

Classificando estratos vegetais de uma área do Bioma Caatinga com imagens de VANTs

Vitor José Ferreira dos Santos de Santana
PAAD - Núcleo Pesq. Avanç.
Anál. Dados - Universidade Federal do Piauí (UFPI)
Picos – PI – Brazil
vitorsantos@ufpi.edu.br

Humberto José da Silva Júnior
PAAD - Núcleo Pesq. Avanç.
Anál. Dados - Universidade Federal do Piauí (UFPI)
Picos – PI – Brazil
1bertojr@ufpi.edu.br

Frank César Lopes Vêras
PAAD - Núcleo Pesq. Avanç.
Anál. Dados - Universidade Federal do Piauí (UFPI)
Picos – PI – Brazil
frank@ufpi.edu.br

Daniel Louçana da Costa Araújo
CCA - Centro de Ciências Agrárias – Universidade Federal do Piauí (UFPI)
Teresina – PI – Brazil
danielloucana@ufpi.edu.br

ABSTRACT

This article presents a low-cost UAV that was assembled and used in the classification of vegetation strata in a Caatinga biome area, aiming to enable the capture and classification of images in a more accessible manner. The high cost of these aircraft has been a barrier to research and agricultural development in disadvantaged regions of Brazil. In this study, the capture and processing of images played an important role in binary classification, subjecting them to the MobileNetV2 Neural Network. The results achieved an accuracy of 93% for the Herbaceous stratum, 94% for the Shrub stratum, and 83% for the Tree stratum, and 91% in the multiclass classification of the three strata, highlighting the potential of the proposed approach.

Keywords

Estratos Vegetais, Classificação, Bioma Caatinga, Monitoramento remoto, Tecnologia Agrícola

1. INTRODUÇÃO

Os VANTs (Veículos Aéreos Não Tripulados) são aeronaves que não requerem tripulação e podem ser pilotadas remotamente ou por meio de sistemas de navegação, como o GPS (Sistema de Posicionamento Global) [7]. Assim, eliminando o risco de acidentes com a tripulação durante o processo e voos mais próximos ao solo [2]. O uso de VANTs tem mostrado ser uma ferramenta promissora para auxiliar os agricultores a solucionar diversos problemas na agricul-

tura. No entanto, a principal dificuldade enfrentada pelos agricultores que desejam utilizar VANTs está atrelada ao seu custo elevado [10], impossibilitando o acesso dos mesmos a essas tecnologias.

No bioma Caatinga, ilustrado na Figura 1 e que detalha a macroregião de Picos - PI, a vegetação é composta, assim como outras regiões do sertão nordestino, por plantas xerófilas que são adaptadas ao solo seco e à escassez de água da região [1]. Além de grande diversidade, a Caatinga é o bioma brasileiro mais alterado e impactado pelas ações das atividades humanas [13]. Devido à estacionalidade climática recorrente em regiões de Caatinga, é bastante comum no período das águas ter uma grande diversidade de espécies vegetais, principalmente herbácea [9]. Durante todo o ano, o pecuarista local utiliza a vegetação disponível no ambiente para alimentar sua criação de ruminantes sendo que as gramíneas e dicotiledôneas herbáceas podem fazer parte da alimentação de ruminantes no período chuvoso, compondo mais de 80% da dieta [3].

Os ecossistemas terrestres apresentam estratos vegetativos essenciais, proporcionando uma diversidade vertical crucial para a flora e fauna. Esses estratos, incluindo herbáceo, arbustivo e arbóreo, representam plantas de baixo porte, arbustos intermediários e árvores imponentes, contribuindo para uma distribuição vertical única. A interdependência entre esses estratos é crucial para a estabilidade ecológica, revelando uma hierarquia vegetal fascinante que molda os ecossistemas terrestres. Em geral, a vegetação da Caatinga é composta por três estratos, a saber: a) arbóreo - representa árvores de 8 a 12 metros de altura; b) arbustivo - representa vegetação de 2 a 5 metros de altura; c) herbácea - representa vegetação com menos de 2 metros de altura [1]. A Figura 2 esboça a diferença entre os estratos vegetais.

