



**LUIS CARLOS DA SILVA SOARES**

**REDES NEURAIIS CONVOLUCIONAIS APLICADAS NA  
IDENTIFICAÇÃO DE RACHADURAS EM IMAGENS DE  
TORAS DE EUCALIPTO EM CAMPO**

**LAVRAS - MG  
2023**

**LUIS CARLOS DA SILVA SOARES**

**REDES NEURAIAS CONVOLUCIONAIS APLICADAS NA IDENTIFICAÇÃO DE  
RACHADURAS EM IMAGENS DE TORAS DE EUCALIPTO EM CAMPO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento de Plantas, área de concentração em Genética e Melhoramento de Plantas, para a obtenção do título de Mestre.

Profª. Dra. Flávia Maria Avelar Gonçalves  
Orientadora

Dra. Izabel Cristina Rodrigues de Figueiredo  
Coorientadora

**LAVRAS - MG  
2023**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Soares, Luis Carlos da Silva.

Redes neurais convolucionais aplicadas na identificação de rachaduras em imagens de toras de eucalipto em campo / Luis Carlos da Silva Soares. - 2023.

50 p. : il.

Orientador(a): Flavia Maria Avelar Goncalves.

Coorientador(a): Izabel Cristina Rodrigues de Figueiredo.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2023.

Bibliografia.

1. Melhoramento genético. 2. Análise de imagens. 3. Otimização florestal. I. Goncalves, Flavia Maria Avelar. II. Figueiredo, Izabel Cristina Rodrigues de. III. Título.

**LUIS CARLOS DA SILVA SOARES**

**REDES NEURAIAS CONVOLUCIONAIS APLICADAS NA IDENTIFICAÇÃO DE  
RACHADURAS EM IMAGENS DE TORAS DE EUCALIPTO EM CAMPO**

**CONVOLUTIONAL NEURAL NETWORKS APPLIED TO IDENTIFY CRACKS IN  
IMAGES OF EUCALYPTUS LOGS IN THE FIELD**

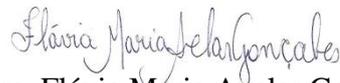
Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento de Plantas, área de concentração em Genética e Melhoramento de Plantas, para a obtenção do título de Mestre.

APROVADO em 18 de janeiro de 2023.

Dra. Izabel Cristina Rodrigues de Figueiredo – PLANTAR S/A

Dr. Vinícius Quintão Cordeiro – UFLA

Dr. Bruno Oliveira Lafetá – IFMG



Profa. Dra. Flávia Maria Avelar Gonçalves  
Orientadora

Dra. Izabel Cristina Rodrigues de Figueiredo  
Coorientadora

**LAVRAS-MG  
2023**

## AGRADECIMENTOS

À Universidade Federal de Lavras, especialmente ao Departamento de Genética e Melhoramento de Plantas, pela oportunidade.

À minha mãe por não medir esforços e estar ao meu lado para que pudesse realizar esse sonho.

À professora Dr<sup>a</sup> Flávia Avelar pelos anos de trabalho, orientação e aconselhamento durante os momentos de dificuldade, seja referente ao curso ou à vida.

À Dr<sup>a</sup> Izabel Figueiredo por ter me recebido na PLANTAR e sempre estar de prontidão para ceder dados para estudos.

Aos membros das da banca, Dr. Bruno Lafetá e Dr. Vinícius Cordeiro pelas contribuições para este trabalho.

Ao Gustavo Pucci pelas ideias e suporte no desenvolvimento dos códigos implementados neste trabalho.

Ao meu amigo e colega José Maurílio pelo apoio mútuo durante todo o decorrer do mestrado.

Aos meus amigos Ana Herculano, Júlia Gomes, Luiz Collins, Samily Rocha, Michele Medina, Sarah Dieckman e Larissa Nara pelo apoio, acolhimento e por me motivarem a não desistir.

Ao amigo Ricardo Lopes que me ajudou obter as imagens usadas nesse trabalho.

Aos órgãos de fomento à pesquisa, em especial à Fundação de Amparo à pesquisa do Estado de Minas Gerais (FAPEMIG), pela concessão da bolsa.

E a todos que de alguma maneira contribuíram para que eu pudesse concretizar esse momento

*“Você segue a evolução da tecnologia ou do universo?” (Martinho Sebastião)*

## RESUMO

A madeira é um produto amplamente utilizado pelo homem. Parte de seu estoque advém de povoamentos florestais artificiais que fomentam setores como o da construção civil e movelaria. Embora parte dos povoamentos apresentem bons desempenhos quanto à produção, o setor ainda lida com perdas de material devido à projeção de rachaduras na madeira. Os esforços para minimizar tal problema concentram-se na obtenção de árvores com constituição genética com menor propensão para rachaduras. Avanços no âmbito de melhoramento genético para tal caráter são relatados para os métodos de avaliação. Abordagens tradicionais de visão computacional se apresentam como uma alternativa para a avaliação de rachaduras. Entretanto, a sua incapacidade de implementação em campo configura-se como o principal gargalo da técnica. Abordagens de fenotipagem em campo usando visão computacional, pautadas em aprendizado profundo, demonstram ser promissoras para tarefas de avaliação em campo. Assim, objetivou-se com esse trabalho avaliar a capacidade das redes neurais convolucionais na identificação de rachaduras em toras a partir de imagens coletadas a campo. Foram usadas imagens em ambiente de campo e em ambiente controlado. O primeiro grupo de imagens passou por processos de anotação das classes (*background*, tora e rachadura) para a geração de máscaras, enquanto o segundo grupo utilizou-se as máscaras anteriormente feitas por outros trabalhos. A partir das imagens de ambiente controlado foram geradas imagens sintéticas simulando o ambiente de campo, a partir da segmentação e mesclagem da tora em fotos de campo. Além disso, para a generalização do modelo, foram realizadas mesclagem de diversas texturas de madeiras. O conjunto de imagens obtidas, sintéticas e de campo, passaram por processos de ampliação do banco de dados para que as arquiteturas tenham imagens o suficiente para um bom treinamento. Ao final, foram obtidas 2.554 imagens as quais foram divididas em conjunto de dados exclusivos de treino e de validação, na proporção de 80% e 20%, respectivamente. Foram avaliadas três arquiteturas de redes neurais convolucionais, sendo elas a U-Net, FPN e Linkinet. Os modelos gerados a partir das arquiteturas foram avaliados e a seleção do melhor se deu em função das melhores médias para a inserção sobre união (IoU). As estimativas das classes do modelo selecionado foram comparadas visualmente com as máscaras esperadas a partir de um conjunto de 20 imagens. Por fim, foram calculadas a área real e estimada da rachadura as quais foram comparadas via teste qui quadrado, coeficiente de determinação ( $R^2$ ), Raiz do erro quadrático médio (RMSE) e o Erro absoluto médio percentual (MAPE). Com esse trabalho, observa-se que o modelo U-Net se configura como a melhor opção dentre as arquiteturas aqui avaliadas para a fenotipagem de rachaduras de toras em campo. A equidade estatística das estimativas da área das rachaduras em relação à área real aliados com a rapidez em se obter os resultados estimulam o seu emprego em tarefas de avaliação de rachaduras em programas de melhoramento florestal, ainda que o modelo apresente dificuldade ao lidar com pequenas rachaduras. Estudos futuros podem focar em estratégias que visem a melhoria de detecção das pequenas rachaduras.

**Palavras- Chave:** Análise de imagens. Melhoramento genético. Segmentação Semântica. Otimização florestal. *Backbone*.

## ABSTRACT

Wood is a product widely used by human. Most of its stock comes from artificial forest stands promoting various industries such as civil construction and furniture. Although part of the stands presents good performances in terms of production, the sector still deals with material losses due to the projection of cracks in the wood. Efforts to minimize this problem mainly focus on obtaining trees with a genetic constitution that is less prone to cracking. Advances in genetic improvement for this character are reported, above all, for the evaluation methods. Traditional computer vision approaches are an excellent alternative for evaluating cracks. However, its inability to implement it in the field is the main bottleneck of the technique. Based on deep learning, field phenotyping approaches using computer vision show promise for field evaluation tasks. Thus, this work aimed to evaluate the ability of convolutional neural networks to identify cracks in logs from images collected in the field. For this purpose, images were used in the field and a controlled environment. The first group of images underwent class annotation processes (background, log, and crack) to generate masks. In contrast, masks previously made by other works were used for the second group. Synthetic images were generated from the controlled environment images, simulating the field environment from the segmentation and merging of the log-in field photos. In addition, several wood textures were combined to generalize the model. The set of images obtained, both synthetic and field, underwent database expansion processes so that the architectures have enough images for good training. In the end, 2,554 images were obtained, which were divided into sets of exclusive training and validation data in the proportion of 80% and 20% respectively. Three architectures of convolutional neural networks were evaluated, namely U-Net, FPN, and Linkinet. The models generated from the architectures were evaluated, and the best one was selected based on the best averages for insertion over union (IoU). The class estimates of the model chosen were visually compared with the expected masks from a set of 20 images. Finally, the actual and estimated area of the crack was calculated and compared using the chi-square test, coefficient of determination ( $R^2$ ), root mean squared error (RMSE), and the mean percentage absolute error (MAPE). With this work, it is observed that the U-Net model is configured as the best option among the architectures evaluated here for the phenotyping of cracks in logs in the field. The statistical equity of the estimates of the crack area concerning the real area and the speed in obtaining the results encourage its use in crack evaluation tasks in forest improvement programs, even though the model presents difficulties in dealing with small cracks. Future studies may focus on strategies to improve the detection of small cracks.

**Keywords:** Image analysis. Genetical enhancement. Semantic Segmentation. Forest optimization. Backbone.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>9</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO.....</b>	<b>11</b>
<b>2.1</b>	<b>Rachadura em madeira: causas e controle .....</b>	<b>11</b>
<b>2.2</b>	<b>Visão Computacional .....</b>	<b>20</b>
<b>2.2.1</b>	<b>Aplicações de visão computacional em detecção de defeitos em madeira.....</b>	<b>26</b>
<b>3</b>	<b>MATERIAL E MÉTODOS.....</b>	<b>30</b>
<b>3.1</b>	<b>Treinamento, validação e avaliação dos modelos.....</b>	<b>32</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÃO .....</b>	<b>35</b>
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>44</b>
	<b>REFERÊNCIAS .....</b>	<b>45</b>

## 1 INTRODUÇÃO

A madeira é um produto amplamente utilizado pelo ser humano. Ela é a base para o desenvolvimento de muitos produtos e utensílios, além de subsidiar a construção civil e naval e ser uma fonte de energia renovável. Por muito tempo, a sua extração para o uso humano foi obtida de florestas naturais. Entretanto, o fortalecimento das políticas ambientais e o incentivo a florestas plantadas desencorajaram a sua exploração em ecossistemas naturais. A adoção de povoamentos artificiais em congruência às práticas de melhoramento e de manejo de florestas possibilitaram a obtenção de povoamentos com alta produtividade e com valor agregado para os devidos objetivos dentro da cadeia produtiva (CASTRO et al., 2016).

Um dos objetivos dos povoamentos florestais é o abastecimento do mercado de madeira para a construção e movelaria. Em geral, tais povoamentos são orientados via melhoramento genético e manejo florestal com o enfoque em características específicas que atendam o seu consumidor final. Embora parte dos povoamentos apresentem bons desempenhos quanto à produção, resistência mecânica e durabilidade, o setor de madeira maciça ou laminados ainda lida com perdas significativas de material devido à projeção de rachaduras na madeira (YANG, 2005; JULLIEN et al., 2013; NISTAL FRANÇA; FILGUEIRA AMORIM FRANÇA; VIDAURRE, 2020).

Organizações florestais vêm investindo em soluções que atenuem a ocorrência e os impactos das rachaduras dentro de seus povoamentos florestais. Os esforços têm-se concentrado sobre delineamento de estratégias silviculturais eficientes e na obtenção de árvores com constituição genética para uma menor propensão para rachaduras (RICHTER, 2015). Avanços significantes, no que se diz respeito às rachaduras em madeira, tem sido feito no âmbito de melhoramento genético. Parte de tais avanços é pautado no estudo dos parâmetros genéticos, principalmente acerca da magnitude da herdabilidade que ainda é incongruente entre os pesquisadores (ASSIS, 1999; GARCIA, 2000; ZELTIŇŠ et al., 2018; ČAKŠŠ et al., 2022). Todavia, ainda que haja controvérsia acerca deste ponto, pesquisas sugerem que tal caráter é passível de seleção e acumulação progressiva de alelos favoráveis. Além disso, um outro campo de interesse dos pesquisadores ao se trabalhar com melhoramento genético de rachadura é o dos métodos de avaliação empregados. Tais métodos são um ponto chave para a seleção de árvores com melhores constituições genéticas para o controle de rachaduras uma vez que subsidiam as informações a serem usadas nos modelos genéticos (MOREIRA, 2020).

Os métodos de avaliação empregados para as rachaduras em madeiras, em sua maioria, são pautados sobre medições manuais das dimensões das rachaduras ou pelo emprego de escalas visuais de notas (ŠĚNHOFÁ et al., 2016; ZELTIŇŠ et al., 2018; NASCIMENTO et al., 2019; ČAKŠŠ et al., 2022). Recentemente, com o advento das redes neurais artificiais, abordagens de visão computacional tem-se configurado como uma alternativa para as avaliações, com acurácia similar ao demais métodos e redução de tempo em relação aos métodos manuais (MOREIRA, 2020).

Um dos grandes gargalos de abordagens de visão computacional na avaliação e detecção de rachaduras é a dificuldade de implantação em ambiente de campo. Em suma, a sua implementação tem sido relatada sob ambientes controlado, com fundo único e luminosidade controlada (HE et al., 2019; HE et al., 2020; MOREIRA, 2020; YANG et al., 2020; WANG et al., 2021). Todavia, ainda que o resultado seja efetivo, o tempo despendido em tarefas para a coleta de material, limpeza e transporte até o local das fotos é alto, traduzindo-se em um maior gasto de tempo e de recursos com a possibilidade de otimização. Aplicações específicas de visão computacional direcionadas para a avaliação de imagens em ambiente de campo podem facilmente contornar tais problemas (ESGARIO et al., 2021; TASSIS; TOZZI DE SOUZA; KROHLING, 2021).

Abordagens de fenotipagem em campo usando visão computacional fundamentadas em aprendizado profundo vêm sendo desenvolvidas em outras áreas do melhoramento como em resistência à fitopatógenos em café, feijão, arroz, milho e pepino (NANEHKARAN et al., 2020; ABED et al., 2021; ESGARIO et al., 2021; TASSIS; TOZZI DE SOUZA; KROHLING, 2021). Fatos assim elucidam a possibilidade de avaliação de rachaduras em campo e a evolução dos métodos de avaliação para rachadura em madeira, sobretudo, nas abordagens de visão computacional. Assim, a partir dessas considerações, esse trabalho objetivou-se em avaliar a capacidade das redes neurais convolucionais na identificação de rachaduras em toras a partir de imagens coletadas a campo.

## 2 REFERENCIAL TEÓRICO

### 2.1 Rachadura em madeira: Padrões, causas e controle

A madeira é um recurso natural amplamente apreciado pelo homem devido às suas propriedades químicas e físicas úteis para uma ampla gama de aplicações industriais e civis. O seu emprego na construção civil decorre de um conjunto de características vantajosas que a madeira propicia que vão desde aos aspectos ornamentais, estruturais e de conforto climático (WIMMERS, 2017). O seu uso para esses fins é tão importante que países desenvolvem e atualizam diretrizes técnicas que norteiam o mínimo de qualidade aceitável para os devidos fins de sua empregabilidade. Atualmente, existem quatro principais organizações que atuam nesse campo sendo elas a (i) *International Organization for Standardization (ISO)*<sup>1</sup>, (ii) *European Committee for Standardization (CEN)*<sup>2</sup>e (iii) *American National Standards Institute (ANSI)*<sup>3</sup>.

Em geral, a madeira pode apresentar defeitos que comprometem a sua utilização. Um desses defeitos que comumente é relatado são as rachaduras. Elas configuram-se como um dos maiores problemas para o setor de madeira roliça e serrarias gerando perdas significativas de material durante o seu processamento nas indústrias. Suas ocorrências não são um problema recente e por muito tempo pesquisadores buscaram as suas causas e medidas para minimizar os danos (RICHTER, 2015).

