special emphasis on the four new spectral bands. **Photogrammetrie, Fernerkundung, Geoinformation**, v. 2012, n. 5, p. 573-588, 2012a.

IMMITZER, M.; VUOLO, F.; ATZBERGER, C. First experience with Sentinel-2 data for crop and tree species classifications in central Europe. **Remote Sensing**, v. 8, n. 3, 2016.

KORPELA, I. *et al.* Tree species classification using airborne LiDAR - effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica*, v. 44, n. 2, p. 319-339, 2010.

KORPELA, I.; ROHRBACH, F. Variation and anisotropy of reflectance of forest trees in radiometrically calibrated airborne line sensor images - Implications to species classification. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 2010. **Conference Paper**. p.342-347.

LANDENBURGER, L. *et al.* Mapping regional distribution of a single tree species: Whitebark pine in the Greater Yellowstone Ecosystem. **Sensors**, v. 8, n. 8, p. 4983-4994, 2008.

LANDENBURGER, L.; Lawrence, R.L.; Podruzny, S.; Schwartz, C.C. Mapping Regional Distribution of a Single Tree Species: Whitebark Pine in the Greater Yellowstone Ecosystem. **Sensors** 2008, 8, 4983-4994.

LEE, S. H. *et al.* Deep-plant: Plant identification with convolutional neural networks. *Proceedings - International Conference on Image Processing, ICIP*, 2015. **Conference Paper**. p.452-456.

LEE, S. H. *et al.* How deep learning extracts and learns leaf features for plant classification. **Pattern Recognition**, v. 71, p. 1-13, 2017.

LIN, T.; Dollár, P.; Girshick, R.; He, K.; Hariharan, B.; Belongie, S. Feature Pyramid Networks for Object Detection. In *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* Honolulu, HI, USA, 21–26 July 2017; pp. 936–944.

MINISTÉRIO DO MEIO AMBIENTE (MMA). Cerrado. 2019. Disponível em: <<http://www.mma.gov.br/biomas/cerrado>>. Acesso em: 03 de março de 2019.

MIZOGUCHI, T. *et al.* Lidar-based individual tree species classification using convolutional neural network. *Proceedings of SPIE - The International Society for Optical Engineering*, 2017. **Conference Paper**.

NAIDOO, L. *et al.* Classification of savanna tree species, in the Greater Kruger National Park region, by integrating hyperspectral and LiDAR data in a Random Forest data mining environment. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 69, p. 167-179, 2012.

NEVALAINEN, O. *et al.* Individual tree detection and classification with UAV-Based photogrammetric point clouds and hyperspectral imaging. **Remote Sensing**, v. 9, n. 3, 2017.

ØRKA, H. O. *et al.* Characterizing forest species composition using multiple remote sensing data sources and inventory approaches. **Scandinavian Journal of Forest Research**, v. 28, n. 7, p. 677-688, 2013.

POUND, M. P. *et al.* AutoRoot: Open-source software employing a novel image analysis approach to support fully-automated plant phenotyping. **Plant Methods**, v. 13, n. 1, 2017.

POUND, M. P. *et al.* Deep machine learning provides state-of-the-art performance in image-based plant phenotyping. **GigaScience**, v. 6, n. 10, 2017.

PUTTONEN, E. *et al.* Tree classification with fused mobile laser scanning and hyperspectral data. **Sensors**, v. 11, n. 5, p. 5158-5182, 2011.

QGIS Development Team. QGIS Geographic Information System. Versão 2.18. Open Source Geospatial Foundation Project. <<http://qgis.osgeo.org>>. 2017.

SÁNCHEZ-AZOFEIFA, A. *et al.* Estimation of the distribution of *Tabebuia guayacan* (Bignoniaceae) using high-resolution remote sensing imagery. **Sensors**, v. 11, n. 4, p. 3831-3851, 2011.

SÁNCHEZ-AZOFEIFA, A.; Rivard, B.; Wright, J.; Feng, J.-L.; Li, P.; Chong, M.M.; Bohlman, S.A. Estimation of the Distribution of *Tabebuia guayacan* (Bignoniaceae) Using High-Resolution Remote Sensing Imagery. **Sensors** **2011**, 11, 3831-3851.

SÁNCHEZ-AZOFEIFA, G. A. *et al.* Wireless sensing networks for environmental monitoring: Two case studies from tropical forests. Proceedings - 2011 7th IEEE International Conference on eScience, eScience 2011, 2011. **Conference Paper**. p.70-76.

SANTOS, A.A.; Marcato Junior, J.; Araújo, M.S.; Di Martini, D.R.; Tetila, E.C.; Siqueira, H.L.; Aoki, C.; Eltner, A.; Matsubara, E.T.; Pistori, H.; Feitosa, R.Q.; Liesenberg, V.; Gonçalves, W.N. Assessment of CNN-Based Methods for Individual Tree Detection on Images Captured by RGB Cameras Attached to UAVs. **Sensors** **2019**, 19, 3595.

SEMADE. **RESOLUÇÃO SEMADE n. 9**, de 13 de maio de 2015. 2015.

SLADOJEVIC, S. *et al.* Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. **Computational Intelligence and Neuroscience**, v. 2016, 2016.

VOSS, M.; SUGUMARAN, R. Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach. **Sensors**, v. 8, n. 5, p. 3020-3036, 2008.

YAO, C.; GAO, G. The direct registration of lidar point clouds and high resolution image based on linear feature by introducing an unknown parameter. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 2012. **Conference Paper**. p.403-408.

YAO, W.; KRZYSZEK, P.; HEURICH, M. Tree species classification and estimation of stem volume and DBH based on single tree extraction by exploiting airborne full-waveform LiDAR data. **Remote Sensing of Environment**, v. 123, p. 368-380, 2012.