Este trabalho apresenta a montagem de um VANT com frame F-450, equipado com uma câmera *Ultra 4K-Sport* para a coleta de imagens vegetativas da Caatinga e a utilização de uma Rede Neural Convolutacional (CNN - *Convolutional Neural Networks*), com a arquitetura *MobileNetV2*, para classificação dos estratos vegetais, no intuito de contribuir para o

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

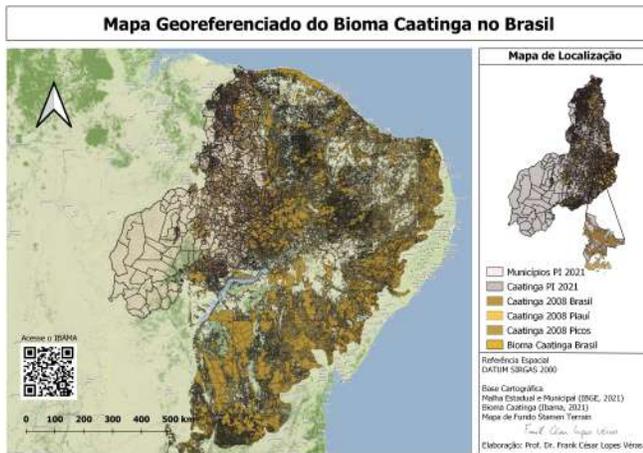


Figure 1: Mapa Georeferenciado da Caatinga no Brasil - Fonte: [6]



Figure 2: Esboço dos estratos vegetais - Fonte: Os autores

avanço da pecuária na região piauiense, identificando áreas de vegetação aptas para pastagem. O artigo é estruturado nas seguintes seções: Seção 2, são descritos e comparados os trabalhos relacionados ao presente estudo; Seção 3, é apresentada a metodologia para execução do projeto; Seção 4, são apresentados os resultados do projeto; Seção 5, as considerações finais e propostas para trabalhos futuros.

2. TRABALHOS RELACIONADOS

Nesta seção, é apresentada uma revisão da literatura existente e suas contribuições para o tema deste trabalho, enfocando os principais estudos e pesquisas relacionados à montagem de drones e à classificação ou detecção de vegetação. A carência de trabalhos sobre a identificação das espécies vegetais nativas da Caatinga piauiense é destacada, resultando na busca por pesquisas que abranjam não apenas a região semiárida, mas também outras áreas que abordem problemas semelhantes ao proposto neste artigo. Estes trabalhos são semelhantes a este artigo quanto à prática de identificação de espécies por redes neurais e estão, de forma resumida, apresentados na Tabela 1. A mesma organiza os trabalhos quanto aos seguintes aspectos: I - Modelo de VANT; II - Região mapeada; e III - Classificação da vegetação.

O artigo de [8] trata do desenvolvimento de um VANT de baixo custo de asa rotativa que utiliza um microcontrolador arduíno Atmel AVR, que foi incapaz de gerenciar todos os sensores e ter uma boa comunicação com a estação de controle e a placa de estabilização, resultando no cancelamento dos testes de voo autônomo. Neste artigo foi utilizada uma controladora APM (*Ardupilot Mega 2.8*) que apresenta mel-

Table 1: Quadro comparativo de trabalhos relacionados

Trabalho	I	II	III
[8]	F-450	Não	Não
[11]	Skywalker X8	Não	Não
[5]	Phantom 3 Advanced	Costa da Caparica, Palmela e Sintra - Portugal	Sim
[12]	Phantom 4 Advanced	Ponta Grossa - PR	Sim
Este artigo	F-450	Picos-PI	Sim

I — Modelo de VANT; II — Região mapeada; III — Classificação da vegetação;

hores resultados acerca desses aspectos.

O trabalho de [11] descreve o desenvolvimento e montagem de um VANT (Veículo Aéreo Não Tripulado) de asa fixa de baixo custo para suprir a demanda de ensino e pesquisa nas Geociências. A plataforma escolhida foi o *Skywalker X8* e o controlador de voo foi o *Pixhawk*. O artigo destaca as vantagens do uso de plataformas de asa fixa, como maior velocidade de voo, maior cobertura de área, maior segurança, baixo consumo de bateria, maior capacidade de carregar equipamentos, maior tempo de voo e baixo custo de fabricação e manutenção.

O trabalho de [5] descreve a criação de um sistema de classificação automática da espécie invasora *Acacia Longifolia* utilizando imagens de VANTs. As imagens foram subdivididas em conjuntos de 200 x 200 pixels para facilitar a classificação, resultando em uma segmentação da vegetação. O sistema utiliza duas redes neurais, **CNNMulti** para identificar 9 classes na paisagem e **CNNbin** para detectar exclusivamente a presença de *Acacia Longifolia*. A rede apresentou uma vantagem de precisão e taxa de acerto, em detrimento aos classificadores clássicos de aprendizagem. O sistema de classificação alcançou uma acurácia de 98.7% utilizando o conjunto de teste.

O trabalho de [12] propõe o desenvolvimento de um sistema para detecção e quantificação de plantas de milho, utilizando técnicas de processamento de imagens e aprendizagem de máquina, com ênfase na utilização de uma Convolutional Neural Network (CNN) baseada na arquitetura RetinaNet. O autor destaca a eficácia da CNN na resolução de problemas de detecção, apresentando resultados promissores, incluindo uma precisão de 99% nos experimentos conduzidos com imagens obtidas por VANT.