Comumente, as rachaduras em toras são atribuídas às tensões de crescimento. Entretanto, vertentes atuais do saber científico relacionam vêm relacionando as rachaduras à causas dependentes das propriedades físico-anatômicas do lenho ou à respostas à eventos bióticos e abiótico. Proposições atuais sugerem que a causa das rachaduras originam padrões característicos de rachaduras nas toras, denotando uma correlação direta de causa e efeito (RICHTER, 2015)

As rachaduras nas toras assumem diferentes formas que podem acometer diferentes regiões da secção da tora, sendo as mais comuns os padrões em forma “I”, “T”, “Y” cruz ou estrela conforme a Figura 1 (RICHTER, 2015). O padrão de distribuição dessas rachaduras, a região de acometimento e sua severidade, hoje, permitem classificar e relacionar as

---

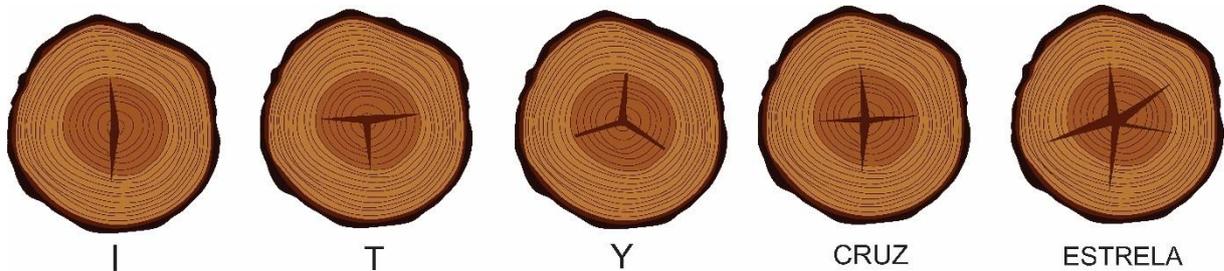
<sup>1</sup> Organização Internacional de normalização.

<sup>2</sup> Comitê Europeu de Normalização

<sup>3</sup> Instituto americano nacional de padronização

rachaduras quanto as suas causas. Tal fato configura-se como uma informação valiosa na busca de métodos para mitigar os danos em plantações futuras.

Figura 1 – Formas de rachaduras que podem ser encontradas em toras.



Fonte: Do Autor (2023).

As rachaduras que ocorrem em toras de madeiras podem ser classificadas quanto a sua forma (padrão de distribuição) e quanto as causas que as originam. Um padrão de rachadura classificada quanto à forma pode ser formado por diferentes causas, conforme demonstrado no Figura 2. Além disso, uma mesma causa pode incorrer em diferentes classes de rachaduras organizadas quanto a sua forma.

De maneira geral, as rachaduras decorrentes das tensões de crescimento (*stress crack*) ocorrem pela liberação das tensões de crescimento acumuladas no lenho durante o crescimento da árvore (Figura 3). Elas originam-se na região da medula, exceto para os casos de *tangencial shakes*, e acometem mais facilmente as áreas de lenho juvenil, fato esse corroborado pela baixa densidade do lenho nessa região. Além disso, essas rachaduras percorrem toda a extensão transversal da tora (*Transversing shakes*), alcançando as suas extremidades e assumindo formatos de “Y”, “T”, cruz, estrela ou uma rachadura linear (RICHTER, 2015).

Embora as rachaduras provenientes de tensão de crescimento apresentem os padrões anteriormente descritos, é importante realçar que estes não são sua exclusividade. A perda da umidade da madeira para valores inferiores ao ponto de saturação das fibras – PSF (30%) (*Dry cracks*) podem provocar os mesmos padrões de rachaduras. Ademais, esse processo também pode originar outros padrões de rachaduras como as *Heart shakes*, *Seasoning crack*, *Spider shake* e *Coat shake* (Figura 3) (RICHTER, 2015).

As rachaduras classificadas como *Heart shake* são caracterizadas por se localizarem na região medular/lenho juvenil e por se estenderem radialmente pela tora sem que alcance as suas regiões mais externas. Embora sejam correlacionadas com as *Dry cracks*, Richter (2015)

menciona que a ação dos ventos (*Schiffer shake*) e forças de cisalhamento (*Pitch pocket*) podem favorecer o aparecimento dessas rachaduras.

Figura 2 - Rachaduras que ocorrem em toras de madeira. Os anéis internos referem-se a rachaduras quanto ao seu formato. O anel externo refere-se às rachaduras quanto às causas.



Fonte: Do Autor (2023).

As *Seasoning cracks* (Figura 3) manifestam-se como uma combinação dos diferentes formatos de rachaduras (“Y”, “T”, cruz, estrela ou rachadura linear) em uma mesma secção da tora. Elas apresentam um padrão de desenvolvimento no sentido radial do tronco e podem penetrar profundamente nas toras, tal qual os *stress cracks*. Elas originam-se em respostas ao

coeficiente de anisotropia da madeira, o qual é responsável pela retração desigual entre os sentidos longitudinal-radial-tangencial, geralmente na proporção de 1:10:20. Como respostas, diferentes linhas de fissuras podem se desenvolver na madeira, acometendo tanto regiões de cerne quanto de alburno (RICHTER, 2015).

As *spiders shake* (Figura 3) originam-se em árvores ainda vivas e são decorrentes do processo de desidratação dos anéis de crescimento e da região do cerne (*dry crack*). Após o corte da árvore e sua secagem abaixo do PSF, sua visualização torna-se mais aparente. Apresentam-se como trepidações radiais em formato de estrela mescladas com rachaduras paralelas aos anéis de crescimento e são exclusivas de árvores tropicais (RICHTER, 2015).

As *dry cracks* também são características de rachaduras do tipo *Coat shake*. Esse tipo de rachadura é caracterizado por apresentar uma rachadura que interliga a medula à uma região externa com um calo. Ao que tudo indica, as *dry cracks* não são a causa imediata para o desenvolvimento das *coat shake*, mas podem potencializar o desenvolvimento desse tipo de rachaduras (RICHTER, 2015).

*Coats shake* são rachaduras que seguem o curso das fibras na superfície da tora penetrando-a, em muitas das vezes, no sentido longitudinal (Figura 3). As suas rachaduras são causadas devido à exposição das árvores à baixas temperaturas (*frost crack*), à altas temperaturas sem regime hídrico (*Heat crack*), ou devido a desidratação do tronco (*Dry crack*). Geralmente, para todos os casos, as rachaduras se desenvolvem com a árvore em pé, com exceção das *Dry cracks* (RICHTER, 2015).

As *frost cracks* acometem árvores submetidas à temperatura congelante. Ao que tudo indica, árvores sob tal circunstância sofrem contrações irregulares do lenho em decorrência do gradiente de temperatura existente entre a superfície exterior (mais frio) e a parte interior (mais quente) (KUBLER, 1988). Além disso, a ocorrência de lesões antigas ou irregularidades na casca, alto teor de umidade na madeira, grã reta, vasos de condução largos, raios grandes e uma alta proporção de parênquima configuram-se como fatores agravantes para o desenvolvimento desses tipos de rachadura (Figura 3). No geral, o desenvolvimento de *frost cracks* é seguido pelo aparecimento de calos na árvore, que podem se estender, longitudinalmente, por metros (RICHTER, 2015).

Enquanto as *frost cracks* são ocasionadas pelo frio extremo, as *heal cracks* são originadas por temperaturas elevadas associadas ao estresse hídrico. A combinação desses fatores provoca um acúmulo de componente de umidade no alburno inferior à 30%, o suficiente para o desenvolvimento de rachaduras (GRABNER et al., 2006; RICHTER, 2015). Essas rachaduras apresentam padrões similares aos das *frost cracks*, podendo ser visíveis na

parte externa da árvore em pé e se estendendo por vários metros (Figura 3). Além disso, a alternância de eventos de frio extremo e altas temperaturas podem agravar problemas de rachaduras de madeira, propiciando o desenvolvimento, em partes, das chamadas *radial shakes* (RICHTER, 2015).

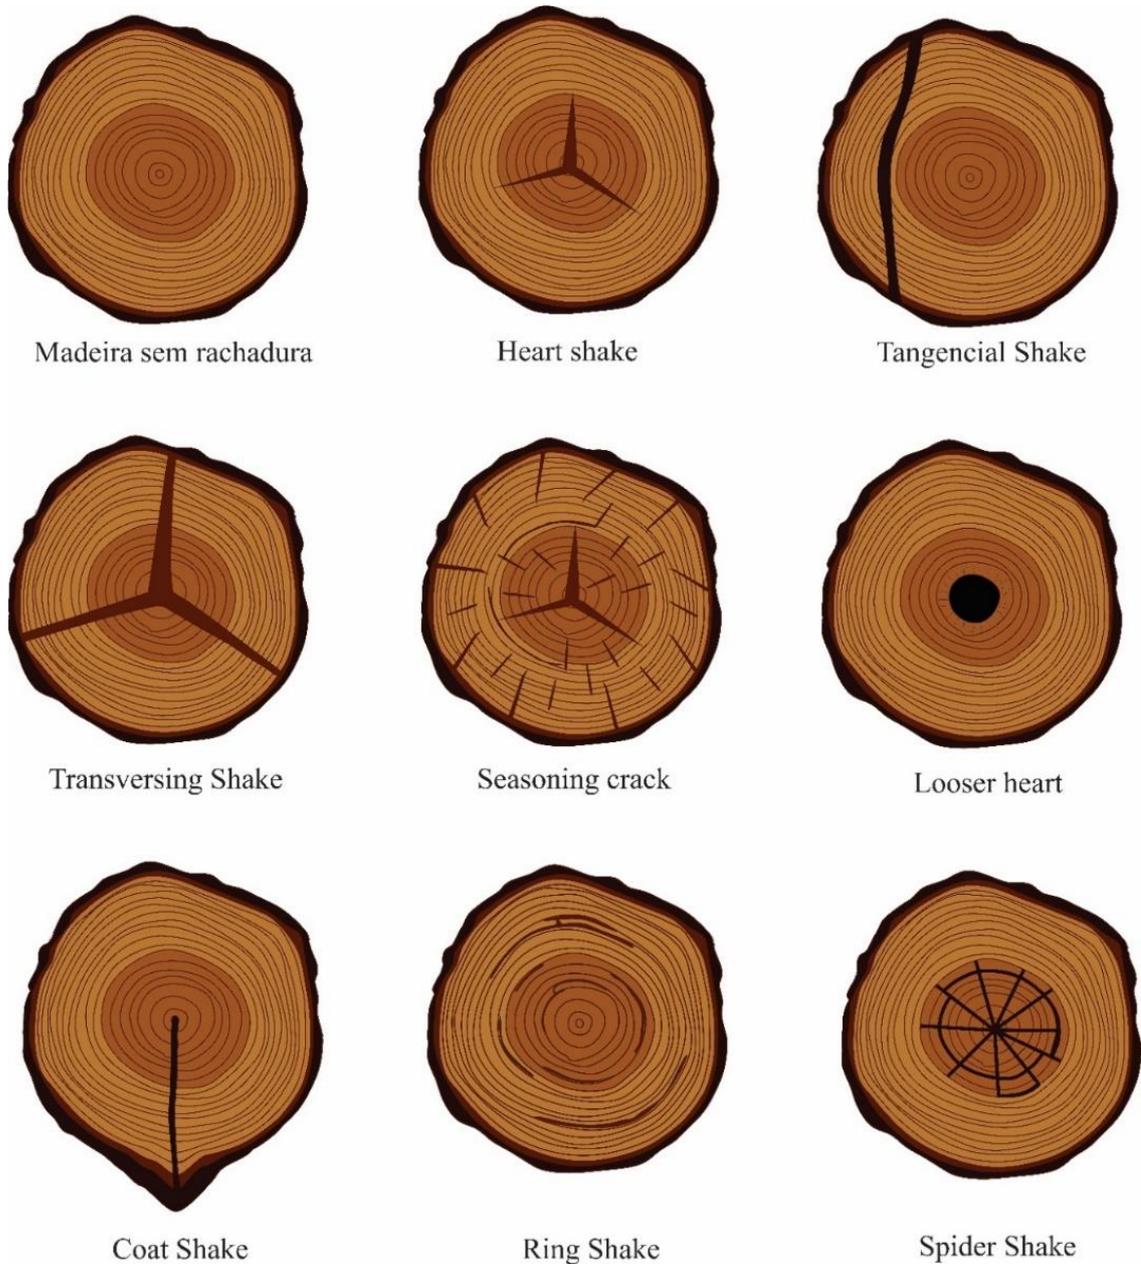
As *radial shakes* são um dos resultados de forças de tensão (*Stress crack*) entre os anéis de crescimento da árvore em ambientes de seca (Figura 3). A diferença de tensão no sentido tangencial entre os anéis de crescimento resulta no desenvolvimento de rachaduras a partir da lamela média-raios/traqueídeos (GRABNER et al., 2006). Esse fato também pode ser explicado pelo intenso potencial hídrico negativo gerado no estresse hídrico, resultando no aparecimento de trincas nos anéis de crescimento (RICHTER, 2015). Indiferente do princípio de surgimento, os estudos convergem para os mesmos resultados, mostrando que essas rachaduras estão associadas às regiões da madeira com menores densidades básicas aliadas às situações de déficit hídrico (Figura 3).

Uma outra forma de rachadura que é encontrada em madeiras são as chamadas *Ring shakes* (Figura 3). Comumente, essas rachaduras desenvolvem-se paralelamente aos anéis de crescimentos da árvore e podem advir de diferentes causas como por estresse (*Stress crack*), ataque de patógenos, ou na transição de lenho juvenil-tardio, sendo esse último característico de espécies tropicais (GRABNER; GIERLINGER; WIMMER, 2001; FONTI; MACCHIONI, 2003; RICHTER, 2015).

Nos casos de *stress cracks* as rachaduras podem se manifestar em decorrência de diferentes motivos ligados à eventos físicos (Figura 3). Elas, comumente são relacionadas às porções de lenho que apresentam lenho de reação, formação irregular dos anéis de crescimento e na fronteira entre o lenho juvenil-tardio (FONTI; MACCHIONI; THIBAUT, 2002; FONTI; MACCHIONI, 2003; RICHTER, 2015). Nesses casos, as rachaduras podem se originar com a árvore ainda em pé e tornam-se visíveis logo após o seu corte (RICHTER, 2015).

Um ponto em aberto na literatura sobre as rachaduras em anéis é a influência que os patógenos exercem para o seu desenvolvimento. No geral, as hipóteses sugerem que danos externos causados pelas *frost cracks* ou *Heal cracks* são, em muitas das vezes, responsáveis pela abertura na madeira por onde os patógenos entram. Richter (2015) classifica e nomeia “as rachaduras em anéis” advinda por patógenos como *Ring rot*. Para o autor, esse tipo de rachadura ocasiona o descolamento do anel de crescimento afetado na árvore. Contudo, Fonti e Macchioni (2003) não classificam esse evento como rachadura, mas sim como um defeito da madeira por descolamento.

Figura 3 - Classificação das rachaduras quanto ao formato.



Fonte: Do Autor (2023).

Indiferente do tipo de rachadura existente há uma preocupação em se buscar métodos que amenizem os seus danos e perdas. Nessa perspectiva, a investigação dos padrões genéticos das rachaduras para a aplicação em programas de melhoramento se tornou frequente em vários locais do mundo (ZELTIŇŠ et al., 2016, 2018; MOREIRA, 2020). Além disso, o refinamento de técnicas de manejo de povoamentos florestais também assume um importante papel no controle do desenvolvimento de rachaduras em madeiras (RICHTER, 2015).

As rachaduras de madeira apresentam um componente genético que contribui para a sua expressão. Esse fato desperta a atenção de melhoristas florestais os quais vêm trabalhando com esse caráter dentro de programas de melhoramento genético desde os anos 60 (LIBBY; JUND, 1962), em distintos gêneros, espécies e em vários locais do mundo.

A estimativa dos componentes genéticos das rachaduras, em especial, a herdabilidade, são frequentemente relatadas em estudos focados para tal caráter. Entretanto, os resultados, quando confrontados entre alguns trabalhos, são inconclusivos. Enquanto Assis (1999) e Garcia (2000) relataram altos valores de herdabilidades para as rachaduras oriundas de tensões de crescimento em toras de madeira, os autores ZELTIŇŠ et al. (2018) e ČAKŠŠ et al. (2022) observaram baixos valores para rachaduras do tipo *Coat shakes*. Assim, é possível que diferentes tipos de rachaduras assumam diferentes valores herdabilidades. Essa dissonância gera incertezas sobre o quão fácil é trabalhar com tal caráter dentro dos programas de melhoramento genético.

Os programas de melhoramento de espécies florestais ao longo do mundo têm assumido diferentes estratégias. Em alguns locais, como na Letônia, testes de procedência em busca de Abeto Noruegues (*Picea abies* Karst) com menores propensão à rachadura são relatados (ZELTIŇŠ et al., 2016, 2018). Os resultados sugerem que há diferença entre as procedências para as rachaduras, permitindo assim, o direcionamento da manutenção dos bancos de germoplasmas e das populações dos programas de melhoramento (ŠĚNHOFÁ et al., 2016; ZELTIŇŠ et al., 2018).

