

# Identificação de Cruzamentos de Eucalyptus Resistentes à Seca e Produtivos utilizando Imagens de Folhas

Marcos Veniciu de Sá Barbalho<sup>1</sup>, Adilson Rosa Lopes<sup>1</sup>, Patrick Araújo<sup>1</sup>,  
Jean Marcel Lira<sup>1</sup>, Gleison dos Santos<sup>1</sup>, José Augusto M. Nacif<sup>1</sup>

<sup>1</sup>Universidade Federal de Viçosa (UFV) – Viçosa, MG – Brasil

{marcos.barbalho, jean.lira, gleison, jnacif}@ufv.br

**Resumo.** Este trabalho utilizou uma rede neural convolucional (CNN) NasNet-Mobile para identificar cruzamentos de eucaliptos que sejam produtivos e resistentes à seca, a partir da análise das folhas. O conjunto de dados é composto por 17.790 imagens, após o aumento de dados, e foi dividido em 4 classes. O teste final foi dividido em 3 etapas. Na etapa I foi testado o número de camada densa, na etapa II a regularização dropout e L2 e na etapa III foi realizado a validação cruzada k-fold com  $k = 10$ . Para a validação cruzada o melhor modelo conseguiu uma acurácia de 82,69% no treinamento, 63,96% na validação e 56,70% com as imagens de teste.

## 1. Introdução

O Brasil é um dos maiores produtores de eucalipto do mundo, com uma área plantada de 7,53 milhões de hectares, representando 75,8% de toda área de floresta comercial plantada no país, chegando a uma produtividade média de 38,9 m<sup>3</sup>/ha/ano. As maiores plantações estão nos estados de Minas Gerais (30%), Mato Grosso do Sul (14%) e São Paulo (13%). O eucalipto tem importante papel na economia nacional, representando um saldo positivo na balança comercial de 10 bilhões de dólares no ano de 2021, além da geração de 2 milhões de empregos diretos e indiretos. A celulose foi o produto derivado do eucalipto mais exportado, representando 6,7 bilhões do montante, deixando o Brasil na primeira posição do ranking mundial dos países exportadores de celulose [de Árvores ibá 2021].

Um fator ambiental que afeta significativamente a produtividade dos plantios de eucalipto são longos e severos períodos de estiagem. Apenas no estado de Minas Gerais, no ano de 2014, aproximadamente 150.000 hectares de plantações de eucalipto foram perdidas em função da seca. Projeções climáticas preveem que eventos desta natureza serão acentuados em regiões tropicais e subtropicais [Masson-Delmotte and (eds.) 2021]. Como consequência, tem-se um aumento considerável na mortalidade das árvores [Germon et al. 2019]. A pesquisa em melhoramento genético, visando a produção de materiais genéticos com alta produtividade de madeira e tolerância à seca, é algo de suma importância para enfrentar este problema futuro, mantendo o ganho econômico das empresas do setor florestal.

Buscando o desenvolvimento de materiais tolerantes às condições de baixa disponibilidade água e que tenham alta produtividade, foi criado um projeto chamado “Tolerância à Seca em Eucalipto”, resultado de uma parceria público-privada entre a Sociedade de Investigações Florestais (SIF), a Universidade Federal de Viçosa (UFV) e 15 grandes empresas do setor florestal brasileiro. No escopo deste projeto, implantou-se

no ano de 2019 um teste de progênies em um local com histórico de seca, a cidade de Buritizeiro-MG. O teste de progênie é um método utilizado em programas de melhoramento genético para seleção de genótipos avaliando as características e desempenho dos descendentes de um progenitor em diferentes ambientes [VanRaden 2008]. Na cultura de eucalipto, em geral, o teste de progênie é realizado em um período de sete anos, que corresponde ao intervalo de rotação da cultura. Assim, os estudos para identificação dos cruzamentos que melhor atendem às características de interesse levam um tempo significativo para serem concluídos.