3. METODOLOGIA

Este projeto efetuou a montagem de um VANT, cujo corpo apoia-se em um *frame* F-450. Os componentes eletrônicos foram construídos com o objetivo de ter-se uma arquitetura que tornasse possível a classificação dos estratos vegetais, especificamente na zona rural do município de Picos - PI, região típica da Caatinga. A representação do trabalho realizado é esboçada na Figura 3 e idealizada em 5 etapas: montagem do VANT; coleta das imagens; pré-processamento das imagens; classificação binária; validação dos resultados.

Na primeira etapa foi realizado a montagem do VANT, Figura 4, conforme a Tabela 2 que descreve seus componentes detalhando cada parte e sua função específica. O Frame F-450 serve como a base estrutural do drone. O Ardupilot APM 2.8 atua como o controlador de voo proporcionando estabilidade. Para a navegação, o M8N GPS

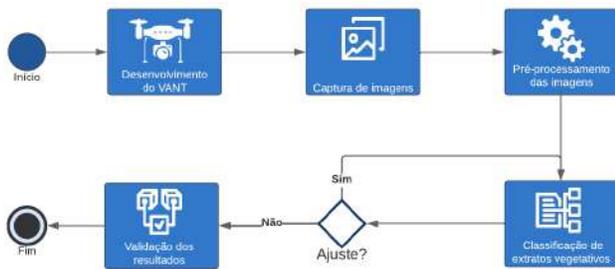


Figure 3: Metodologia - Fonte: Os autores

Compass oferece a geolocalização. Os 04 Módulos ESCs são controladores eletrônicos de velocidade que, junto aos 04 Motores brushless de 980 Kv, garantem a propulsão adequada.



Figure 4: F-450 em período de montagem - Fonte: Os autores

O sistema de comunicação é composto pelo receptor Flysky FSiA6B e pelo transmissor Flysky FS-i6, ambos operando em 2.4GHz. A bateria LiPo Power de 4200 mAh fornece a energia para o funcionamento do drone. Por fim, a Câmera Ultra HD 4K permite capturar imagens. Cada componente é fundamental para o desempenho e eficácia do VANT em suas missões aéreas.

Table 2: Componentes do VANT

#	Componente	Função
1	Frame F-450	Base de montagem do drone (46 x 46 cm).
2	ArduPilot APM 2.8	Controlador de voo.
3	M8N GPS Compass	GeoLocalização para a navegação do drone.
4	04 Módulos ESCs	Controladores eletrônicos de velocidade.
5	04 Motores <i>brushless</i>	980 Kv regulados pelos ESCs.
6	04 Hélices	10 polegadas de diâmetro e um passo de 4,5 .
7	Flysky FSiA6B	Receptor de 2.4GHz.
8	Flysky FS-i6	Transmissor - Controle remoto de 2,4 GHz.
9	Bateria	LiPo Power 4200 mAh.
10	Câmera Ultra HD 4K	Qualidade Full HD 1080p e imagem 4K

Durante a segunda fase do projeto, procedeu-se à captura de imagens aéreas em duas localidades distintas da região de Picos. Esta fase resultou em um conjunto de fotografias de alta resolução, cada uma com 4.000 x 2.250 pixels. A maioria das imagens aéreas retrata a vegetação durante a estação chuvosa, caracterizada por folhas verdes conforme exemplificado nas Figuras 5 e 6.

Na fase de pré-processamento, as imagens foram submetidas a um processo de corte utilizando uma grelha regular



Figure 5: Imagem aérea capturada pelo VANT com predominância dos estratos Arbóreo e Arbustivo - Fonte: Os autores



Figure 6: Imagem aérea capturada pelo VANT com predominância do estrato Herbáceo - Fonte: Os autores

de dimensões 250x250 pixels. A Figura 7 esboça o funcionamento da grelha regular. Esse procedimento foi aplicado a todas as imagens, totalizando 3.318 amostras, sendo 442 do estrato Arbóreo, 485 do estrato Arbustivo e 2000 do estrato Herbáceo. O conjunto de dados foi particionado em três conjuntos distintos: treino, validação e teste, conforme a Tabela 3.

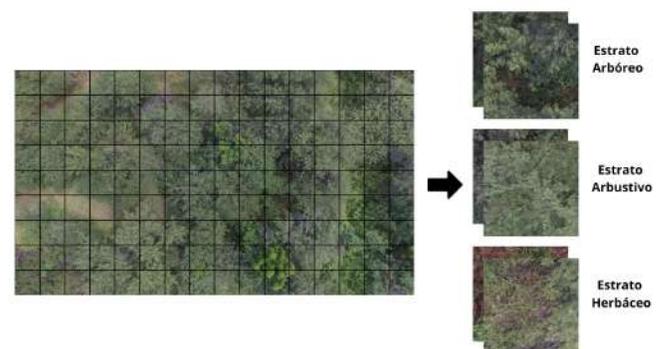


Figure 7: Ilustração da grelha regular utilizada na formação do banco de imagens - Fonte: Os autores

Um *pipeline* abrangente para aprimoramento do conjunto de dados incluiu tanto a normalização de todas as imagens

Table 3: Tabela de distribuição de amostras nos conjuntos de treino, validação, teste.