Estratégias de hibridação e de clonagem apresentam bons resultados no controle de rachaduras em abeto-falso (*Picea sp.*) e Álamo (*Populus sp.*). Diferenças significativas entre clones de híbridos de *Populus tremula* L. com *Populus tremuloides* Michx. podem ser observadas (ČAKŠŠ et al., 2022). Esse fato possibilita uma seleção eficiente de árvores com constituição genética favorável ao controle das rachaduras (ČAKŠŠ et al., 2022). Além disso, o procedimento de hibridação permite a obtenção de árvores com altas capacidades regenerativas à danos externos ao tronco da árvore. Com isso, danos ocasionados por eventos abióticos podem ser minimizados, dificultando a entrada de patógenos e o desenvolvimento de *Rings rot*.

O levantamento bibliográfico sobre as rachaduras em madeira denota a existência de uma dicotomia para a seleção. Por vezes, a seleção pode ser praticada por vias indiretas, pela correlação com outros caracteres; ou por vias diretas, por meio de mensurações das rachaduras presentes. A sua investigação, sobretudo, para o primeiro caso, é bem relatada na literatura e, por vezes, tem sido preferida.

A recomendação da seleção indireta para as rachaduras decorre de suas aparentes correlações com outras características inerentes à madeira. Comumente, os estudos sugerem que o seu desenvolvimento pode estar atrelado à alguns caracteres tais como: (i) densidade do lenho, (ii) diâmetro da altura do peito – DAP; e (iii) dimensões das fibras.

Entre os caracteres que tem alta correlação com as rachaduras na madeira, a densidade do lenho é a que apresenta uma unanimidade dentro da comunidade científica. Regiões do lenho com menores densidades apresentam maior probabilidade de desenvolvimento de rachaduras (BATISTA; KLITZKE; SANTOS, 2010; MONTEIRO et al., 2017; ZELTIŇŠ et al., 2018; NASCIMENTO et al., 2019). Assim, a seleção de árvores com maiores densidades básicas denota uma estratégia viável à seleção para rachaduras (ZELTIŇŠ et al., 2018; NASCIMENTO et al., 2019).

De longe, o diâmetro na altura do peito (DAP) é um dos caracteres mais importantes ao se trabalhar com espécies arbóreas. Todavia, a sua relação com surgimento de rachaduras na madeira, por vezes, não é consonante entre os pesquisadores. Alguns trabalhos, como o de Cunha et al. (2014) e Nascimento et al. (2019), por exemplo, sugerem uma maior probabilidade de rachaduras em troncos com menores diâmetros. Entretanto, Šenhofa et al. (2016) e Zeltiňš et al. (2018) contrapõem-se a tais afirmações ao concluírem a inexistência de relações diretas do DAP e rachaduras.

Embora haja alegações sobre o crescimento da árvore e o DAP no desenvolvimento de rachaduras esses fatores não dão respaldo o suficiente para fazer quaisquer afirmações sólidas. Os trabalhos que relatam uma tendência de rachadura em função do diâmetro carecem de informações mais detalhadas sobre a densidade e suas relações com perdas hídricas, lenho juvenil-tardio e quaisquer métodos de padronização para controle de umidade. Sobre esse último, Nascimento et al. (2019) infere que as rachaduras que incorrem em toras após o corte derivam do processo de secagem (*dry cracks*) e que é necessária uma logística para o controle das rachaduras. Nesse sentido, árvores menores atingem o ponto de saturação das fibras (PSF), ou seja, umidade da madeira menor que 30%, mais rapidamente quando comparado às árvores de maiores diâmetros. Desse modo, quando deixadas em mesmo ambiente, no momento em que árvores de diâmetros maiores atingem o PSF, as árvores de menores diâmetros estão abaixo desse valor, e por conseguinte, racham mais.

Ainda, existem abordagens anatômicas que sugerem que as rachaduras apresentam relações diretas com as dimensões das fibras. Com o aumento da idade da árvore as novas fibras apresentam maiores dimensões e menores deformações longitudinais. O menor potencial de deformação das fibras implica em menores tensões de crescimento no tronco da

árvore que, por sua vez, incorre em uma menor incidência de rachaduras (TRUGILHO et al., 2002; PÁDUA et al., 2004). Entretanto, esse argumento não é forte o suficiente para justificar a presença das rachaduras e acaba incorrendo nos mesmos problemas para o DAP, anteriormente mencionado. Se árvores mais velhas têm maiores dimensões de fibras e deformam menos, o que se espera é uma menor tendência de rachaduras em árvores com maiores DAP e isso, de fato, não é relatado nos trabalhos de Šēnhofa et al. (2016) e Zeltiņš et al. (2018) .

A seleção de árvores com menores propensão às rachaduras, geralmente, ocorre por métodos diretos. Neles, à área de rachadura é contabilizada e seus valores subsidiam as entradas dos modelos matemáticos para a seleção. Embora haja a possibilidade de se praticar o melhoramento indireto para as rachaduras de topo, boa parte dos programas de melhoramento genético praticam a seleção direta para esse caráter. Para tanto, é necessário aferir a área afetada por meio de métodos eficazes ao passo que certos cuidados sejam tomados para que fatores externos não enviesem as estimativas das análises (SCHACHT; GARCIA; VENCOVSKY, 1998).

Diferentes abordagens podem ser usadas para se avaliar as rachaduras de topo de toras como as avaliações manuais (NASCIMENTO et al., 2019), por notas (ŠĚNHOFA et al., 2016; ZELTIŅŠ et al., 2018; ČAKŠS et al., 2022) e, recentemente, a visão computacional (MOREIRA, 2020).

Os métodos manuais são aqueles nos quais a mensuração das rachaduras ocorre diretamente pelo ser humano com o auxílio de algum equipamento métrico como fitas métricas, réguas ou paquímetros. Em geral, duas vias de análises podem ser adotadas para os métodos manuais. A primeira, e a menos comum, é a utilização dos valores nominais da área afetada da tora. Já o segundo, e mais utilizado principalmente na comunidade científica brasileira, é o cálculo de índice de rachaduras (IR) proposto por Lima, Garcia e Piedade (2002). Este último, em especial, apresenta resultados semelhantes das análises por notas e por visão computacional. Todavia, métodos manuais dependem de muitas horas humanas de trabalho (HH) o que implica em análises lentas e mais onerosas (MOREIRA, 2020).

Abordagens avaliativas por escalas de notas apresentam bons resultados e são promissoras para a seleção de árvores para a rachadura de topo. Além de terem boa coincidência frente aos métodos de análises manuais, esta abordagem apresenta uma notável redução do tempo para as análises (MOREIRA, 2020). Contudo, avaliações baseadas em escalas de notas são passíveis de subjetividade do avaliador, podendo aumentar o erro e influenciar na seleção.

Abordagens tecnológicas, recentemente, tem sido relatada para a inferência da área afetada por rachaduras em toras de madeira. No geral, algoritmos de visão computacional são criados, ou adaptados, para que um computador consiga identificar e contabilizar as rachaduras em fotos digitais (MOREIRA, 2020). A eficiência dessa metodologia para discriminar rachaduras de toras apresenta bons resultados tal qual aos demais métodos. Contudo, a redução do tempo necessário para as análises é um dos principais destaques da técnica, economizando recursos e acelerando as análises, sobretudo, para a seleção de genótipos (MOREIRA, 2020). Todavia, as abordagens de visão computacional testadas até o presente momento utilizam fotografias realizadas em ambiente controlado. O desenvolvimento de plataformas de fenotipagem de rachaduras no ambiente de campo pode ser de bem valia, já que ganhos notórios de tempo podem ser alcançados (em segundos), além de dispender de uma mão de obra reduzida, em geral uma ou duas pessoas (ESGARIO et al., 2021; TASSIS; TOZZI DE SOUZA; KROHLING, 2021).

## **2.2 Visão Computacional**

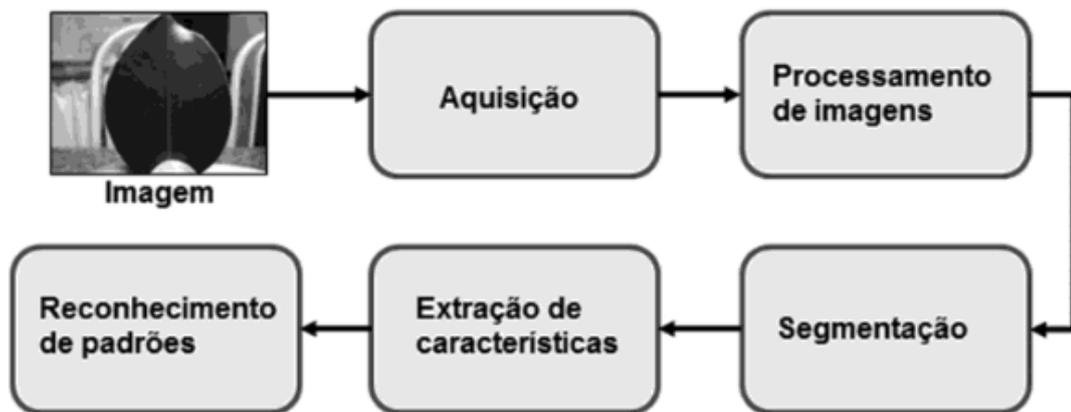
A visão computacional (CV) é um amplo campo de pesquisa que visa criar máquinas capazes de entender o mundo por meio da sua estrutura perceptível. Ela surgiu como uma subdivisão da inteligência artificial com o objetivo de emular em máquinas as habilidades visuais encontradas nos seres humanos (OLAGUE, 2016).

Inicialmente a visão computacional foi utilizada para a identificação de padrões simples em imagens. Com as evoluções tecno-científicas ela sofreu profundas modificações permitindo que fosse empregada na solução de diferentes tipos de problemas (OLAGUE, 2016). A principal evolução técnica-científica foi a introdução das unidades de processamentos gráficos (GPU's) que possibilitaram a execução de grandes quantidades de cálculos em processamento paralelo e a implementação de diferentes algoritmos complexos de aprendizado profundo.

Hoje, a visão computacional configura-se como um processo complexo o qual é constituído por várias etapas. Entender os princípios e o funcionamento de cada etapa propicia a otimização das aplicações de visão computacional, trazendo melhorias e boa performance para a tarefa cuja tal aplicação foi desenvolvida. Há uma variação entre as literaturas sobre quais são as fases que compõem uma aplicação de visão computacional, contudo Backes e Sá Júnior (2019) (Figura 4) a categorizam em:

- **Aquisição:** Processo pelo qual a imagem do objeto é obtida por meio de um dispositivo como um scanner ou uma câmera;
- **Processamento de imagem:** Corresponde a etapa de preparação e melhoria da imagem. São realizadas etapas de controle de ruído, saturação, brilho, recortes, aplicações morfológicas. Tem o objetivo de fornecer uma imagem de qualidade para o algoritmo. Em algumas literaturas essa etapa pode ser nomeada como pré-processamento (VOULODIMOS et al., 2018);
- **Segmentação:** Particiona os objetos de interesse da imagem;
- **Extração de características:** Responsável por encontrar uma codificação numérica que permite obter um conjunto de características dos objetos da imagem;
- **Reconhecimento de padrões:** Fase na qual os objetos da imagem são classificados ou agrupados com base nas suas características.

Figura 4 – Esquema de um sistema de visão computacional.



Fonte: Backes e Sá Júnior (2019).

As abordagens tradicionais de aprendizado de máquinas possuem limitações quanto a sua capacidade de processamento de dados brutos. Ao se trabalhar com visão computacional é necessário alto poder de processamento e de abstração. Nesses casos, a implementação de modelos de aprendizado profundo são sugeridas já que elas cumprem tais requisitos (LECUN; BENGIO; HINTON, 2015). Dentre as diferentes arquiteturas de aprendizado profundo as redes neurais convolucionais (CNN's) são as mais comuns em aplicações de visão computacional, uma vez que apresentam maior precisão e confiabilidade quando comparada com outras redes (KRIZHEVSKY; SUTSKEVER; HINTON, 2017).

As redes neurais convolucionais (CNN's) (Figura 5) foram inspiradas na estrutura do sistema visual baseado nos modelos propostos por Hubel e Wiesel (1962). Os primeiros modelos computacionais com essas arquiteturas apresentavam invariâncias translacionais quando neurônios com os mesmos parâmetros são aplicados em trechos da camada anterior em locais diferentes (FUKUSHIMA; MIYAKE, 1982). Posteriormente, as CNN's foram aprimoradas e seu uso direcionou-se para o reconhecimento de padrões de texto e de escritas (LECUN et al., 1989, 1998). Hoje, sua aplicação é relatada em diversos nichos como no automobilístico, médico, industrial, geoespacial, agrário, civil e dentre outros (GAO et al., 2022; GÜNDER et al., 2022; LI; CHEN, 2022; PRASANALAKSHMI et al., 2022; RAUT; KRIT; CHATTERJEE, 2022; THOMBARE, 2022).

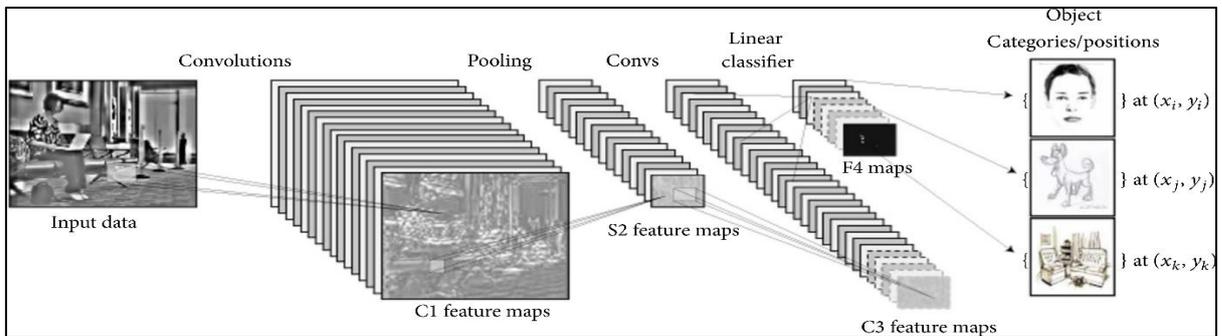
As CNN's geralmente são estruturadas em três tipos de camadas neurais conhecidas como: (i) camadas convolucionais, (ii) camadas de agrupamento e (iii) camadas totalmente conectadas. Cada camada de uma CNN tem papéis específicos e todas têm o poder de transformar o volume de entrada em um volume de saída de ativação do neurônio. Esse processo resulta em camadas finais totalmente conectadas e convergem em um mapeamento dos dados de entrada para um vetor de recursos (VOULODIMOS et al., 2018). No geral, as atribuições de cada camada podem ser resumidas em:

- i) Camadas Convolucionais. Nessas camadas a CNN utiliza vários *kernels* para “convoluir” toda a imagem, bem como os mapas de recursos intermediários, gerando vários mapas de recursos. Podem ser usadas no lugar das camadas totalmente conectadas com o objetivo de obter tempos de aprendizado mais rápidos.
- ii) Camadas de Agrupamento (*Pooling*): As camadas de agrupamento são responsáveis por reduzir as dimensões espaciais dos dados de entradas (*ex. imagens*) por meio de processos chamados de redução de dimensionalidade (*subsampling* ou *downsampling*). Essa redução se faz necessária para diminuir o esforço computacional ao passo que problemas de sobreajustes (*overfittings*) são evitados.
- iii) Camadas Totalmente Conectadas: Essas camadas são responsáveis por receber as informações das demais camadas e realizar um raciocínio de alto nível na rede neural.

As CNNs enfrentam problemas de sobreajustes relacionados ao grande número de parâmetros que precisam ser aprendidos. Esse problema ocorre quando o modelo é excessivamente treinado. O excesso de aprendizado gera muitos ruídos no modelo, diminuindo a sua precisão e a sua capacidade de generalização. Para evitá-lo, algumas proposições sugerem o emprego de técnicas de *pooling* estocástico, *dropout*, ampliação do

banco de dados (*data augmentation*), aprendizado de transferência ou o uso *backbones* adequados (HINTON et al., 2012; WU; GU, 2015; VOULODIMOS et al., 2018; WANG et al., 2018; ZHONG et al., 2020).

Figura 5 – Esquema simplificado do funcionamento de uma rede neural convolucional.



Fonte: Voulodimos et al. (2018).