Visando encurtar o período do teste de progênie, resultando na maior eficiência do uso do tempo e economia de recursos na obtenção dos genótipos de interesse, o problema estudado neste artigo se refere à identificação precoce destes materiais utilizando técnicas de visão computacional. Utilizando como base de dados as imagens das folhas das árvores de eucalipto coletadas em campo pelo projeto, pretende-se avaliar a viabilidade do uso dessa técnica para a identificação precoce dos cruzamentos promissores. Para tanto, imagens das folhas de plantas em idades mais jovens foram usadas como preditoras para classificação dos genótipos quanto à tolerância e produtividade em uma idade futura, objetivando a modelagem da seleção precoce. O processo de modelagem é composto pelas etapas de pré-processamento das imagens, divisão do conjunto de dados em treinamento, validação e teste, ajuste de hiperparâmetros, treinamento, validação e teste da rede NasNetMobile [Zoph et al. 2018] e avaliação dos resultados. As imagens foram rotuladas em: (0) não resistente e não produtiva; (1) resistente e não produtiva; (2) não resistente e produtiva; (3) resistente e não produtiva, totalizando 4 classes. O modelo treinado alcançou resultados de 82.70% de acurácia no treinamento, 63.97% de acurácia na validação e 56.70% de acurácia com as imagens de teste.

O artigo está dividido em outras quatro seções, onde a Seção 2 apresenta trabalhos relacionados com aplicações de CNN em problemas de classificação a partir de imagens de folhas de plantas. A Seção 3 descreve a metodologia deste trabalho, onde serão apresentadas as etapas de desenvolvimento do estudo. Na Seção 4 são mostrados os resultados do trabalho e a discussão acerca dos mesmos. Por fim, a Seção 5 conclui o trabalho com as considerações finais e propostas de trabalhos futuros relacionados ao problema estudado.

## **2. Trabalhos Relacionados**

Técnicas de visão computacional como Redes Neurais Convolucionais (CNN), são comumente empregadas para identificar objetos e classificar imagens. No entanto, não foram encontrados estudos que tratem especificamente sobre o tema deste artigo, que é o uso de imagens de folhas de eucalipto para identificação de espécies com alta produtividade e resistência à seca. Os trabalhos encontrados estão relacionados a aplicação de CNN para estudos em plantas, em alguns casos utilizando um conjunto de dados público ou um próprio para a pesquisa. Eles estão mais relacionados ao uso de imagens de folhas e das frutas para a identificação de doenças em estágio inicial, para que permita uma melhor tomada de decisão antes que a doença se prolifere na plantação.

Em [Na Yao 2021] foi proposto o uso de uma modificação da rede Xception para a identificação precoce de 7 principais doenças que afetam as plantações de pêssegos. Nos testes foram comparados o desempenho do modelo proposto com o de outras 6 arquiteturas. Obtendo uma acurácia de 93,85% com os dados de validação com o modelo

proposto.

Em [Mohanty et al. 2016] foi realizado o treinamento de duas arquiteturas de CNN para identificação de doenças, utilizando imagens de folhas. Foi utilizado um conjunto de dados público contendo mais de 54 mil imagens de folhas saudáveis e doentes, abrangendo um total de 14 espécies e 26 doenças. Para isso eles treinaram duas arquiteturas, a Alexnet e a GoogleNet. O experimento alcançou uma acurácia de 99,35% com as imagens de teste.

### **3. Materiais e Métodos**

Nesta seção, apresentaremos a metodologia aplicada nesse trabalho. Será falado sobre o projeto de melhoramento genético que gerou as imagens para o estudo, o conjunto de dados e a forma como as imagens foram processadas e rotuladas, e sobre as etapas de treinamento do modelo.