Conjunto de imagens	Número de amostras	Porcentagem das amostras
Treino	2.316	70%
Validação	661	20%
Teste	332	10%
Total	3.318	100%

quanto a aplicação de técnicas de aumento de dados. A normalização precedeu a entrada das imagens no modelo, visando ajustar os valores dos pixels para o intervalo $[0,1]$. Posteriormente, foram implementadas três transformações no conjunto de treinamento por meio do *pipeline* de aumento de dados: a) *RandomFlip*, realizando espelhamento horizontal aleatório; b) *RandomRotation*, introduzindo rotações aleatórias de até 0.2 radianos; e c) *RandomZoom*, aplicando zoom aleatório de até 20%.

A arquitetura da MobileNetV2, empregada neste estudo, destaca-se como uma CNN eficiente e otimizada, projetada especialmente para aplicações em dispositivos móveis e ambientes com recursos computacionais restritos. Desenvolvida pela Google, a MobileNetV2 é reconhecida por sua capacidade de fornecer alto desempenho de classificação de imagens com uma quantidade significativamente menor de parâmetros em comparação com arquiteturas convencionais. O objetivo principal era criar uma arquitetura mais simples, rápida e que permitisse uma integração fácil com aplicativos de celulares [4].

Para a classificação binária, o modelo proposto é uma arquitetura sequencial que incorpora os modelos da *MobileNetV2* para cada estrato estudado. A arquitetura subsequente consiste em camadas adicionais, incluindo uma de redução de dimensionalidade com *GlobalAveragePooling* para extração de características, uma camada de *Dropout* para regularização e, finalmente, uma camada *Dense* de saída com ativação *sigmoid* para conduzir a classificação binária. A função de perda escolhida é *BinaryCrossentropy*, adequada para tarefas de classificação binária.

A arquitetura proposta para classificação multiclases foi implementada por meio de um modelo sequencial seguida por uma camada de *GlobalAveragePooling* para redução de dimensionalidade e uma camada de *Dropout* para regularização, visando mitigar possíveis problemas de *overfitting*. A última camada é uma camada *Dense* com ativação *softmax*, indicando uma tarefa de classificação multiclases, onde o número de unidades corresponde ao número de classes no conjunto de dados. A função de perda escolhida é a *Sparse-CategoricalCrossentropy* apropriada para tarefas de classificação multiclases.

Ambas as arquiteturas utilizaram o otimizador *Adam*, a uma taxa de aprendizado específica de 10^{-4} . Os resultados deste estudo foram apresentados por meio de gráficos e matrizes de confusão, conforme descrito na Seção 4. A avaliação dos resultados foi conduzida por meio das métricas de acurácia e da matriz de confusão no conjunto de testes. A acurácia proporciona uma medida geral da precisão do modelo, enquanto a matriz de confusão permite uma inspeção mais aprofundada das classificações, destacando possíveis fontes de erro e áreas de melhoria. Essa abordagem fortalece a confiabilidade e compreensão dos resultados, contribuindo para uma análise mais abrangente e informativa do desempenho do modelo proposto.

4. RESULTADOS

Nesta seção, são apresentados os resultados obtidos no decorrer do desenvolvimento do VANT, juntamente com a análise do desempenho da rede ao longo de 100 épocas. Durante os voos, o VANT demonstrou uma operação livre de falhas, corroborando sua confiabilidade e validando sua eficácia na execução das missões planejadas reforçando sua utilidade prática e sua capacidade de desempenhar tarefas de forma consistente e confiável. Para avaliar a classificação foi utilizada a métrica de acurácia que representa a precisão geral do modelo em suas previsões e para proporcionar uma compreensão visual do treinamento, foi efetuado o mapeamento gráfico da acurácia e perda em função das épocas.

Para o estrato Herbáceo, a rede alcançou 93% de acurácia quando submetido ao conjunto de imagens de testes. As Figuras 8 e 9 expõem os gráficos do treinamento da rede. A Figura 8 apresenta uma representação visual do comportamento dessa função de perda ao longo das iterações do treinamento. A Figura 9 permite uma análise do comportamento da acurácia durante o período de treinamento, onde é possível observar uma tendência de estabilização dos resultados a partir da época 60.