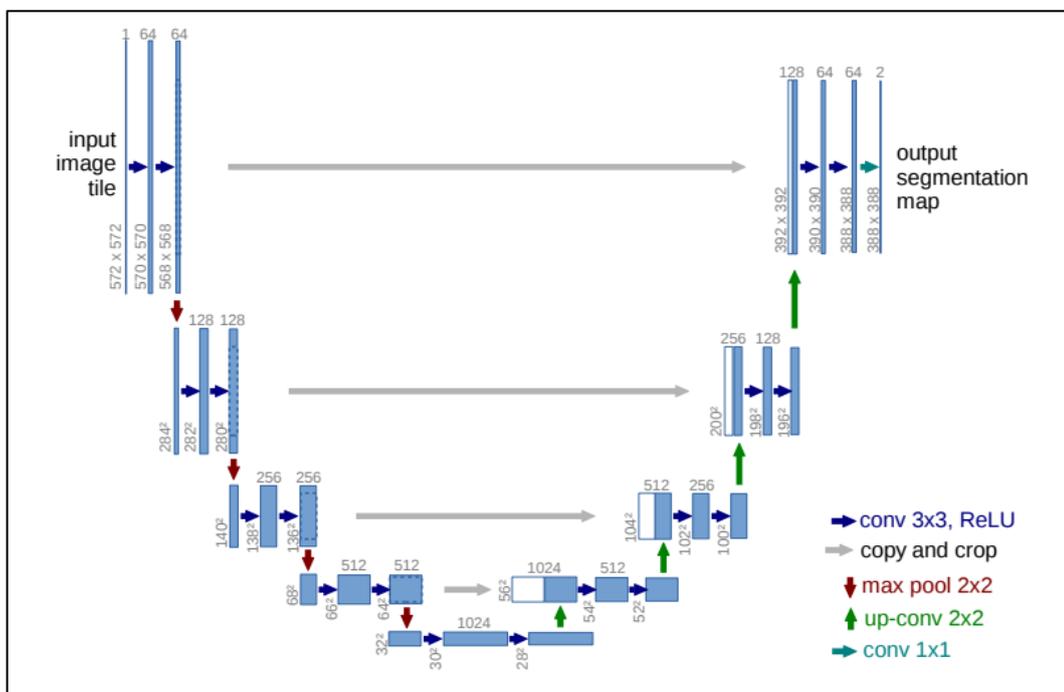
A arquitetura U-Net foi apresentada por Ronneberger et al. (2015) cuja proposta era criar uma estrutura de análises de imagens médicas com alta performance. A sua construção ocorreu de modo que fosse possível obter um bom desempenho dos modelos com um *dataset* reduzido. Sua base é fundamentada sobre as redes neurais totalmente convolucionais (FCN). Nela, os operadores de agrupamento são substituídos por operadores de redução de dimensionalidade, o que é traduzido em imagens menores com um alto grau de detalhes preservados (RONNEBERGER; FISCHER; BROX, 2015). Ademais, o seu processo de localização passa a ser a combinação dos recursos de alta resolução do caminho de contratação com a saída com resolução aumentada (*upsampled*). Os resultados desses processos são melhores taxas de aprendizado das camadas convolucionais ao passo que menores esforços computacionais são requeridos.

O funcionamento da U-Net, descrito anteriormente, pode ser resumido em processos denominados *Encoder* (Contração) e *Decoder* (Decodificação) (Figura 6). O *Encoder* extrai os recursos multiescalares da imagem por meio de uma sequência de camadas convolucionais e de *Max pool* (pool máximo) (Figura 6). Já o *Decoder* é usado para localizar regiões das imagens usando circunvoluções transpostas. A combinação desses processos permite que a arquitetura U-Net trabalhe com imagens de qualquer tamanho (ALSENAN; YOUSSEF; ALHICHRI, 2021).

Embora tenha sido construído para o uso em imagens médicas, a arquitetura U-Net têm sido amplamente empregada no setor agrário. As abordagens baseadas nessa arquitetura

buscam o desenvolvimento de plataformas de fenotipagem de alto-rendimento com foco em contagem e análise morfológica de grãos (TODA et al., 2020), identificação e quantificação de daninhas (ZOU et al., 2021), severidade de doenças (TASSIS; TOZZI DE SOUZA; KROHLING, 2021; DIVYANTH; AHMAD; SARASWAT, 2022), acamamento de culturas (SU et al., 2022), estudos de copa (SHAO et al., 2022) e avaliação de sistemas radiculares (SMITH et al., 2020).

Figura 6 – Esquema de funcionamento da arquitetura U-Net. Os blocos azuis correspondem aos mapas de recursos, os blocos brancos correspondem aos mapas de recursos copiados e cortados. O número de feições no mapa é mostrado no topo de cada bloco e as setas indicam as operações realizadas.



Fonte: Ronneberger et al. (2015).

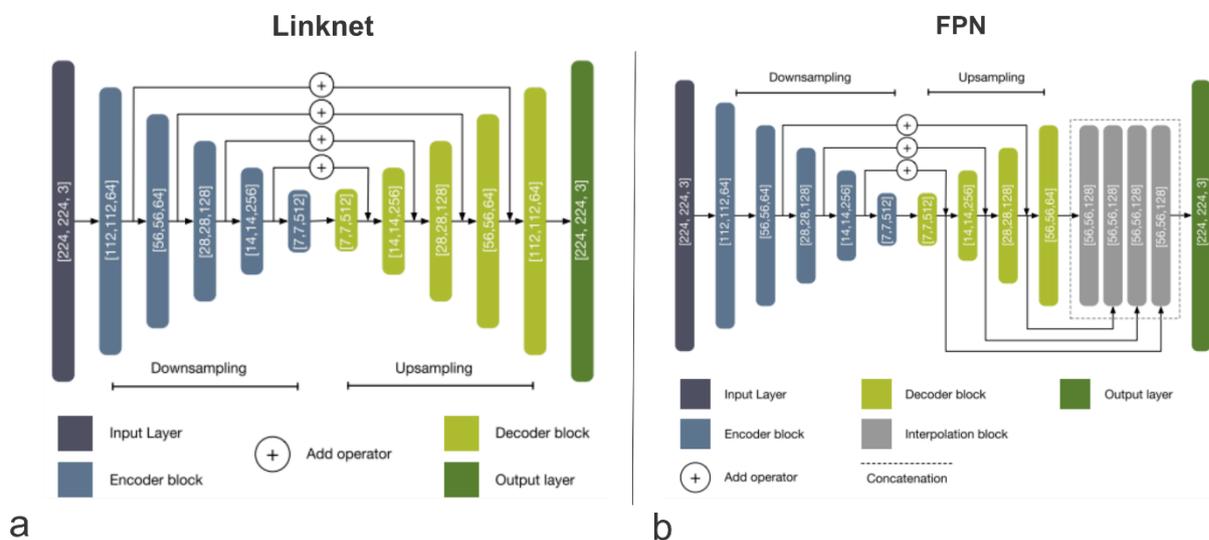
De maneira geral, os resultados das aplicações da arquitetura U-Net para a solução de problemas relacionados ao setor agrário são promissores. Independente da característica analisada, a acurácia dos modelos U-Net é superior à 90%, tanto em condições de laboratório quanto de campo. Outro ponto positivo é o seu curto tempo para o processamento das imagens que podem ocorrer em microssegundos (ZOU et al., 2021).

Dentro do grupo de modelos de CNN's há duas arquiteturas que se assemelham ao à U-Net, sendo elas a Linknet e a recurso de redes piramidais (FPN). De modo homólogo à U-Net, essas são constituídas por codificadores e decodificadores multiescalares os quais são

responsáveis pela extração dos recursos dos dados, pela aplicação de uma redução de dimensionalidade e a realização do incremento da resolução dos mapas de recursos ao passo que reduz pela metade número de canais de recurso.

Embora as arquiteturas apresentem semelhanças quanto ao princípio de funcionamento, ainda sim, essas carregam consigo peculiaridades que as tornam únicas. A grande diferença entre as arquiteturas é o modo pelo qual as camadas de codificação e de decodificação são integradas.

Figura 7 – Arquiteturas Linknet (a) e FPN (b). Os números entre colchetes indicam as saídas dos blocos [altura, largura, número de canais].



Fonte: Adaptado de Garcia-Pedrero et al. (2020).

Enquanto a U-Net concatena o mapa de características de cada uma das rotas de *downsampling* com os seus correspondentes no *upsampling*, na Linknet a entrada de cada *encoder* é mesclada à saída de seu *decoder* correspondente (Figura – 7) com o objetivo de recuperar o espaço de informações perdidas durante o processo de *downsampling*. Por outro lado, a FPN inclui uma rota de cima para baixo e uma rota de baixo para cima com conexões laterais. Embora a sua implementação seja interpretada de forma semelhante aos da U-Net e da Linknet, a principal diferença é vista nas conexões laterais, uma vez que elas mesclam mapas de recursos do mesmo tamanho espacial, desde o caminho do *encoder* até a saída de cada *decoder* correspondente. Ademais, a informação dentro da rede é desviada para as camadas do bloco de interpolação, localizadas entre o bloco *decoder* e a camada de saída.

### 2.2.1. Aplicações de visão computacional em detecção de defeitos em madeira

O interesse em se utilizar aplicações de visão computacional para a avaliação de defeitos de madeira é relatado desde o século passado. Adel et al. (1993) já demonstravam a intenção de modernizar os processos de análises de defeitos de madeira por meio de aplicações de visão computacional (CV). Nos últimos anos, devido a popularização do aprendizado profundo, houve um crescente aumento no uso de abordagens de visão computacional para a identificação de defeitos na madeira, sobretudo para características como nós, rachaduras, manchas e lenho de reação (Tabela 1). Entretanto, mesmo com os avanços técnicos científicos, o tipo de defeito na madeira e a ocorrência de seus diferentes tipos implicam diretamente na acurácia e no tempo de detecção de algumas abordagens de visão computacional (CHANG; CAO; ZHANG, 2018; HE et al., 2019).

Uma abordagem para a detecção de defeitos na madeira por meio da associação dos padrões binários locais (LBP) com o detector/descritor de recursos robustos e acelerados (SURF) e o classificador máquina de vetor de suporte (SVM) foi desenvolvida por Hittawe et al. (2015). O estudo se voltou na detecção de rachaduras e nós em tábuas de diferentes espécies de *Pinus* e os resultados dessa metodologia apresentaram-se promissores com acurácias de detecção média de 91,50%.

Um método de detecção de nós e de rachaduras por meio da fusão análise de componentes principais (PCA) com a detecção comprimida foi proposto por Zhang et al (2015). O novo método de classificação e detecção apresenta uma série de vantagens em relação a rede neural de mapa auto-organizado (SOM) apresentada por Lampinen et al. (1996), tais quais: (1) Maior processamento em menor tempo; (2) Maior acurácia; (3) Maior flexibilidade e (4) Quantidade menor de parâmetros.

He et al. (2019) aplicaram a rede neural mista e totalmente convolucional (Mix-FCN) para avaliação de nós vivos e mortos, rachaduras, manchas azuis e *Pitch streak* em tábuas. O algoritmo apresentou uma acurácia de 99,14% em condições de laboratório sendo a maior quando comparada com outras abordagens existentes na época.

Recentemente, as redes neurais convolucionais profundas (DCNN) foram testadas para a detecção de defeitos de madeira. He et al. (2020) aplicaram esse algoritmo para a detecção de rachaduras, nós e manchas e comparou o seu tempo de processamento e a sua acurácia com outros métodos de detecção. A nova abordagem apresentou resultados promissores, com uma acurácia de 99,13%. Além disso, o tempo de processamento também se demonstrou como ponto forte dessa abordagem com a análise de 50 imagens em 0,389 segundos.

Um outro algoritmo relatado para a detecção de defeitos em madeira é o detector multiBox Shot (SSD), o qual é muito utilizado para a detecção de rostos. Yang et al. (2021) modificaram a estrutura do algoritmo, por meio da substituição de parte da rede do grupo de geometria visual (VGG) pela rede de resíduos (ResNet). Os resultados dessas alterações se traduziram no incremento da acurácia da detecção de 78,60 % (SSD normal) para 89,70% (SSD modificado). Além disso, a mudança também permitiu a redução no tempo de detecção o qual caiu de 160 milissegundos para 90 milissegundos.

Uma das redes neurais com mais potencial para a análise de madeira são as redes neurais convolucionais (CNN). Elas apresentam alto poder de aprendizado e reduzem o impacto da segmentação manual no processo de treinamento o que, por sua vez, se traduz em modelos com menores erros de treinamento (GAO et al., 2021). Chen e Jahanshahi (2018) associaram as CNN ao classificador de *Naive bayes* para a automação de detecção de manchas e rachaduras de madeira em vídeos. O novo método teve acurácia de 98,30% de detecção e tem alta empregabilidade por permitir o uso em vídeos.

Um dos problemas em se trabalhar com detecção de defeitos em madeira é o tamanho das amostras. Em algumas situações, utilizar um grande conjunto de dados de treinamento pode ser uma tarefa difícil, tanto pela aquisição das imagens quanto pelo processo de treinamento manual. Utilizar um conjunto de dados composto por poucas imagens pode enviesar o modelo pelo aparecimento de subaprendizado ou superaprendizado. Um dos modos de contornar esse problema foi proposto por Gao et al. (2021). Eles desenvolveram um algoritmo com 35 camadas de convoluções para o estudo de defeitos na madeira ao unir ao extrator Res-Net 34 à transferência de aprendizado. O resultado obtido pelos pesquisadores foi uma acurácia de 98,12% com alto poder de detecção de diferentes tipos de defeitos na madeira com o emprego de um conjunto de dados reduzido.

Em geral, os estudos de detecção de defeitos em madeiras buscam alternativas para a análise de qualidade da madeira. Em geral, a inspeção dos defeitos da madeira é manual sendo um método tendencioso e passível de erros (LIM; BONAB; CHUA, 2022). Além dos estudos já citados existem muitos outros que testaram outras abordagens para o estudo de detecção de defeitos em madeira, os quais podem ser consultados na Tabela 1. Entretanto, todas as abordagens convergem para análises em situações de laboratório ou industrial, não cobrindo avaliações em ambientes dinâmicos (campo) e nem contabilizam as áreas afetadas.

Tabela 1- Principais arquiteturas de visão computacionais, suas acurácias e tempo de detecção para defeitos de madeira.

(Continua)

Método de detecção de defeitos de madeira	Acurácia (%)	Defeitos	Tempo e detecção (segundos)	Imagem	Referência
CNN + classificador ELM	96,72	Manchas, Nós e rachadura	0,187	Imagem RGB (100 x 100 pixels)	(YANG et al., 2020)
FMMIS + classificador SVM	91,00	<i>Bird's eyes</i> <sup>4</sup> , manchas, buracos, nós vivos e mortos, pockets, <i>split wane</i> <sup>5</sup>	9,770	Imagem cinza (320X240 pixels)	(RUZ; ESTÉVEZ; RAMÍREZ, 2009)
Realce de contraste, maximização de entropia, ajuste de imagem para extração de recursos + classificador SVM	91,50	Nós e rachaduras	1,600	Imagem cinza (640x4500 pixels)	(HITTAWE et al., 2015)
PCA+SOM	92,00	Nós vivos e mortos e rachaduras	0,216	Imagem cinza (256 x 256 pixels)	(ZHANG et al., 2015)
Análise linear discriminante	94,00	Nós e rachaduras	0,000446	Imagem cinza (128 x 128 pixels)	(LI et al., 2017)
Segmentação Otsu+ CART	94,10	Pinhole, Rachaduras, nós vivos e mortos	3,170	Imagem cinza (256 x 256 pixels)	(CHANG; CAO; ZHANG, 2018b)
YoloV3	80,76	Rachaduras, nós e buracos	-	Imagem colorida (416x416 pixels)	(WANG et al., 2021)

<sup>4</sup> Defeito de madeira comum na família do sabugueiro semelhante à pequenos nós com aspecto de olho de pássaros que interrompem a continuidade da grã. Até o presente momento dessa pesquisa sua causa ainda é desconhecida.

<sup>5</sup> Tipo de rachadura que acomete tábuas no sentido do seu comprimento.