#### **3.1. Projeto**

O projeto “Tolerância à Seca em Eucalipto” iniciado no ano de 2019 com uma duração esperada de 7 anos, tem por objetivo a identificação de espécies de eucalipto que tivessem uma alta resistência à seca e conseguissem manter uma alta produtividade. Para isso foi realizado o cruzamento de algumas espécies de eucalipto. Foram geradas 220 progênies, que se referem ao conjunto de descendentes desses cruzamentos. Cada progênie possui 20 indivíduos, totalizando 4400 indivíduos. As coletas de dados desses indivíduos foram realizadas aos 6, 18, 30, 36 e 42 meses, onde selecionou-se aleatoriamente 6 indivíduos. As coletas não eram realizadas com os mesmos indivíduos, pois alguns desses indivíduos poderiam ter morrido no intervalo entre as coletas. Os dados coletados dessas amostras, que foram mais relevantes para este trabalho foram, o Incremento Médio Anual Volumétrico - IMAVol ( $m^3/ha/ano$ ) e a taxa de sobrevivência e foram utilizados para rotular as imagens, com base no desempenho das progênies. A plantação foi realizada em um sítio localizado no município de Buritizeiro, no estado de Minas Gerais ( $17^{\circ} 05' 49''S$   $44^{\circ} 53' 09''O$ ). Entre os anos de 2018 a 2021, a temperatura média foi de  $25^{\circ}C$ , a temperatura mínima de  $5,4^{\circ}C$  e a máxima de  $41^{\circ}C$ . A precipitação anual nesse período foi: 2018 (971,5 mm), 2019 (509 mm), 2020 (1.090mm) e 2021 (1.041,5mm)[Minasligas 2021]. Para comparação foram plantadas 6 espécies, que já são conhecidas por seu desempenho, que foram chamadas de testemunhas. No total foram coletadas informações de 83 progênies diferentes, bem como das 6 testemunhas.


#### **3.2. Conjunto de dados**

As imagens coletadas foram digitalizadas e processadas para que ficassem o mais semelhantes possível, o conjunto de imagens usado contém as imagens que foram coletadas aos 6, 18, 30 e 36 meses e foram rotuladas de acordo com os critérios de tolerância à seca e produtividade avaliados com base nos dados de inventário das progênies coletadas aos 42 meses.

##### **3.2.1. Processamento**

Inicialmente havia várias folhas em uma mesma imagem, para fazer a identificação e segmentação das imagens das imagens foi utilizada a rede neural Yolo

[Redmon et al. 2016], o que gerava imagens com alguma inclinação e pedaços de outras folhas como mostrados na figura 1.



**Figura 1.** A imagem mais à esquerda, é a imagem inicial resultante da digitalização das folhas, a imagem do meio as folhas foram detectadas pelo Yolo e a imagem à direita é a imagem final com a segmentação das folhas também feita pelo Yolo.

Para melhorar o tratamento das imagens foi realizado um segundo processamento nelas a fim de deixar uma folha por imagem, sem a presença de pedaços de folha após a segmentação, com um fundo preto na resolução 536 x 536 pixels. Inicialmente as imagens possuíam partes de outras folhas junto com a folha principal, é então gerada uma máscara para essa imagem para diferenciar as folhas do fundo da imagem, como na figura 2.



**Figura 2.** Imagem após a segmentação com o Yolo a esquerda e máscara para a imagem a direita.

Após gerar a máscara, é realizada a separação das folhas. Para separar as folhas é gerada uma matriz na mesma resolução da máscara. Então cada ponto da máscara é verificado até que seja encontrado um pixel branco, o que significa que uma possível folha foi encontrada. Então todos os pontos brancos próximos ao pixel encontrado são mapeados para a matriz. Quando o mapeamento termina, os pixels da imagem original que estão marcados na matriz são colados em uma imagem com fundo preto, salvando assim apenas o objeto identificado na imagem. Quando terminar de mapear um objeto, a verificação dos pixel continua do ponto em que o primeiro foi encontrado até que outro

pixel branco que ainda não tenha sido mapeado na matriz seja encontrado, esse processo se repete até que todos os pontos brancos da imagem tenham sido verificados. No final tem uma imagem de fundo preto para cada folha encontrada, como pode ser visto na figura 3.