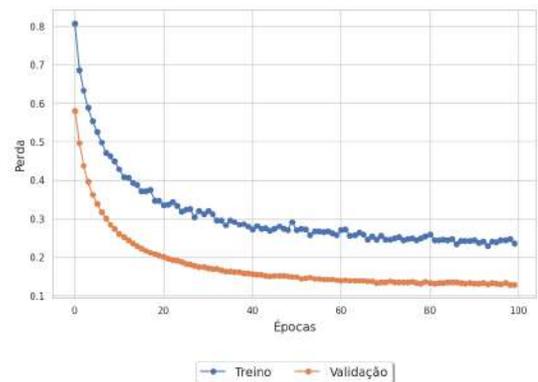


Figure 8: Gráfico de perda no treino e validação do estrato Herbáceo - Fonte: Os autores

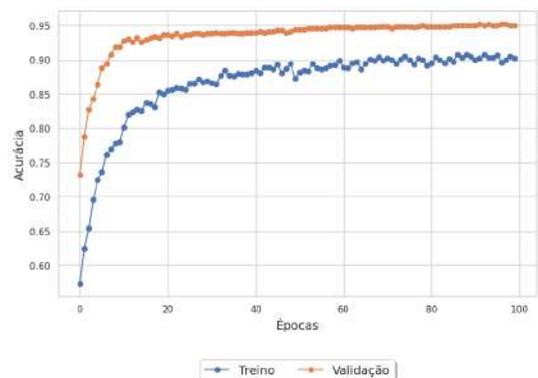


Figure 9: Gráfico de acurácia no treino e validação do estrato Herbáceo - Fonte: Os autores

A Figura 10 ilustra a matriz de confusão obtida na classificação do estrato Herbáceo para o conjunto de teste. Esta matriz é uma ferramenta útil para avaliar a qualidade do

modelo de classificação e identificar áreas que podem precisar de ajustes ou melhorias. No contexto de identificação de herbáceas e não herbáceas, a matriz de confusão fornece uma visão geral do desempenho do modelo e das possíveis fontes de erro nas previsões.

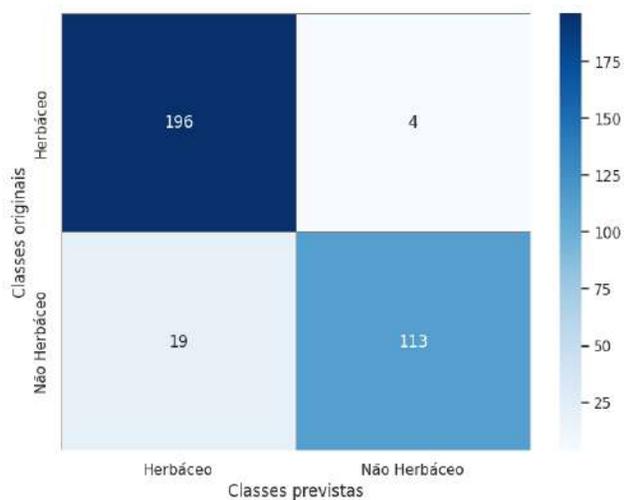


Figure 10: Matriz de confusão da classificação do estrato Herbáceo - Fonte: Os autores

Para o estrato Arbustivo, a rede alcançou 94% de acurácia quando submetido ao conjunto de imagens de testes. As Figuras 11 e 12 expõem os gráficos do treinamento da rede. A Figura 11 apresenta uma representação visual do comportamento dessa função de perda ao longo das iterações do treinamento. A Figura 12 permite uma análise do comportamento da acurácia durante o período de treinamento, onde é possível observar uma tendência de estabilização dos resultados a partir da época 40.

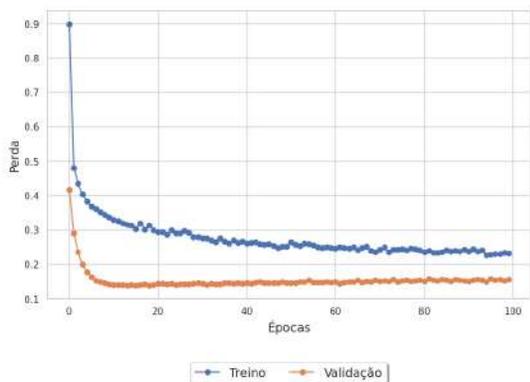


Figure 11: Gráfico de perda no treino e validação do estrato Arbustivo - Fonte: Os autores

A Figura 13 ilustra a matriz de confusão obtida na classificação do estrato Arbustivo para o conjunto de teste. A precisão observada na matriz é um testemunho da eficácia da rede neural na tarefa de classificação. Os resultados indicam que a CNN foi capaz de identificar com alta precisão as categorias corretas dentro do estrato arbustivo, o que demonstra a adequação deste modelo de aprendizado de máquina para

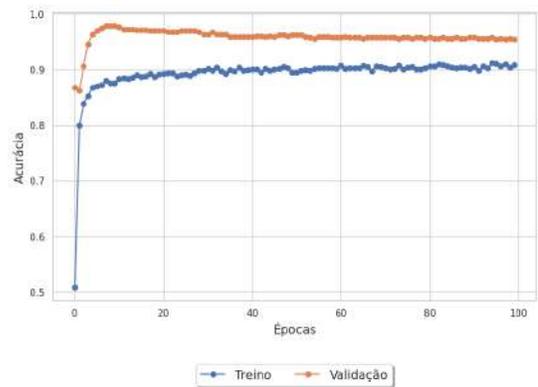


Figure 12: Gráfico de acurácia no treino e validação do estrato Arbustivo - Fonte: Os autores

a análise e classificação de dados complexos em contextos de vegetação.