Classificador SVM +estrutura de árvore	96,50	Nós	-	Imagem colorida (320 × 240 pixels)	(GU; ANDERSSON; VICEN, 2010)
NB-CNN	98,30	Marca de moagem, rachadura, arranhão	0,37 – 9,35	Imagem colorida (120 x 120 pixels)	(CHEN; JAHANSHAH, 2018)
DCNN	99,13	Nós, Rachaduras, mofo	0,389	Imagem colorida (200 × 200 pixels)	(HE et al., 2020)
Mix-FCN	99,14	Rachaduras, manchas, nós vivos e mortos e pitch streak	0,368	Imagem colorida (256x256 pixels)	(HE et al., 2019)
DCNN	98,30	Nós, rachaduras, apodrecimento	0,000446	Imagem cinza (200 × 200 pixels)	(PAN; ROGULIN; KONDRASHEV, 2021)
BLNN	99,20	Nós	0,0795	Imagem colorida (25 x25 pixels)	(GAO et al., 2021b)
Faster R-CNN	99,00	Nós, Rachaduras	0,0112	-	(MOHSIN et al., 2022)

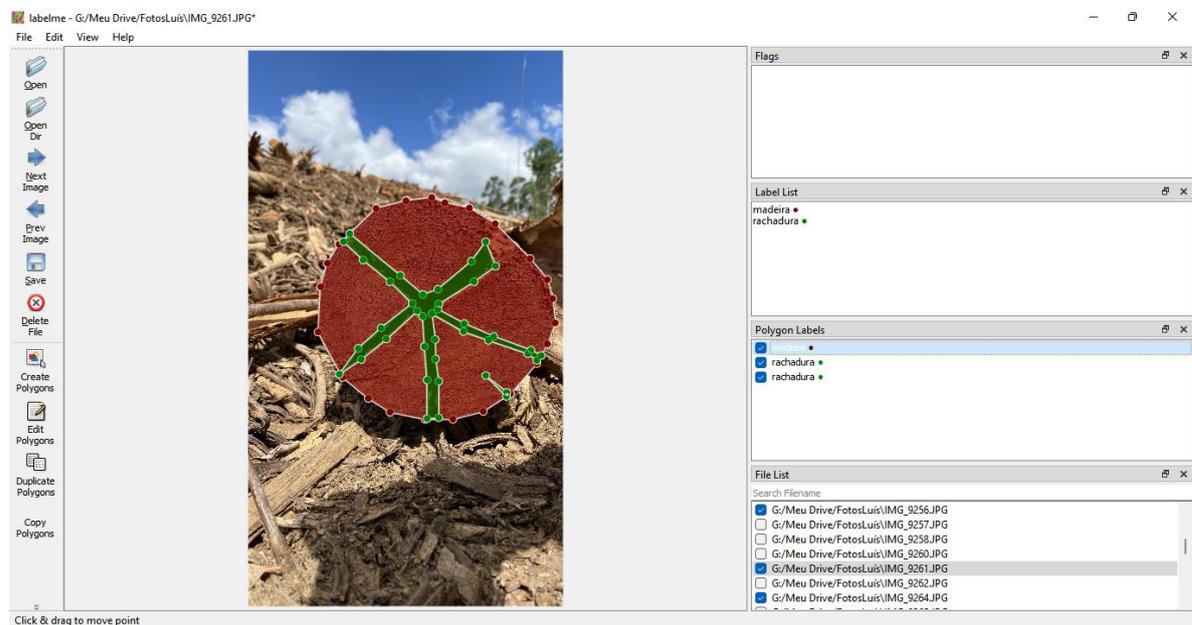
Fonte: Do Autor (2023).

### 3 MATERIAL E MÉTODOS

Para a realização desse trabalho foram utilizadas imagens de rachaduras de topo de *Eucalyptus spp* obtidas em condições de campo e em estúdio. Foram tomadas 149 imagens em condições de campo em um plantio sob processo de colheita no município de Virginópolis-MG no ano de 2022. Para a obtenção das imagens de campo foi utilizado uma câmera de um Iphone 11, com um sensor de resolução de 4000 x 3000 pixels (12 megapixels) e abertura de 1.8. Além disso, foram usadas 202 imagens de estúdio obtidas e Moreira (2020) por meio de uma câmera de 13 megapixels.

Para a anotação e confecção das máscaras das imagens obtidas em campo, foi utilizada a ferramenta de anotação LabelMe (RUSSELL et al., 2008). Para cada imagem foi obtida uma máscara composta por três classes sendo elas o *background*, a madeira e as rachaduras (Figura 8).

Figura 8 - Exemplo de anotação manual das imagens de campo no labelme. Na imagem as áreas verdes e vermelhas correspondem, respectivamente, às rachaduras e à secção da tora. O background foi atribuído para todo o restante da imagem.



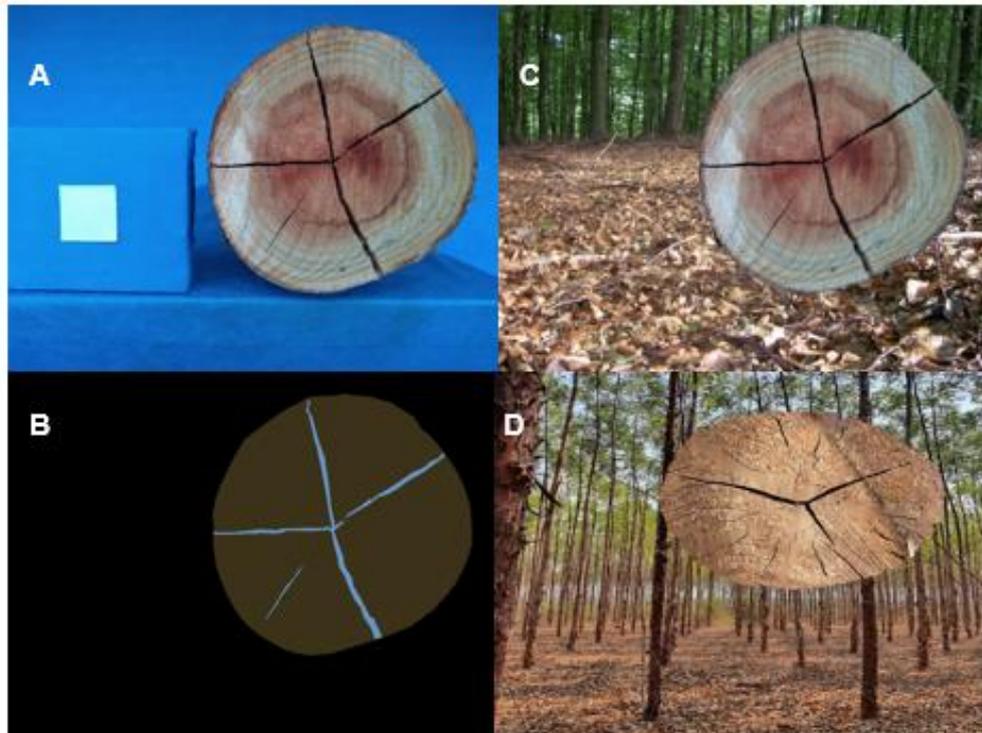
Fonte: Do Autor (2023).

As toras presentes nas imagens de estúdio (Figura 9-A) foram segmentadas e posteriormente mescladas à diferentes imagens de *backgrounds* com o intuito de simular uma situação de campo totalizando 202 imagens (Figura 9-C). Todavia, as imagens de estúdio apresentavam padrões similares de textura e coloração o que limita a capacidade de

generalização dos modelos. Para contornar esse problema foram geradas outras 464 imagens (Figura 9-D) com diferentes padrões de texturas e coloração por meio da mesclagem desses atributos extraídos de imagens de madeiras reunidas da internet e por colaboradores. Ao final desses processos, foram obtidas 666 imagens sintéticas, sendo 202 com texturas originais e 464 com texturas modificadas.

Diferentemente das imagens de campo anotadas, as imagens sintéticas não apresentam informações de referenciamento e nem as máscaras das classes alvo, informações essenciais para o treinamento dos modelos. Para contornar tal problema, foram utilizadas as máscaras preexistes do banco de imagens de Moreira (2020) daquelas imagens empregadas para a criação das imagens sintéticas (Figura 9-B). O referenciamento das classes nas imagens foi realizado por meio da extração das posições das classes nas máscaras e transferidas para as imagens sintéticas. A rotina utilizada para a geração das imagens sintéticas pode ser acessada no GitHub<sup>6</sup>.

Figura 9 - Exemplo de Imagem do *dataset* de Moreira (2020) (A), sua respectiva máscara (B), Imagem sintética com troca de *background* (C) e com troca de *background* e textura (D).



Fonte: Do Autor (2023).

<sup>6</sup> [https://github.com/Luigicarlo01/Gerador-de-Imagens-sint-ticas/blob/main/synthetic\\_image\\_generator%20\(1\).ipynb](https://github.com/Luigicarlo01/Gerador-de-Imagens-sint-ticas/blob/main/synthetic_image_generator%20(1).ipynb)

Após tais etapas foram reservadas 20 imagens obtidas ao acaso das imagens de campo para a análise visual dos resultados. O restante das imagens foi congregado com as imagens sintéticas em um *dataset* inicial composto de 795 imagens (Campo= 129; Sintéticas = 666).

Antes do treinamento dos modelos foi feita a ampliação do banco de imagens a fim de se evitar a ocorrência de *overfitting*. Para tanto, sobre as 795 imagens já existentes, foram aplicadas as funções de rotações horizontais e verticais, além de correções aleatórias do Gamma (SUN et al., 2021; TAN; LANGENKÄMPER; NATTKEMPER, 2022). Ao final, foram geradas 1749 novas imagens que, somadas com imagens já existentes, compuseram um conjunto de dados com 2544 imagens. Essas imagens, juntamente de suas respectivas máscaras foram divididas em dois subconjuntos nas proporções de 80% e 20%, para a realização do treinamento e validação, respectivamente.

### **3.1 Treinamento, validação e avaliação dos modelos**

Inicialmente, foram avaliadas três diferentes arquiteturas de redes neurais convolucionais, sendo eles a U-Net, FPN e a LinkNet. Em todas as arquiteturas foi aplicado o *backbone* VGG-16, que, dentre as diversas funções, é responsável pela extração das informações das imagens. Para a otimização do treinamento dos modelos realizou-se uma redução da dimensionalidade das imagens para 256 x 256 pixels. Além disso, foi utilizado aprendizado de transferência com a finalidade de otimizar o treinamento e diminuir a probabilidade de ocorrência de *overfitting*. Foram necessárias 50 interações para o treinamento das redes neurais com um *batch size* igual a oito. O restante da construção das arquiteturas, tais como número convoluções, quantidade de camadas *encoder* e *decoder*, *padding operation* e funções de ativação basearam-se no trabalho de Garcia-Pedreiro et al (2020).

As entradas do treinamento dos modelos foram compostas das imagens e suas respectivas máscaras a qual contém as identificações das classes que as redes neurais devem utilizar para o aprendizado. Ao final, cada modelo retorna uma saída da predição das classes em uma máscara denominada máscara de predição.

Para a avaliação e comparação dos modelos utilizou-se a intercessão sobre união (IoU), também conhecido como Índice de Jaccard ou Coeficiente de similaridade de Jaccard, conforme recomendado por (MÜLLER; SOTO-REY; KRAMER, 2022). O IoU mede a sensibilidade e a precisão da previsão, pelo qual pontua a sobreposição entre a segmentação

prevista e a verdadeira. Além disso, conforme a Equação 1, ele penaliza os falsos positivos, o que é muito comum para conjuntos de dados desbalanceados.

$$IoU = \frac{TP}{TP+FP+FN} \quad \text{Equação 1}$$

Em que: TP são os verdadeiros positivos; FP são os falsos positivos e; FN são os falsos negativos.

As análises foram realizadas sobre as classes de *background*, madeira e rachadura. A seleção do melhor modelo se deu em função dos maiores IoU da classe das rachaduras e IoU médio. Na Figura 10 encontra-se um resumo dos procedimentos utilizados para a obtenção do modelo final.

Além do IoU, foi utilizada uma análise visual das máscaras de predição, conforme recomendado por Müller et al. (2022), sobre um conjunto de 20 imagens obtidas do campo. Esse método consiste na comparação visual das segmentações previstas e anotadas e permite acompanhar o real desempenho da previsão dos modelos (ou arquitetura). Em geral, com o emprego dessa abordagem, problemas como viés estatístico e a superestimativa do poder preditivo de métricas computadas inadequadamente, ou incorretamente, são visualizados. A rotina utilizada para as tarefas de ampliação do banco de dados, treinamento do modelo e sua avaliação encontram-se disponíveis no GitHub<sup>7</sup> para fins de consulta.

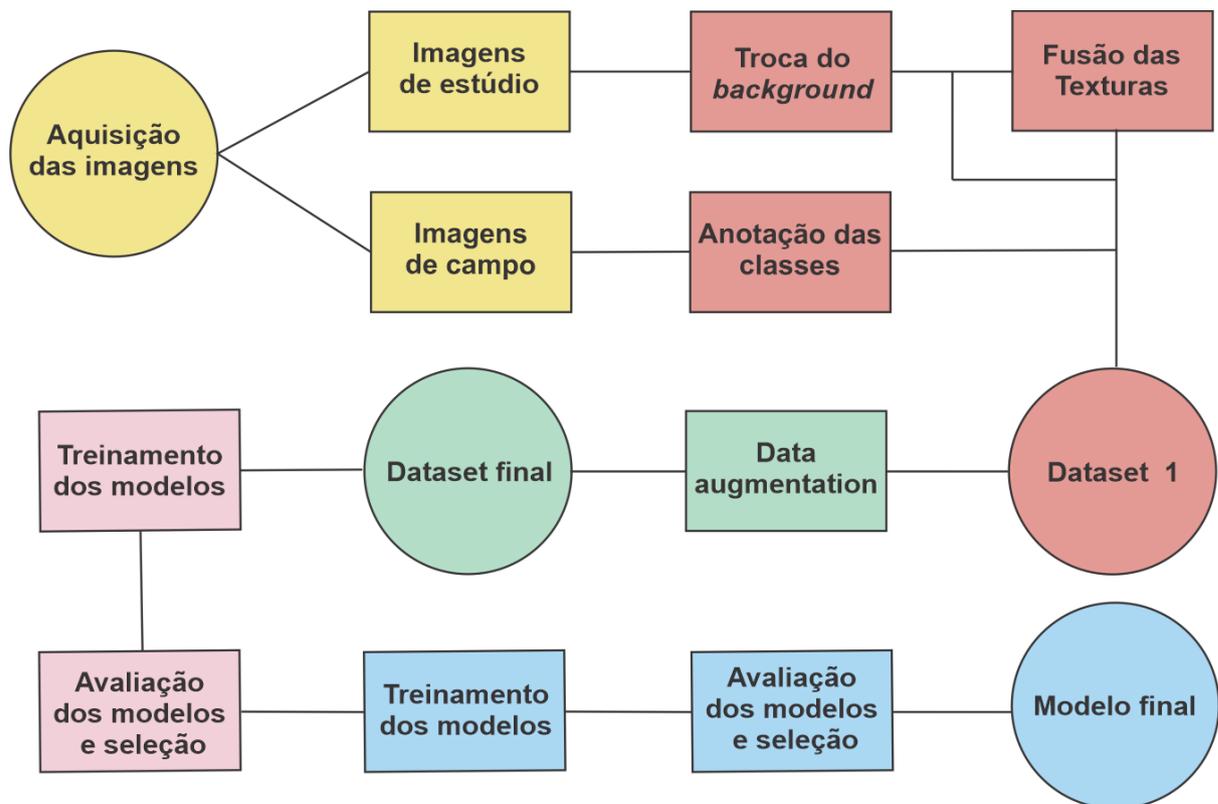
Sobre as segmentações previstas (máscaras) e estimadas (máscaras de predição) das 20 imagens de campo empregadas para a análise visual foi calculada a porcentagem da área afetada por rachaduras mediante a Equação 2. Para a avaliação do poder preditivo do modelo para o cálculo de área empregou-se as correlações de Spearman, coeficiente de determinação ( $R^2$ ), a raiz do erro médio (RMSE) e o percentual erro absoluto médio (MAPE) (HUANG et al., 2021). Os valores obtidos das áreas afetadas por rachadura foram comparados via teste de qui-quadrado à 95% de probabilidade, a fim de averiguar se há diferenças estatísticas entre a área real e a predita. Para a recomendação do modelo para sua aplicação no cotidiano espera-se que não haja diferenças estatísticas entre as áreas previstas e estimadas.

$$AR(\%) = \frac{T_{pr}}{T_{pm}} * 100 \quad \text{Equação 2}$$

<sup>7</sup> [https://github.com/Luigicarlo01/Gerador-de-Imagens-sint-ticas/blob/main/Unet\\_rachadura.ipynb](https://github.com/Luigicarlo01/Gerador-de-Imagens-sint-ticas/blob/main/Unet_rachadura.ipynb)

Em que:  $AR$  é a área rachada em %;  $T_{pr}$  é a total de pixel atribuída à classe das rachaduras;  $T_{pm}$  é a total de pixel atribuídas à madeira.

Figura 10 - Esquema dos processos para a obtenção dos modelos de visão computacional aplicados nesse trabalho. Os círculos e retângulos correspondem aos resultados e processos, respectivamente. As cores amarela, vermelho, verde, rosa e azul das formas relacionam-se, respectivamente, com a etapa de aquisição das imagens, confecção de imagens sintéticas, ampliação do banco de dados (*data augmentation*), treinamento/avaliação dos modelos e a seleção do melhor modelo.



Fonte: Do Autor (2023).