**Figura 3.** Imagens de cada folha encontrada na imagem inicial.

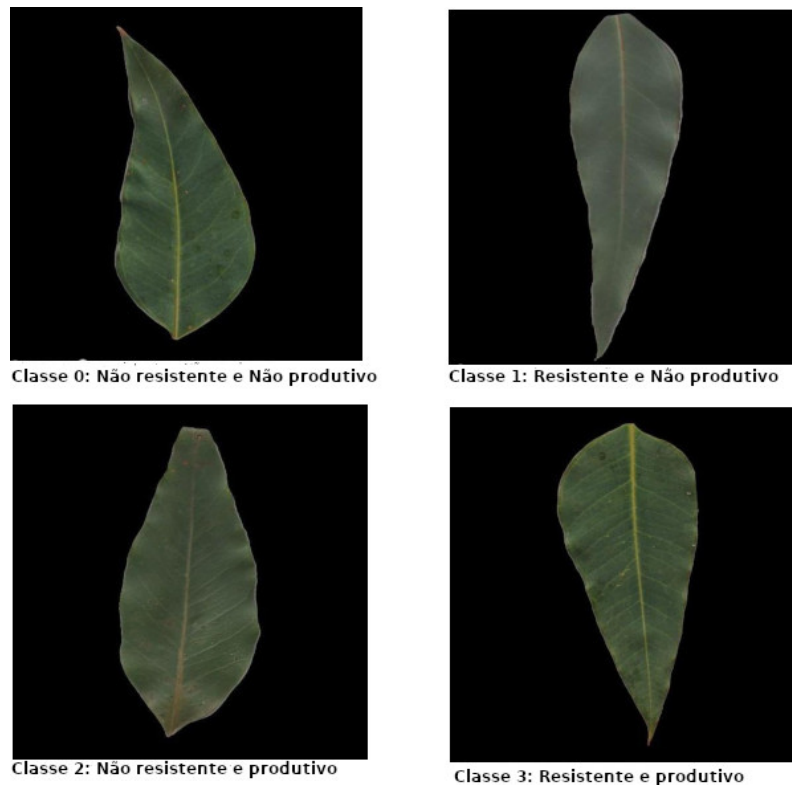
Após separar as imagens, é selecionado o objeto com o maior número de pixels, que seria a maior folha encontrada, e ela é então verticalizada. Para isso a largura da imagem é minimizada, rotacionando a imagem em 1 grau e o excesso de fundo é removido. Esse processo se repete até que a largura mínima seja atingida. Após a largura ser minimizada a imagem é redimensionada para uma altura de 536 pixels, ela é então colada no centro de uma imagem de fundo preto com resolução 536 x 536, como pode ser visto na figura 4.



**Figura 4.** À esquerda, a maior folha encontrada, no centro a folha verticalizada e à direita, a folha centralizada com resolução de 536 x 536.

O conjunto de imagens foi dividido em 4 classes: (0) não resistente e não produtiva; (1) resistente e não produtiva; (2) não resistente e produtiva; (3) resistente e não produtiva. Cada classe possui respectivamente 1760, 1570, 1470 e 4260 imagens, mais 200, 205, 200, 201 imagens para testes. Para uma progênie ser considerada tolerante ela deve ter menos de 50% dos indivíduos mortos aos 42 meses, caso contrário ela é considerada não tolerante. Em relação à produtividade, ela é considerada produtiva se a média do IMAVol das árvores vivas aos 42 meses for maior ou igual a média do IMAVol de todos os indivíduos vivos do experimento (média geral do IMAVol).