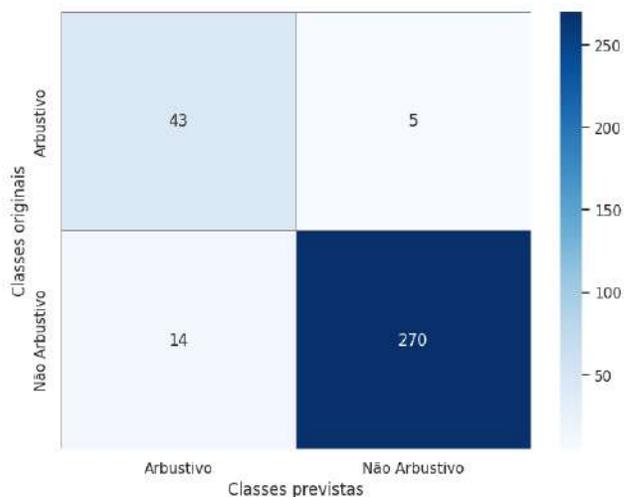


Figure 13: Matriz de confusão da classificação do estrato Arbustivo - Fonte: Os autores

Para o estrato Arbóreo, a rede alcançou 83% de acurácia quando submetido ao conjunto de imagens de testes. As Figuras 14 e 15 expõem os gráficos do treinamento da rede. A Figura 14 apresenta uma representação visual do comportamento dessa função de perda ao longo das iterações do treinamento. A Figura 15 permite uma análise do comportamento da acurácia durante o período de treinamento, onde é possível observar uma tendência de estabilização dos resultados a partir da época 40.

A Figura 16 ilustra a matriz de confusão obtida na classificação do estrato Arbustivo para o conjunto de teste onde há um destaque de queda na precisão da *MobileNetV2* o estrato, indicando um desempenho inferior em comparação aos modelos anteriores. A redução na taxa de acertos pode ser devida a fatores como a similaridade visual entre as classes, variação intraclasse, ou a qualidade dos dados de treinamento. Para melhorar a precisão, pode-se ajustar os parâmetros da CNN, enriquecer o conjunto de dados de treinamento com exemplos mais representativos.

Para a classificação multiclases dos estratos Arbóreo, Ar-

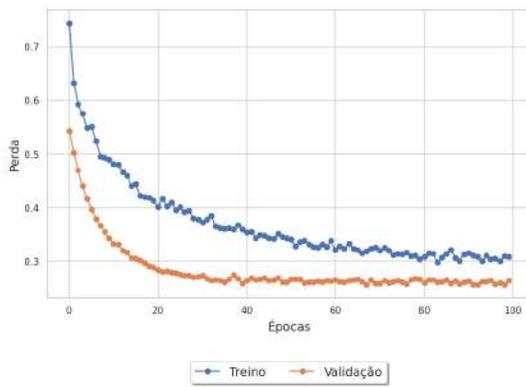


Figure 14: Gráfico de perda no treino e validação do estrato Arbóreo - Fonte: Os autores

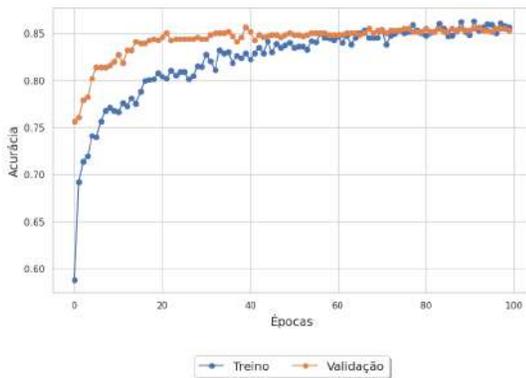


Figure 15: Gráfico de acurácia no treino e validação do estrato Arbóreo - Fonte: Os autores