#### 4 RESULTADOS E DISCUSSÃO

Os modelos derivados das arquiteturas empregadas nesse trabalho obtiveram desempenhos similares para as classes. Dentre elas, o *background* apresentou os maiores valores para o IoU, entre todas as arquiteturas, seguido pela tora e rachadura, respectivamente (Tabela 2).

Tabela 2 - IoU do processo de validação dos modelos U-Net, FPN e LinkNet para as classes das rachaduras, madeira e *background*.

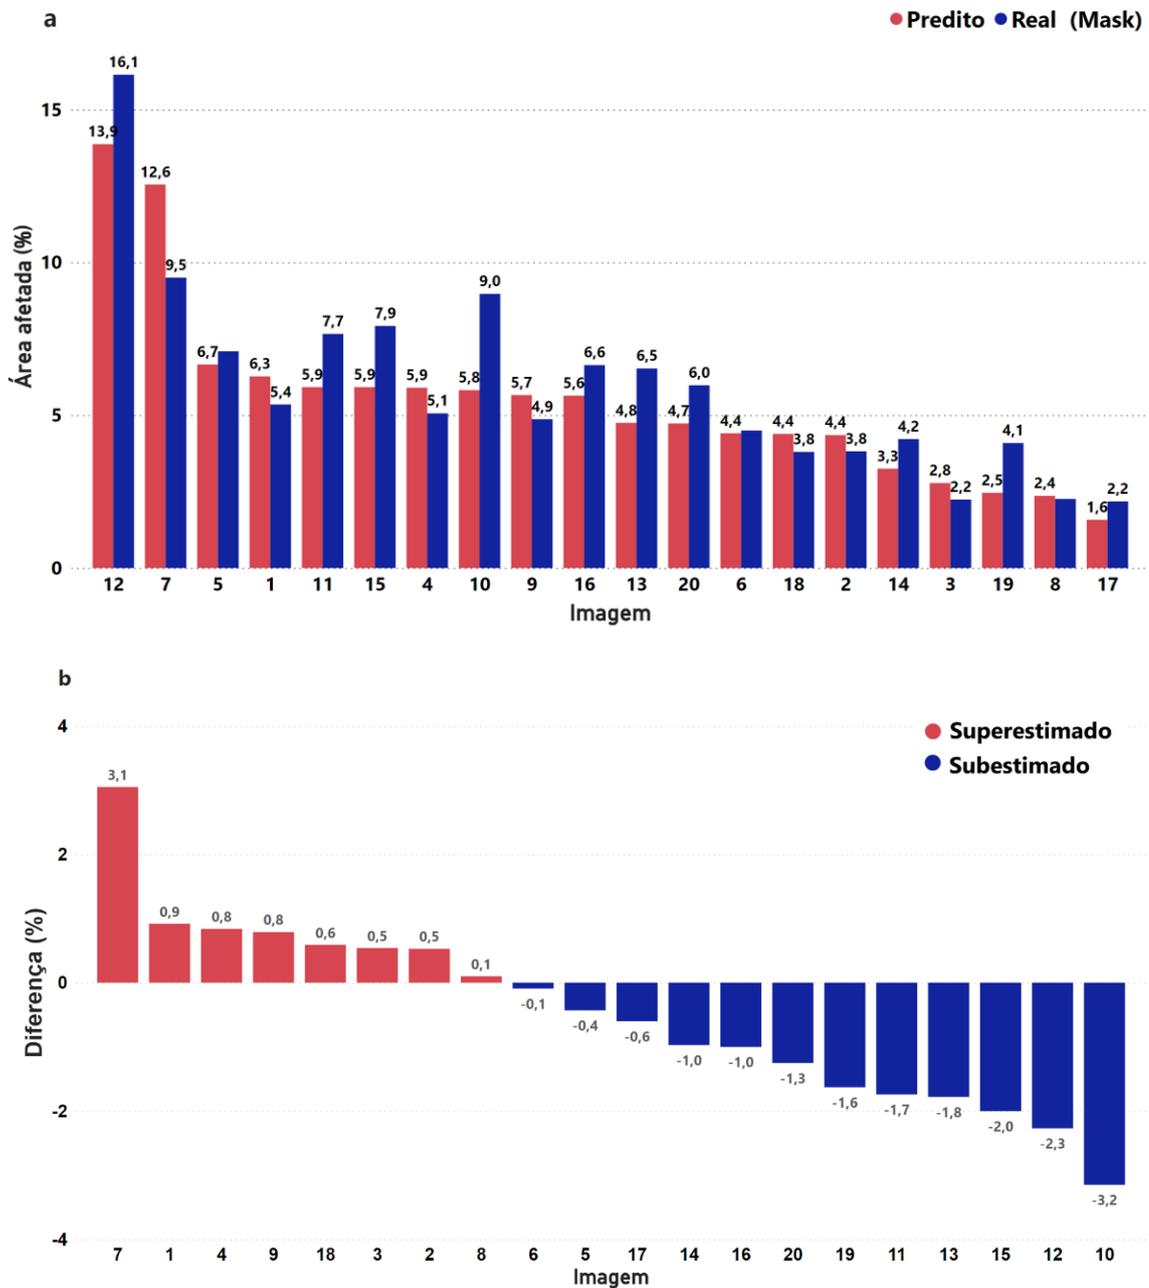
<b>Classes</b>	<b>U-Net</b>	<b>FPN</b>	<b>LinkNet</b>
<b>Rachadura</b>	0,6260	0,6202	0,6209
<b>Madeira</b>	0,9354	0,9306	0,9339
<b>Background</b>	0,9811	0,9791	0,9805
<b>Média</b>	0,8475	0,8433	0,8451

Fonte: Do Autor (2023).

Os baixos valores de IoU encontrados para as rachaduras podem ser consequência do processo de redução da resolução espacial das imagens. Durante esse processo, há a perda de pequenos detalhes, como no caso de rachaduras pequenas. Entretanto, essa redução não afeta a informação das máscaras de anotação usadas para o treinamento. Com isso, a informação da localização das rachaduras é mantida nas camadas de treinamento. Isso gera uma dificuldade de associação das pequenas rachaduras entre as máscaras e a imagem, dificultando o reconhecimento de padrões dos pixels relacionados à pequenas rachaduras. Dessa maneira, a predição das menores rachaduras pode ser comprometida. Como o cálculo do IoU leva em consideração os acertos e os erros de predição para cada pixel das imagens, à medida que a previsão da classe de um pixel é equivocada o IoU tende a se reduzir. Como os modelos aqui gerados apresentaram dificuldade em predizer pequenas rachaduras (Figura 12 e Figura 13), seus IoU para tal classe tendem a apresentar menores valores.

Dentre os modelos gerados neste trabalho, a U-Net apresentou valores ligeiramente maiores do IoU na validação para todas as classes em relação aos outros modelos. Tal informação foi utilizada para a sua seleção para a continuidade das análises. É importante salientar que não é possível afirmar categoricamente que há a sua superioridade em relação aos demais modelos. Além disso, comparações de modelos U-Net, FPN e Linknet para outras variáveis, como de xilema denotam certa proximidade dos valores do IoU's das classes entre os modelos tal qual aqui observado (GARCIA-PEDRERO et al, 2020).

Figura 11 - Análise do valor real e estimado para as rachaduras segundo a arquitetura U-Net. (a) Área da rachadura por imagem, (b) Diferença entre a área predita e a real.



Fonte: Do Autor (2023).

Após a seleção do modelo baseado na arquitetura U-Net, sob um conjunto de 20 imagens foi realizada uma análise visual (Figuras 12, 13, 14) e o cálculo da área rachada (real e estimada) na secção da tora de *Eucalyptus spp* (Figura 11-a). A estimativa da área afetada por rachadura tendeu a ser subestimada. Das 20 imagens utilizadas 12 apresentaram um valor percentual de rachadura menor que o real valor da segmentação (Figura 11-b). A provável

explicação para esse fenômeno é a dificuldade do modelo em estimar as rachaduras de pequena dimensão para essas imagens (Figura 12).

Ao analisar as imagens das toras que apresentaram maior grau de subestimativa da área rachada (Figura 12), nota-se que o modelo teve dificuldade de prever as pequenas rachaduras. A maior diferença entre as máscaras do valor real e estimado é a ausência de pequenas rachaduras nas máscaras de predição (estimado). Assim, o valor da área calculada para as máscaras de saídas é menor que o valor da área real (Figura 11-a).

Embora o modelo tenha dificuldade em prever pequenas rachadura, conforme as imagens da Figura 12, o seu desempenho para rachaduras maiores, por vez, é satisfatório. O modelo foi capaz de detectar todas as rachaduras de maior dimensão na madeira. Contudo, em algumas regiões das rachaduras nota-se pequenas distorções em suas predições, seja por superestimativa (pequena dilatação de rachaduras na predição em algumas regiões da máscara, Figura 12 - Imagens 10 e 15) ou por subestimativa/ perda de detalhes (Figura 12- Imagens 12,13).

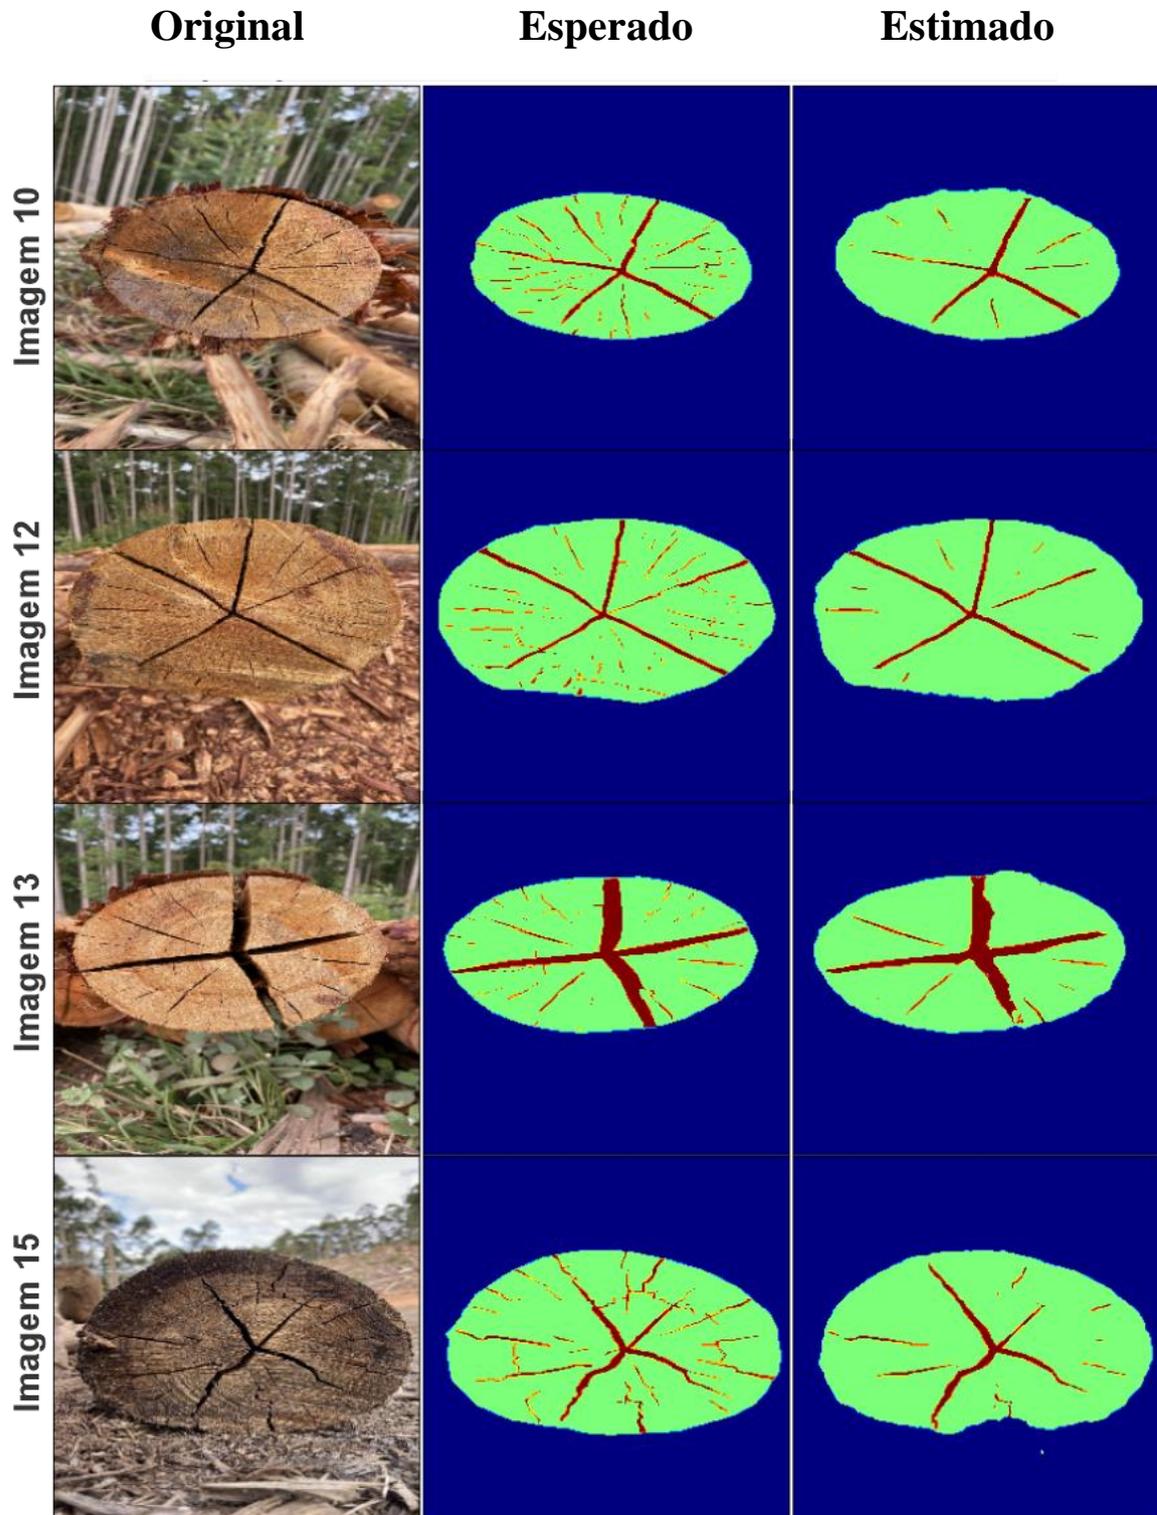
A ocorrência de superestimativa em maiores rachaduras pode ser a explicação do porquê as imagens 1, 2, 3, 4, 7, 9, 18, apresentam um maior valor para a estimativa em relação ao valor real da porcentagem de área rachada (Figura 11-a, b). As imagens apresentadas na Figura 13 alinham-se com as afirmações feitas para a Figura 12, sobretudo, no quesito de superestimativa para as rachaduras de maior dimensão. Nota-se, nas camadas de predição, uma superestimativa de tais rachaduras. Embora o modelo tenha sido capaz de detectar as rachaduras de maior dimensão, ele apresentou uma leve tendência em dilatá-las no processo de predição. Ainda que haja perda de pixels em rachaduras menores a superestimativa nas maiores rachaduras suplantam esse déficit, levando à superestimativa. Além disso, é importante ressaltar que parte do valor superestimado para a Imagem 7 da Figura 13 pode ser explicado pela presença de falsos positivos<sup>8</sup> na camada de predição.

De modo geral o modelo U-Net apresentou um bom desempenho para a estimativa das áreas rachadas. A alta correlação ( $CORR = 0,89$ ) entre os valores reais e estimados juntamente um bom coeficiente de determinação ( $R^2 = 0,80$ ) indicam uma alta previsibilidade do modelo. Ademais, o RMSE aponta uma variação média de 1,49 do valor estimado em relação a valor verdadeiro ao passo que para o MAPE tal variação corresponde, em média, 23,71% em relação ao valor verdadeiro.