Para reduzir o overfitting e melhorar a precisão do modelo foi utilizado o aumento da quantidade de imagens, utilizado a técnica de aumento de dados (Data Augmentation) [Perez and Wang 2017]. Como é difícil distinguir as classes apenas observando as imagens, como mostrado na figura 5, e como também foram posicionadas na vertical, isso acabou limitando os tipos e a quantidade de transformações que poderíamos utilizar, pois não queríamos que as imagens fossem muito afetadas por transformações como alteração



**Figura 5.** Exemplo de imagem do conjunto de dados para cada classe.

de saturação, brilho e recorte. Usamos apenas duas transformações, espelhando a imagem para cima ou para baixo e espelhando a imagem para direita ou esquerda. De modo que para cada imagem foram geradas mais duas imagens. Com isso pudemos deixar as classes 0, 1 e 2 que possuíam menos imagens, com uma quantidade similar ao da classe 4 que possuía 4.260 imagens, ficando no final 17.790 imagens. As transformações foram aplicadas nas imagens após elas serem divididas nas 10 pastas de que serão usadas para treinamento e validação, de modo que a imagem original e as suas variações ficaram no mesmo grupo, já nas imagens de teste não foi aplicado o aumento de dados. Para melhor avaliar os modelos, foi utilizado validação cruzada k-fold com  $k=10$ , de modo que cada pasta continha 10% do conjunto total de treinamento, sendo 90% para treinamento e 10% para validação, sem contar as imagens de teste.

### 3.3. Treinamento

#### 3.3.1. Configuração

Para treinamento da rede foi utilizada uma máquina que possui um processador AMD Ryzen 9 5900X 12-Core Processor, uma GPU NVIDIA TITAN V de 12GB. O treinamento foi realizado utilizando a rede NasNetMobile.

#### 3.3.2. NasNetMobile

Para o treinamento dos modelos foi utilizada a rede CNN NasNetMobile, ela foi escolhida com base no custo de treinamento, que foi limitado pela quantidade de memória

disponível na GPU e pelo tempo necessário para realizar o treinamento dos modelos. Para o treinamento não foi utilizado um modelo pré-treinado, os modelos foram treinados com pesos inicializados aleatoriamente, com a função padrão da biblioteca Keras da linguagem Python.

### 3.3.3. Etapas de treinamento

O treinamento final foi dividido em 3 etapas. Em todos eles a taxa de aprendizado foi mantida como  $1,6970e-04$ , com o batch size de 32, a resolução de  $480 \times 480$ , por 40 épocas. Para ajudar na redução do overfitting foi utilizado juntamente com o DataAugmentation e a redução da taxa de aprendizado [You et al. 2019], reduzindo a taxa de aprendizado em 90% a cada 3 épocas sem redução da taxa de perda.

Na etapa I foi testado o número de camadas densas na parte de classificação. Foram testadas com 1, 2, 3 e 5 camadas sem contar a camada de saída para as 4 classes. Todos os modelos possuíam Dropout de 50% apenas na entrada da camada visível.

Na etapa II, foram realizados testes de regularização, com o objetivo de reduzir a taxa de perda e o overfitting. Nessa etapa foram treinados 9 modelos, sendo 6 com variações na regularização usada e 3 variando a taxa de Dropout. Em todos eles, havia 3 camadas densas para testar o comportamento das técnicas de regularização. Para esses testes foram usadas as técnicas de regularização Dropout e L2 e a combinação das duas técnicas [Srivastava et al. 2014]. Foram testados:

- Modelo 1: Dropout apenas nas camadas ocultas;
- Modelo 2: Dropout apenas na entrada da camada visível;
- Modelo 3: Apenas regularização L2 em todas as camadas;
- Modelo 4: Dropout na entrada da camada visível e L2 nas camadas ocultas;
- Modelo 5: Dropout apenas na entrada da camada oculta e L2 em todas as camadas;
- Modelo 6: Dropout e L2 em todas as camadas.