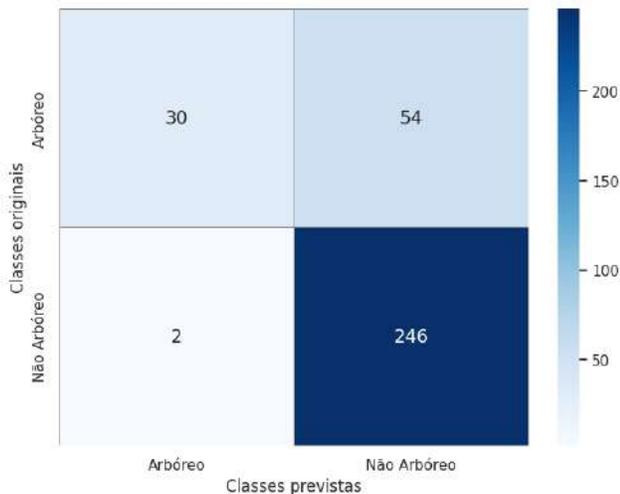


Figure 16: Matriz de confusão do estrato Arbóreo - Fonte: Os autores

bustivo e Herbáceo a rede alcançou uma acurácia de 91% quando submetido ao conjunto de imagens de testes. As Figuras 17 e 18 ilustram os gráficos referentes ao treinamento da rede. A Figura 17 apresenta uma representação visual do comportamento dessa função de perda ao longo das iterações

do treinamento. A Figura 18 permite uma análise do comportamento da acurácia durante o período de treinamento, onde é possível observar uma tendência de estabilização dos resultados a partir da época 40.

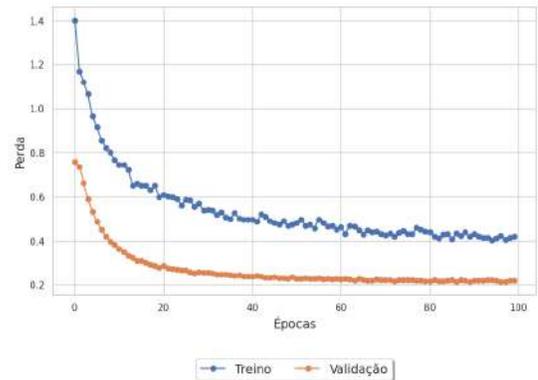


Figure 17: Gráfico de perda no treino e validação da classificação multiclases - Fonte: Os autores

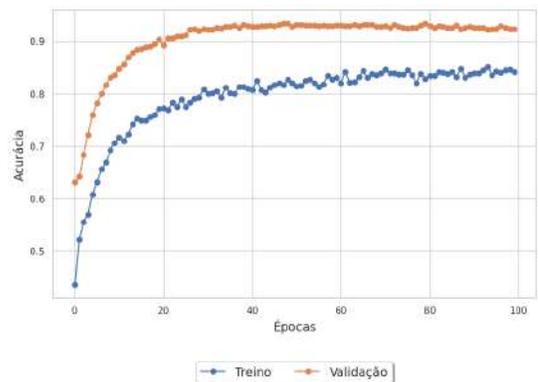


Figure 18: Gráfico de acurácia no treino e validação da classificação multiclases - Fonte: Os autores

A matriz de confusão da classificação multiclases, apresentada na Figura 19, exibe os resultados da classificação dos três estratos nas 332 amostras de teste. Este gráfico é fundamental para avaliar o desempenho do modelo de classificação, pois fornece uma visão clara sobre o número de previsões corretas e incorretas feitas pelo modelo para cada estrato.

A Tabela 4 oferece uma síntese dos resultados obtidos destacando os valores de acurácia alcançados para os diferentes estratos. Na classificação do estrato herbáceo obteve uma acurácia de 93%. No estrato arbustivo a arquitetura de rede obteve o valor de acurácia de 94%. Para o estrato arbóreo, a acurácia alcançada foi de 83%. Na classificação multiclases, a rede neural obteve uma acurácia de 91%. Estes resultados fornecem uma visão abrangente do desempenho do modelo em cada cenário experimental.

5. CONCLUSÃO

Este trabalho apresenta um estudo sobre a classificação de estratos vegetais de um bioma exclusivamente brasileiro, a Caatinga, por meio de imagens aéreas capturadas por

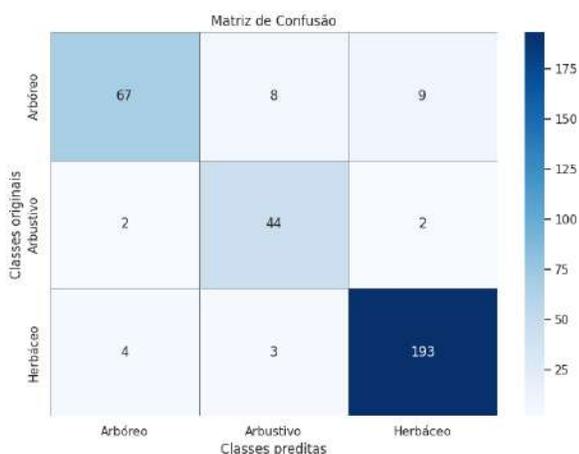


Figure 19: Matriz de confusão da classificação multiclasses - Fonte: Os autores

Table 4: Tabela de comparação das acurácias para cada estrato.