---

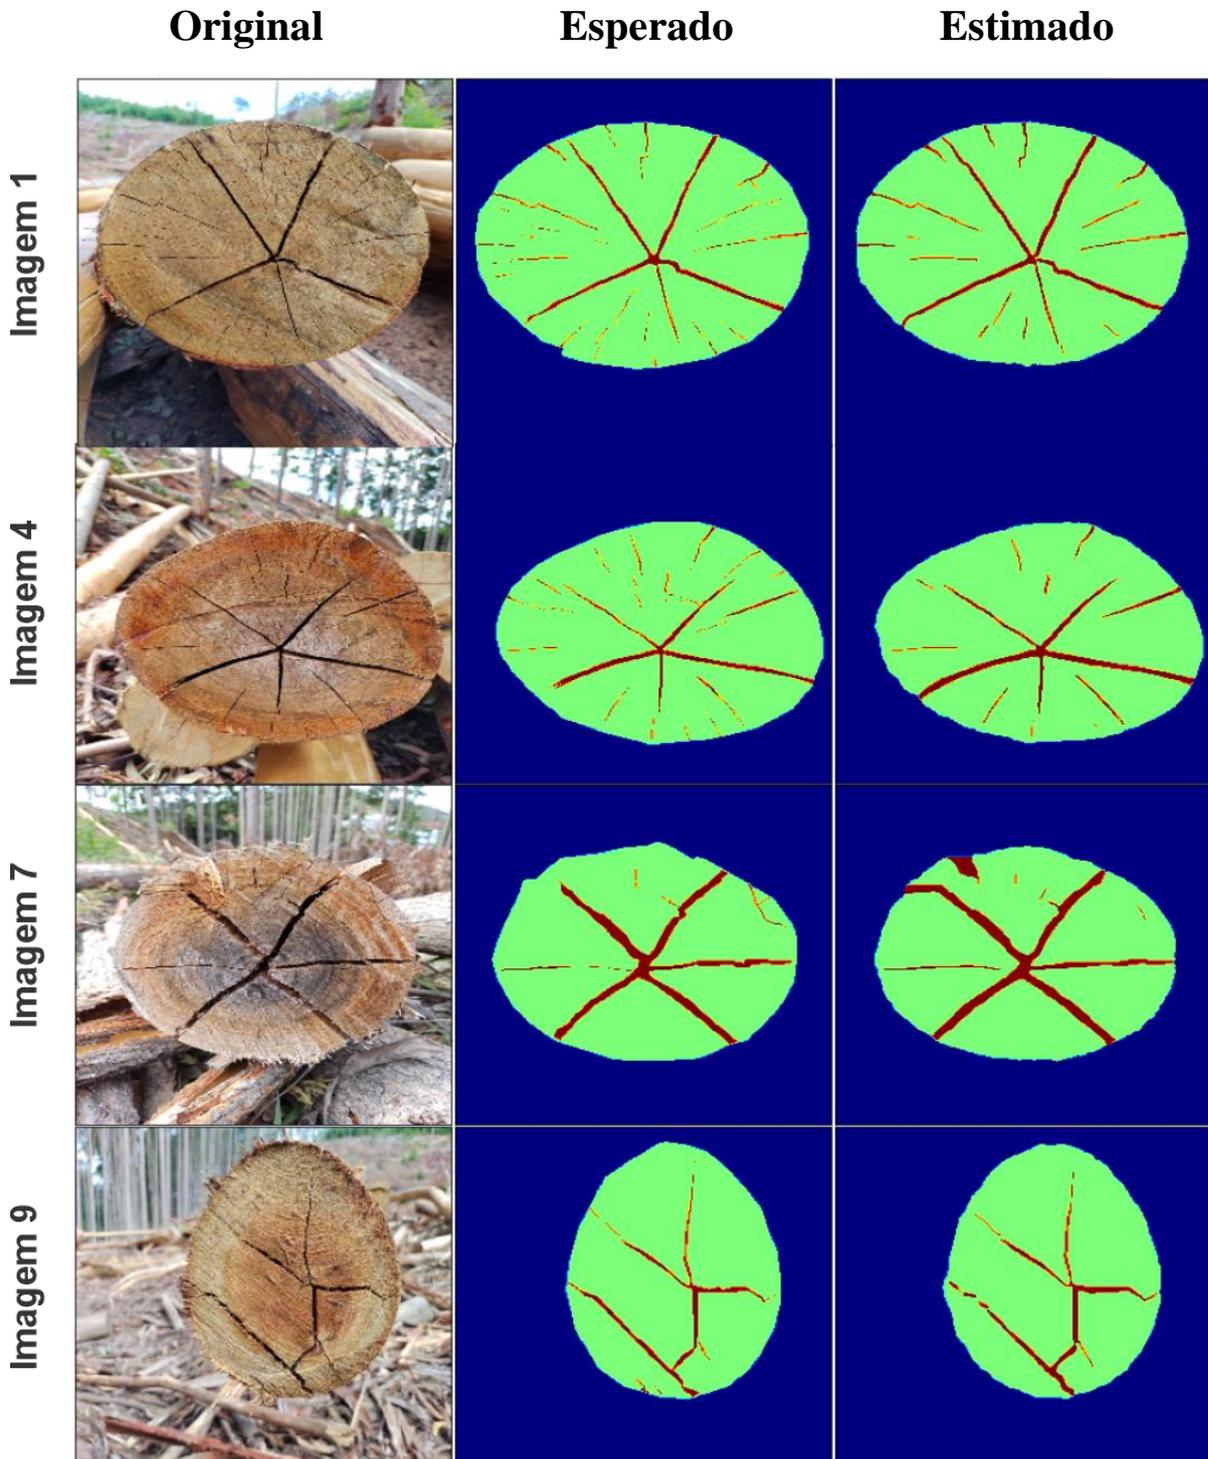
<sup>8</sup> Previsões de rachaduras que não existem no objeto original

Figura 11 - Imagens de toras com suas máscaras esperadas e estimadas pelo modelo U-Net com maior viés de subestimativa dentro as 20 empregadas. Nas máscaras as cores azul, verde e vermelho referem-se, respectivamente, ao *background*, a tora e as rachaduras.



Fonte: Do Autor (2023).

Figura 12 - Imagens de toras com suas máscaras esperadas e estimadas pelo modelo U-Net com maior viés de superestimativa dentro as 20 empregadas. Nas máscaras as cores azul, verde e vermelho referem-se, respectivamente, ao *background*, a tora e as rachaduras.



Fonte: Do Autor (2023).

Embora o modelo U-Net apresente um viés (subestimativa ou superestimativa) para a área das rachaduras em algumas imagens, ainda sim, esse fato não limita a sua aplicação. Ao

se aplicar o teste de qui quadrado, à 95% de probabilidade, não são observadas diferenças entre as áreas rachadas reais com as estimadas pelo modelo, já que o valor do teste foi igual a 6.08, menor que o valor de 10,12 tabelado com 19 graus de liberdade para um alfa de 0.05. Sendo assim, a sua utilização para tarefas de quantificação de áreas rachadas em secção de toras é exequível e sua aplicação para programas de melhoramento pode ser sugeridas.

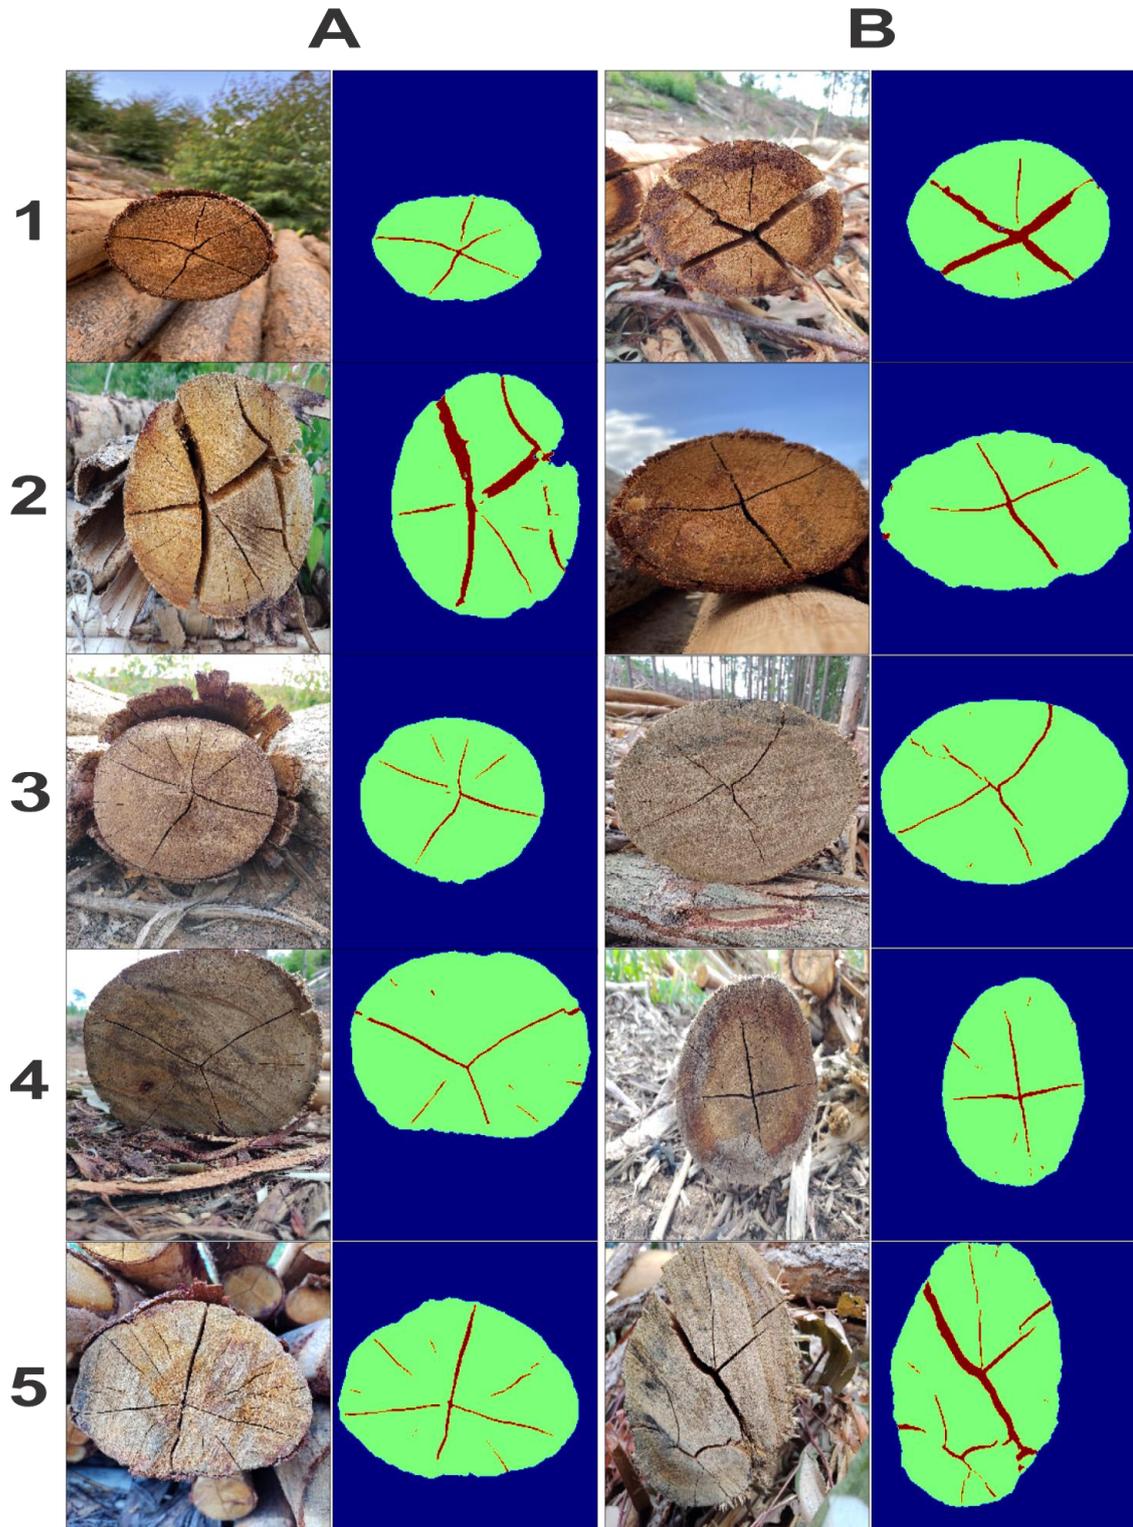
O modelo U-Net teve alto desempenho na detecção de toras nos mais variados cenários. Ele se mostrou versátil ao detectar as toras e predizer suas máscaras em cenários de alto contraste (tora/fundo (*background*)), como folhas (Figura 14 – 1A, 2A) e céu (Figura 14 - 2B), e em cenários de menor contraste (tora/fundo (*background*)), como chão (Figura 14 - 4A), madeira empilhada (Figura 14 - 1A, 2B), casca e serragem (Figura 14 - 4B e 5B).

Na predição da tora de algumas imagens há a ocorrência de pequenas distorções em relação à imagem original. Essas, por sua vez, ocorrem nas áreas periféricas da tora na máscara de predição e podem ser fruto da dificuldade do modelo em distinguir a casca do lenho, quando estas encontram-se unidas e com texturas similares entre si (Figura 14 2-B). Além disso, o ângulo em que as fotos das toras com rachaduras de grandes proporções são tomadas pode influenciar em sua predição caso parte do *background* seja capturado por entre as rachaduras (Figura 14 - 2A).

Embora a casca unida ao lenho possa influenciar levemente na classificação das toras, nos demais casos, onde há a presença de casca nas imagens, o modelo U-Net apresenta um desempenho satisfatório. Em situações em que uma nítida diferença de textura/contraste entre a casca e a tora é observada, quando essas se encontram ainda unidas, a detecção da tora é satisfatória (Figura 14 - 1A). Do mesmo modo, em situações em que a casca se encontra desprendida da tora, o modelo apresenta alta performance para a classificação da tora (Figura 14 - 3A). No que se concerne sobre este último, uma notória melhoria é observada, sobretudo, quando comparado aos resultados de Moreira (2020), que enfrentou leves dificuldade em relação às cascas desprendidas das toras.

Ainda que haja pequenas variações na predição da tora não há indícios que elas impactem negativamente o resultado. Devido a variação ser restrita somente à borda elas acabam por ser de pequena magnitude em relação à totalidade da tora. Assim, mesmo que haja distorções na máscara de predição o seu impacto para o cálculo da área final é diminuto e insignificante perante o todo.

Figura 14 - Imagens de toras de *Eucalyptus spp.* com rachaduras com suas respectivas máscaras preditas sob diferentes ambientes (*backgrounds*).



Fonte: Do Autor (2023).

Uma das principais áreas que podem se beneficiar com o emprego da arquitetura U-Net é o melhoramento genético florestal com foco em madeira maciça e/ou para laminação.

Conforme apresentado anteriormente, a arquitetura U-Net tem alta capacidade de predição das classes nas imagens, denotando alta acertabilidade e confiabilidade na estimativa das áreas rachadas. Sobre este último ponto, ainda que a arquitetura tenha dificuldade em estimar as pequenas rachaduras, os resultados sugerem que não há diferença entre os valores estimados e os valores reais da área rachada.

Embora o índice de coincidência de seleção de clones, considerando os valores reais e estimados, não tenha sido abordado neste trabalho, algumas especulações podem ser imputadas. Moreira (2020) ao comparar abordagens de visão computacional frente à métodos de avaliação manual e por nota constatou que não há diferença estatística entre os métodos. Embora elas sejam equivalentes, do ponto de vista estatístico, diferença sutis no ranqueamento dos clones entre os métodos são observadas, ao passo que um alto índice de coincidência entre os métodos é obtido (77,50 %). É esperado que as observações feitas por Moreira (2020) se reproduzam em situações na qual ocorra o emprego da arquitetura U-Net. Assim, ainda que não haja diferenças estatísticas entre as predições da arquitetura e o valor real, ao se aplicar o U-Net, é esperado a ocorrência de pequenas alterações de ranqueamentos dos clones (ou progênies) frente o valor real da área das rachaduras, mantendo, sobretudo, um alto índice de coincidência de seleção.

Além dos pontos já citados, um outro ponto positivo da U-Net para a fenotipagem de rachadura de madeiras é a economia de tempo. A arquitetura U-Net implementada nesse trabalho leva, em média, 0,6 segundos para a predizer e quantificar a área afetada por rachaduras. Abordagens similares de quantificação de rachadura, como a proposta por Moreira (2020), já indicava uma redução de tempo significativa quando comparado à métodos de medição manual. Todavia, o método apresentado por ele ainda despendia de muitas horas visto a necessidade de obter as imagens em estúdio. O tempo para a obtenção dos discos nas secções das toras, aliados à tarefa de limpeza configuram-se como processos que despendem tempo e passíveis de otimização. Com a possibilidade de análise de imagens em ambiente de campo um considerável tempo pode ser economizado, visto que etapas são cortadas, além da rapidez em se gerar os resultados.

Até esse presente ponto é evidente que, apesar de seu bom desempenho para a classificação e quantificação das rachaduras, o modelo baseado na arquitetura U-Net apresenta pontos que podem ser melhorados no tocante à pequenas rachaduras e cascas aderidas à tora com baixo contraste entre si. Ainda que as pequenas rachaduras nas toras das imagens avaliadas neste trabalho não influenciaram na estimativa da área rachada é possível que em algumas situações uma diferença estatística possa ser capitada. As toras das imagens

aqui testadas eram, em sua maioria, compostas por grandes rachaduras, as quais são responsáveis por grande parte da área afetada. Assim, a incapacidade de detecção de algumas pequenas rachaduras não se traduziu em uma diferença significativa para área total estimada. Entretanto, é possível que, nos casos em que a tora seja afetada exclusivamente por pequenas rachaduras, a área estimada final seja diferente da área real, visto a dificuldade do modelo perante as pequenas rachaduras. Todavia, essa alegação tange o campo de especulação e não foi aqui abordada.