Em todos os que possuíam Dropout, a taxa foi de 50%. Os três últimos testes foram realizados variando a taxa de Dropout em 30%, 50% e 70% apenas nas camadas ocultas. Na etapa III, foi realizado o teste de validação cruzada, no qual o conjunto de imagens foi dividido em 10 pastas, cada uma contendo 10% das imagens e uma pasta de teste com as imagens que serão usadas para testar os modelos em cada treinamento.

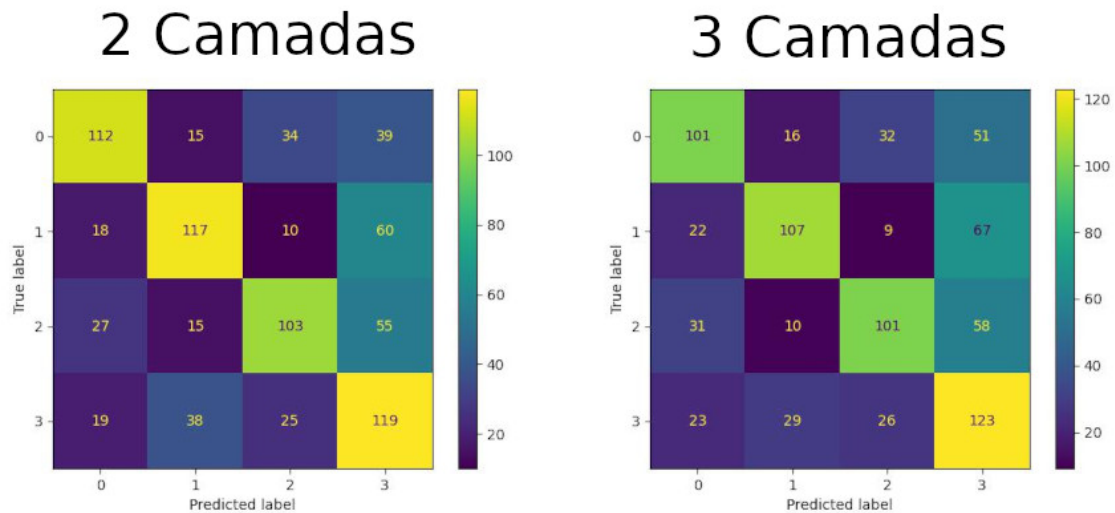
## 4. Resultados e Discussão

Na etapa I o melhor resultado foi com o modelo de 2 camadas, que obteve uma acurácia de 55,95% com as imagens de teste, o pior resultado com a de 3 camadas, que obteve um resultado de 53,59% com as imagens de teste. Os resultados completos podem ser vistos na figura 6. Para cada teste também foi gerado um gráfico com a matriz de confusão, conforme a figura 7.

Já para os testes da etapa II, o modelo 1 com dropout apenas nas camadas ocultas e o modelo 3 com regularização L2 em todas as camadas, obtiveram o mesmo resultado na acurácia de teste, 57,19%, como pode ser visto na figura 8 o resultado do treinamento de cada modelo e na figura 9 a matriz de confusão desses modelos. Para o teste de dropout, as taxas de 30% e 50% obtiveram resultados próximos, como pode ser visto na figura 10.

	Acurácia Treino	Acurácia Validação	Acurácia Teste	Loss Treinamento	Loss Validação
1 camada	75,59	63,23	54,96	0,6212	0,9306
2 camadas	74,73	61,94	55,95	0,6381	0,9122
3 camadas	73,41	62,50	53,59	0,6553	0,9114
5 camadas	74,19	63,18	54,59	0,6368	0,9133