Treinamento	Tipo de classificação	Número de épocas	Acurácia
Estrato Herbáceo	Binária	100	93%
Estrato Arbustivo	Binária	100	94%
Estrato Arbóreo	Binária	100	83%
Todos os estratos	Multiclasses	100	91%

VANT. O artigo visa a montagem de um VANT de baixo custo idealizado para a captura e classificação destas imagens de uma área do bioma Caatinga na região de Picos, Piauí. Como mencionado anteriormente, o alto custo de VANTs pode inviabilizar pesquisas além da respectiva implementação e adequação na agricultura local e, de forma geral, nas regiões menos favorecidas do Brasil. Em contrapartida, este trabalho é relevante para a agropecuária na região da Caatinga por proporcionar um mapeamento da vegetação na região e facilitar na utilização de estratégias de manejo mais eficientes, contribuindo com o agropecuarista local.

O estudo demonstrou com sucesso a aplicabilidade de um VANT, que foi montado para a realização do mapeamento da área e captura das imagens já que a aeronave cumpriu toda a missão estabelecida, sem apresentar erros de comunicação ou falha na captura das imagens. A classificação das imagens registradas obtiveram valores de acurácia satisfatórios como de 93% para o estrato herbáceo, 94% para o estrato arbustivo e 83% para o estrato arbóreo. Além disso, na classificação multiclasses, a rede neural apresentou uma acurácia de 91%, evidenciando sua capacidade de lidar com múltiplas categorias simultaneamente, de modo que pode contribuir na identificando áreas de vegetação aptas para pastagem.

Como perspectivas de estudos futuros, propõe-se o aprimoramento do trabalho realizado mediante o mapeamento de novas áreas da Caatinga para a realização de novos experimentos em um conjunto de imagens ainda mais amplo

e diversificado, bem como a exploração de outras técnicas de aprendizado de máquina para aprimorar o desempenho, na identificação da vegetação e expandir as classes de estudo para a identificação das espécies da vegetação disponíveis na região.

6. REFERENCES

- [1] B. L. M. Camacam and C. M. B. de Omena Messias. Potencial alimentar de frutas e plantas da caatinga: revisão integrativa. *Research, Society and Development*, 11(9):e39911931997–e39911931997, 2022.
- [2] G. H. M. Cassemiro and H. B. Pinto. Composição e processamento de imagens aéreas de alta-resolução obtidas com drone. 2014.
- [3] J. A. de Araújo Filho. Proposta para a implementação do manejo pastoril sustentável da caatinga. 2014.
- [4] L. G. Fazan. Exploração de arquiteturas de redes neurais convolucionais para identificação de forrageiras do gênero bachiaria e panicum. 2020.
- [5] C. d. C. L. Gonçalves. *Identificação automática de plantas invasoras em imagens aéreas*. PhD thesis, 2019.
- [6] IBGE. Biomass e sistema costeiro-marinho do brasil: compatível com a escala 1:250.000. 2019.
- [7] J. C. Melo, R. G. Constantino, S. G. Santos, T. P. Nascimento, and A. V. Brito. A system embedded in small unmanned aerial vehicle for vigor analysis of vegetation. pages 310–321, 2017.
- [8] A. Mescoloti, L. L. Almeida, D. R. Pereira, M. A. Pazoti, and F. A. da Silva. Desenvolvimento de um vant autônomo utilizando hardware e materiais de baixo custo. In *Colloquium Exactarum*. ISSN: 2178-8332, volume 10, pages 41–50, 2018.
- [9] L. B. d. Oliveira, A. J. d. S. Macêdo, and E. M. Santos. Interação entre espécies forrageiras nativas e cultivadas em condições de semiárido: revisão. *Arquivo de Ciências Veterinária e Zoologia*, 22(4):127–138, 2019.
- [10] E. Oliveira Ribatski, F. S. dos Santos, and F. N. Neto. Review of uses of rpas in the agricultural scenario. *Brazilian Journal of Technology*, 1(2):313–333, 2018.
- [11] L. Renner, T. S. da Silva, C. W. M. Júnior, R. F. Wiebbelling, and G. A. Breda. Desenvolvimento e montagem de vant de asa fixa de baixo custo para suprir a demanda de ensino e pesquisa nas áreas de geociências. *Terrae Didatica*, 16:e020002–e020002, 2020.
- [12] E. Salvadori. Identificação de plantas de milho utilizando imagens aéreas obtidas por vants. B.S. thesis, Universidade Tecnológica Federal do Paraná, 2020.
- [13] G. Santos. Bioma caatinga: do estudo a desmistificação dos mitos acerca da sua biodiversidade. 2021.