**Figura 6.** Resultado dos testes da Etapa I.



**Figura 7.** Resultado dos testes da Etapa I.

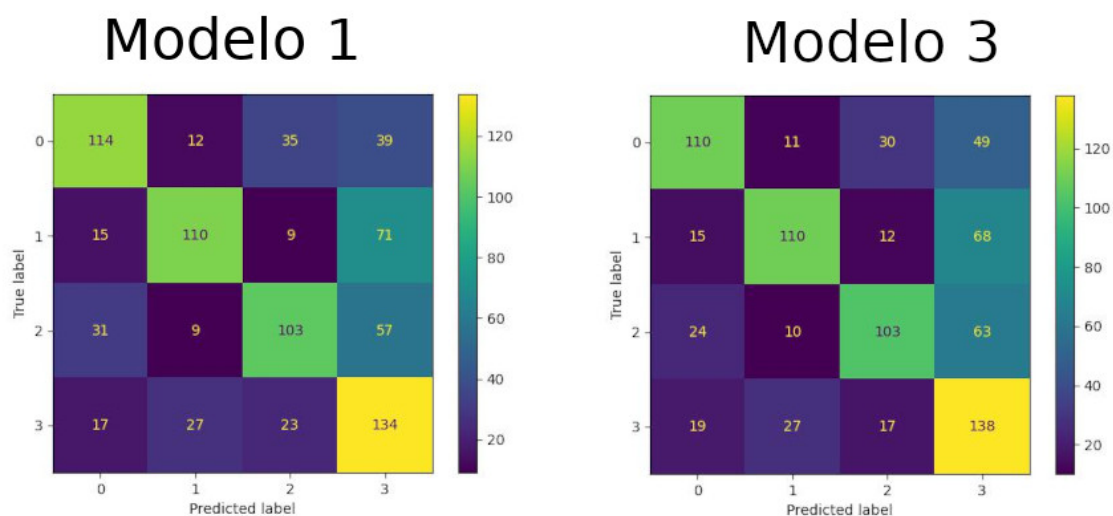
	Acurácia Treino	Acurácia Validação	Acurácia Teste	Loss Treinamento	Loss Validação
Modelo 1	70,84	62,28	57,19	0,7280	0,9248
Modelo 2	73,41	62,50	53,69	0,6553	0,9114
Modelo 3	77,82	64,58	57,19	0,6381	0,9551
Modelo 4	78,21	64,41	54,21	0,5857	0,9313
Modelo 5	87,80	62,90	55,08	0,4244	1,0314
Modelo 6	77,37	62,26	53,47	0,7121	1,0498

**Figura 8.** Resultados dos testes dos modelos, na Etapa II.

Para a etapa III, onde foi realizado a validação cruzada k-fold com k=10. O melhor resultado obtido foi com o modelo 2, que obteve uma acurácia de 56,70% enquanto os 10 modelos obtiveram uma acurácia média de 53,73% ambos com as imagens de teste. Para as imagens de validação ele obteve 63,96% de acurácia e uma acurácia média de 61,09% para as imagens de teste, como pode ser visto na figura 11. Foi gerado também o gráfico da curva de aprendizado, figura 12, a matriz de confusão, figura 13 e a curva Roc do modelo, figura 14. A curva Roc (Característica de Operação do Receptor) gerada apresenta a comparação entre as classes.

Como pode ser observado em todas as matrizes de confusão, a classe 3 foi a que obteve o melhor resultado em relação às outras classes. Isso se deve principalmente ao fato de que a classe 3 possui 4.260 imagens, enquanto que as outras tem entre 1.570 e 1.760 imagens e mesmo utilizando o aumento de dados para balancear as classes, a classe 3 continuou tendo um melhor resultado, de modo que um conjunto de dados que seja





**Figura 9.** Matriz de confusão dos modelos 1 e 3 treinados na Etapa II.


	Acurácia Treino	Acurácia Validação	Acurácia Teste	Loss Treinamento	Loss Validação
Dropout 30%	73,61	61,72	56,07	0,6484	0,9018
Dropout 50%	77,45	62,78	55,33	0,5921	0,8970
Dropout 70%	66,51	59,13	51,86	0,8189	0,9663

**Figura 10.** Resultados do teste de Dropout.


naturalmente mais balanceado poderia ter um resultado melhor.

	Acurácia Treino	Acurácia Validação	Acurácia Teste	Loss Treinamento	Loss Validação
Modelo 0	68,44	60,09	50,24	0,77062	0,92817
Modelo 1	73,01	59,86	52,73	0,67707	0,95773
Modelo 2	82,69	63,96	<b>56,70</b>	0,45659	0,91023
Modelo 3	79,95	60,14	55,45	0,52449	0,02303
Modelo 4	73,71	61,66	53,10	0,66369	0,9409
Modelo 5	72,26	59,94	54,09	0,68976	0,94639
Modelo 6	71,93	63,18	51,73	0,69495	0,91149
Modelo 7	72,25	61,43	53,22	0,69006	0,91510
Modelo 8	68,62	60,02	52,23	0,76653	0,94782
Modelo 9	73,98	61,66	47,89	0,63993	0,96002


**Figura 11.** Resultado da validação cruzada k-fold com k=10.



**Figura 12.** Curva de aprendizado do modelo 2.



**Figura 13.** Matriz de confusão do modelo 2.



**Figura 14.** Curva ROC do modelo 2.

## 5. Considerações Finais

Os resultados foram obtidos a partir de imagens de 6, 18, 30 e 36 meses rotulados com base nos dados de 42 meses, podendo ser testados ainda outras combinações para se ter uma visão mais abrangente da viabilidade do uso das folhas de eucalipto, para identificar cruzamentos que seja produtivos e resistentes a seca. Outro ponto a ser observado é que por questões de tempo e limitação na memória da GPU foi utilizado apenas uma arquitetura de CNN, realizar novos testes comparando outras arquiteturas poderia dar uma visão mais adequada sobre a capacidade das CNNs em extrair as características das folhas, uma vez por não haver uma diferença visual muito clara entre as classes, redes maiores poderia ter resultados diferentes. Por questão de tempo de treinamento, não foi possível treinar os modelos mais vezes para se ter uma acurácia mais confiável.

## Agradecimentos

Gostaríamos de agradecer CAPES, CNPq (Processo #401839/2021-4), Fapemig (Projeto #APQ-02062-21) e SIF (Sociedade de Investigações Florestais) pelo financiamento a este trabalho.

## Referências

- de Árvores ibá, I. B. (2021). Relatório anual ibÁ 2021. Technical report, indústria brasileira de árvores.
- Germon, A., Jourdan, C., Bordron, B., Robin, A., Nouvellon, Y., Chapuis-Lardy, L., de Moraes Gonçalves, J. L., Pradier, C., Guerrini, I. A., and Laclau, J.-P. (2019). Consequences of clear-cutting and drought on fine root dynamics down to 17m in coppice-managed eucalypt plantations. *Forest Ecology and Management*, 445:48–59.
- Masson-Delmotte, V., P. Z. A. P. S. C.-C. P. S. B. N. C. Y. C. L. G. M. G. M. H. K. L. E. L. J. M. T. M. T. W. O. Y. R. Y. and (eds.), B. Z. (2021). *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*.
- Minasligas, E. (2021). Dados meteorológicos coletados em estação meteorológica. Dados brutos. Estação Meteorológica da Empresa Minasligas, Buritizeiro-MG, Brasil.
- Mohanty, S. P., Hughes, D. P., and Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7.
- Na Yao, Fuchuan Ni, Z. W. J. L. W.-K. S. C. L. . G. L. (2021). L2mxception: an improved xception network for classification of peach diseases. *Plant Methods*.
- Perez, L. and Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(56):1929–1958.
- VanRaden, P. M. (2008). Efficient methods to compute genomic predictions. *Journal of Dairy Science*.
- You, K., Long, M., Wang, J., and Jordan, M. I. (2019). How does learning rate decay help modern neural networks?
- Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2018). Learning transferable architectures for scalable image recognition.