O problema de detecção das pequenas rachaduras pode ser minimizado ou até resolvido por completo com a adesão de alguns procedimentos. A aplicação de menores intensidades de redução de dimensionalidade podem manter maiores detalhes nas fotos, e por consequência, conservar os detalhes inerentes à pequenas rachaduras. Deste modo, a rede neural tem subsídio para identificar e aprender os detalhes das pequenas rachaduras. Entretanto, é importante se atentar ao fato de que imagens com maiores dimensões demanda um maior tempo e poder computacional para o treinamento dos modelos, o que, a depender da situação, pode não justificar o seu uso.

Um outro ponto que pode trazer melhoria significantes é a escolha do *backbone* ideal. Em resumo, há uma infinidade de *backbones* que, a depender da tarefa e do modelo, podem trazer significantes melhorias. Cada *backbone* possui suas peculiaridades no quesito arquitetura e quantidades de parâmetros. Elharrouss et al. (2022), apresenta uma discussão pertinente sobre a escolha dos *backbones* sugerindo que aqueles que apresentam maiores quantidades de parâmetros trazem uma maior precisão na extração das informações das imagens. Como a precisão do modelo é dependente da extração dos recursos das imagens, espera-se que outros *backbones* possam ter uma maior sensibilidade para a classificação das pequenas rachaduras e para lidar melhor com o contraste de casca/madeira. Deste modo, trabalhos futuros podem basear-se sobre tal fato para implementação de melhorias no modelo de detecção de pequenas rachaduras.

## **5 CONCLUSÃO**

O modelo U-Net não possui desempenho superior à Linknet e FPN para a fenotipagem de rachaduras de toras em campo. A equidade estatística das estimativas da área das rachaduras em relação à área real, aliados com a rapidez em se obter os resultados, estimulam o emprego do modelo gerado a partir da arquitetura U-Net em tarefas de avaliação de rachaduras em programas de melhoramento florestal.

## REFERÊNCIAS

- ABED, S. H.; AL-WAISY, A. S.; MOHAMMED, H. J.; AL-FAHDAWI, S. A modern deep learning framework in robot vision for automated bean leaves diseases detection. **International Journal of Intelligent Robotics and Applications**, v. 5, n. 2, p. 235–251, 30 jun. 2021. doi: 10.1007/s41315-021-00174-3.
- ADEL, M.; WOLF, D.; VOGRIG, R.; HUSSON, R. Evaluation of colour spaces in computer vision application of wood defects detection. Em: Proceedings of IEEE Systems Man and Cybernetics Conference - SMC, **Anais...IEEE**, 1993. doi: 10.1109/ICSMC.1993.384922.
- ALSENAN, A.; YOUSSEF, B. ben; ALHICHRI, H. A Deep Learning Model based on MobileNetV3 and UNet for Spinal Cord Gray Matter Segmentation. Em: 2021 44th International Conference on Telecommunications and Signal Processing (TSP), **Anais...IEEE**, 26 jul. 2021. doi: 10.1109/TSP52935.2021.9522652.
- ASSIS, T. F. de. Aspecto do melhoramento de Eucalyptus para obtenção de produtos sólidos de madeira. In: TÉCNICAS DE ABATE, PROCESSAMENTO E UTILIZAÇÃO DA MADEIRA DE EUCALIPTO, 1999, Viçosa. Workshop [...]. Viçosa: DEF, 1999. p. 61-72.
- BACKES, A. R. & Sá Junior, J. J. M. 2016Introdução à visão Computacional usando MATLAB®(Introduction to theComputational Using MATLAB®). Alta Books Ed., Brazil.
- BATISTA, D. C.; KLITZKE, R. J.; SANTOS, C. V. T. Basic density and retractibility of wood clones of three Eucalyptus species. p. 665–675, 2010.
- ČAKŠS, R.; ZELTIŇŠ, P.; ČAKŠA, L.; ZEPS, M.; JANSONS, Ā. The Effects of Frost Cracks and Large Poplar Borer Damage on Stem Rot in Hybrid Aspen (*Populus tremula* L. × *Populus tremuloides* Michx.) Clones. **Forests**, v. 13, n. 4, p. 593, 10 abr. 2022. doi: 10.3390/f13040593.
- CASTRO, C. A. de O.; RESENDE, R. T.; BHERING, L. L.; CRUZ, C. D. Brief history of Eucalyptus breeding in Brazil under perspective of biometric advances. **Ciência Rural**, v. 46, n. 9, p. 1585–1593, 16 jun. 2016. doi: 10.1590/0103-8478cr20150645.
- CHANG, Z.; CAO, J.; ZHANG, Y. A novel image segmentation approach for wood plate surface defect classification through convex optimization. **Journal of Forestry Research**, v. 29, n. 6, p. 1789–1795, 5 nov. 2018a. doi: 10.1007/s11676-017-0572-7.
- CHANG, Z.; CAO, J.; ZHANG, Y. A novel image segmentation approach for wood plate surface defect classification through convex optimization. **Journal of Forestry Research**, v. 29, n. 6, p. 1789–1795, 5 nov. 2018b. doi: 10.1007/s11676-017-0572-7.
- CHEN, F.-C.; JAHANSHAHI, M. R. NB-CNN: Deep Learning-Based Crack Detection Using Convolutional Neural Network and Naïve Bayes Data Fusion. **IEEE Transactions on Industrial Electronics**, v. 65, n. 5, p. 4392–4400, maio 2018. doi: 10.1109/TIE.2017.2764844.
- CUNHA, A. B. da; FRANÇA, M. C.; ALMEIDA, C. C. F. de; GORSKI, L.; CRUZ, R. C. da; SANTOS, D. dos. AVALIAÇÃO DO RENDIMENTO EM MADEIRA SERRADA DE *Eucalyptus benthamii* E DE *Eucalyptus grandis* POR MEIO DO DESDOBRO TANGENCIAL E RADIAL. **FLORESTA**, v. 45, n. 2, p. 241, 19 ago. 2014. doi: 10.5380/uf.v45i2.32570.
- DIVYANTH, L. G.; AHMAD, A.; SARASWAT, D. A two-stage deep-learning based segmentation model for crop disease quantification based on corn field imagery. **Smart Agricultural Technology**, v. 3, p. 100108, fev. 2022. doi: 10.1016/j.atech.2022.100108.

ELHARROUSS, O.; AKBARI, Y.; ALMAADEED, N.; AL-MAADEED, S. Backbones-Review: Feature Extraction Networks for Deep Learning and Deep Reinforcement Learning Approaches. 16 jun. 2022.

ESGARIO, J. G. M.; DE CASTRO, P. B. C.; TASSIS, L. M.; KROHLING, R. A. An app to assist farmers in the identification of diseases and pests of coffee leaves using deep learning. **Information Processing in Agriculture**, v. 9, n. 1, p. 38–47, mar. 2021. doi: 10.1016/j.inpa.2021.01.004.

FONTI, P.; MACCHIONI, N. Ring shake in chestnut: Anatomical description, extent and frequency of failures. **Annals of Forest Science**, v. 60, n. 5, p. 403–408, jul. 2003. doi: 10.1051/forest:2003032.

FONTI, P.; MACCHIONI, N.; THIBAUT, B. Ring shake in chestnut. **Annals of Forest Science**, v. 59, n. 2, p. 129–140, 2002. doi: 10.1051/forest:2002007.

FUKUSHIMA, K.; MIYAKE, S. Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Visual Pattern Recognition. Em: **Lecture Notes in Biomathematics**. 1. ed. Berlin: Springer, 1982. 45 p. 267–285. 1982.

GARCIA, J. N. Log end splitting and improvement in sowing *Eucalyptus grandis*. In: THE FUTURE OF *Eucalyptus* FOR WOOD PRODUCTS, 2000, LAUNCESTON. Proceedings... LAUNCESTON. **IUFRO**, 2000, p. 113-123.

GAO, F.; YUE, P.; CAO, Z.; ZHAO, S.; SHANGGUAN, B.; JIANG, L.; HU, L.; FANG, Z.; LIANG, Z. A multi-source spatio-temporal data cube for large-scale geospatial analysis. **International Journal of Geographical Information Science**, p. 1–32, 14 jun. 2022. doi: 10.1080/13658816.2022.2087222.

GAO, M.; QI, D.; MU, H.; CHEN, J. A Transfer Residual Neural Network Based on ResNet-34 for Detection of Wood Knot Defects. **Forests**, v. 12, n. 2, p. 212, 11 fev. 2021a. doi: 10.3390/f12020212.

GAO, M.; WANG, F.; SONG, P.; LIU, J.; QI, D. BLNN: Multiscale Feature Fusion-Based Bilinear Fine-Grained Convolutional Neural Network for Image Classification of Wood Knot Defects. **Journal of Sensors**, v. 2021, p. 1–18, 17 ago. 2021b. doi: 10.1155/2021/8109496.

GRABNER, M.; CHERUBINI, P.; ROZENBERG, P.; HANNRUP, B. Summer drought and low earlywood density induce intra-annual radial cracks in conifers. **Scandinavian Journal of Forest Research**, v. 21, n. 2, p. 151–157, 22 abr. 2006a. doi: 10.1080/02827580600642100.

GRABNER, M.; CHERUBINI, P.; ROZENBERG, P.; HANNRUP, B. Summer drought and low earlywood density induce intra-annual radial cracks in conifers. **Scandinavian Journal of Forest Research**, v. 21, n. 2, p. 151–157, 22 abr. 2006b. doi: 10.1080/02827580600642100.

GRABNER, M.; GIERLINGER, B.; WIMMER, R. Mechanism leading to intra-ring radial cracks in young spruce trees. (Kaennel Dobbertin M, Bräker O.U., Eds.) Em: International Conference Tree Rings and People, 1, Davos. **Anais...** Davos: Swiss Federal Research Institute WSL, 2001.

GU, I. Y.-H.; ANDERSSON, H.; VICEN, R. Wood defect classification based on image analysis and support vector machines. **Wood Science and Technology**, v. 44, n. 4, p. 693–704, 18 nov. 2010. doi: 10.1007/s00226-009-0287-9.

GÜNDER, M.; ISPIZUA YAMATI, F. R.; KIERDORF, J.; ROSCHER, R.; MAHLEIN, A.-K.; BAUCKHAGE, C. Agricultural plant cataloging and establishment of a data framework from UAV-based crop images by computer vision. **GigaScience**, v. 11, 17 jun. 2022. doi: 10.1093/gigascience/giac054.

- HE, T.; LIU, Y.; XU, C.; ZHOU, X.; HU, Z.; FAN, J. A Fully Convolutional Neural Network for Wood Defect Location and Identification. **IEEE Access**, v. 7, p. 123453–123462, 2019. doi: 10.1109/ACCESS.2019.2937461.
- HE, T.; LIU, Y.; YU, Y.; ZHAO, Q.; HU, Z. Application of deep convolutional neural network on feature extraction and detection of wood defects. **Measurement**, v. 152, p. 107357, fev. 2020. doi: 10.1016/j.measurement.2019.107357.
- HINTON, G. E.; SRIVASTAVA, N.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. R. Improving neural networks by preventing co-adaptation of feature detectors. 3 jul. 2012.
- HITTAWA, M. M.; MUDDAMSETTY, S. M.; SIDIBE, D.; MERIAUDEAU, F. Multiple features extraction for timber defects detection and classification using SVM. Em: 2015 IEEE International Conference on Image Processing (ICIP), **Anais...IEEE**, set. 2015. doi: 10.1109/ICIP.2015.7350834
- HUANG, C.; SHEN, Y.; CHEN, Y.; CHEN, H. A novel hybrid deep neural network model for short-term electricity price forecasting. **International Journal of Energy Research**, v. 45, n. 2, p. 2511–2532, 9 fev. 2021. doi: 10.1002/er.5945.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. **The Journal of Physiology**, v. 160, n. 1, p. 106–154, 1 jan. 1962. doi: 10.1113/jphysiol.1962.sp006837.
- JULLIEN, D.; WIDMANN, R.; LOUP, C.; THIBAUT, B. Relationship between tree morphology and growth stress in mature European beech stands. **Annals of Forest Science**, v. 70, n. 2, p. 133–142, 2 mar. 2013. doi: 10.1007/s13595-012-0247-7.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. **Communications of the ACM**, v. 60, n. 6, p. 84–90, 24 maio 2017. doi: 10.1145/3065386.
- KUBLER, H. FROST CRACKS IN STEMS OF TREES. **Arboricultural Journal**, v. 12, n. 2, p. 163–175, 27 maio 1988. doi: 10.1080/03071375.1988.9746783.
- LAMPINEN, J.; SMOLANDER, S. SELF-ORGANIZING FEATURE EXTRACTION IN RECOGNITION OF WOOD SURFACE DEFECTS AND COLOR IMAGES. Em: PIETIKÄINEN, M.; PAU, L. F. (Ed.). **Machine Perception and Artificial Intelligence**. 22. ed. Finlândia: World scientific, 1996. 22 p. 97–113. 1996.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 28 maio 2015. doi: 10.1038/nature14539.
- LECUN, Y.; BOSER, B.; DENKER, J. S.; HENDERSON, D.; HOWARD, R. E.; HUBBARD, W.; JACKEL, L. D. Backpropagation Applied to Handwritten Zip Code Recognition. **Neural Computation**, v. 1, n. 4, p. 541–551, dez. 1989. doi: 10.1162/neco.1989.1.4.541.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. doi: 10.1109/5.726791.
- LI, C.; ZHANG, Y.; TU, W.; JUN, C.; LIANG, H.; YU, H. Soft measurement of wood defects based on LDA feature fusion and compressed sensor images. **Journal of Forestry Research**, v. 28, n. 6, p. 1285–1292, 12 nov. 2017. doi: 10.1007/s11676-017-0395-6.

- LI, Y.; CHEN, J. Computer Vision–Based Counting Model for Dense Steel Pipe on Construction Sites. **Journal of Construction Engineering and Management**, v. 148, n. 1, jan. 2022. doi: 10.1061/(ASCE)CO.1943-7862.0002217.
- LIBBY, W. J.; JUND, E. Variance associated with cloning. **Heredity**, v. 17, n. 4, p. 533–540, nov. 1962. doi: 10.1038/hdy.1962.55.
- LIM, W.-H.; BONAB, M. B.; CHUA, K. H. An Optimized Lightweight Model for Real-Time Wood Defects Detection based on YOLOv4-Tiny. Em: 2022 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS), **Anais.IEEE**, 25 jun. 2022. doi: 10.1109/I2CACIS54679.2022.9815274.
- LIMA, I. L. de; GARCIA, J. N.; PIEDADE, S. M. de S. Rachaduras de extremidades de tora e suas implicações nas rachaduras da madeira serrada. **Scientia Forestalis**, v. 61, p. 13–24, 2002.
- MOHSIN, M.; BALOGUN, O. S.; HAATAJA, K.; TOIVANEN, P. Real-time defect detection and classification on wood surfaces using deep learning. **Electronic Imaging**, v. 34, n. 10, p. 382-1-382–6, 16 jan. 2022. doi: 10.2352/EI.2022.34.10.IPAS-382.
- MONTEIRO, T. C.; LIMA, J. T.; HEIN, P. R. G.; SILVA, J. R. M. da; TRUGILHO, P. F.; ANDRADE, H. B. Efeito dos elementos anatômicos da madeira na secagem das toras de *Eucalyptus Corymbia*. **Scientia Forestalis**, v. 45, n. 115, 1 set. 2017. doi: 10.18671/scifor.v45n115.07.
- MOREIRA, J. **FENOTIPAGEM DE RACHADURA SEM CLONES DE *Eucalyptus* spp.** 2020. Universidade Federal de Lavras , Lavras, 2020.
- MÜLLER, D.; SOTO-REY, I.; KRAMER, F. Towards a Guideline for Evaluation Metrics in Medical Image Segmentation. 10 fev. 2022.
- NANEHKARAN, Y. A.; ZHANG, D.; CHEN, J.; TIAN, Y.; AL-NABHAN, N. Recognition of plant leaf diseases based on computer vision. **Journal of Ambient Intelligence and Humanized Computing**, 4 set. 2020. doi: 10.1007/s12652-020-02505-x.
- NASCIMENTO, T. M. do; MONTEIRO, T. C.; BARAÚNA, E. E. P.; MOULIN, J. C.; AZEVEDO, A. M. Drying of *Eucalyptus*. **BioResources**, v. 14, n. 1, p. 220–233, 2019.
- NISTAL FRANÇA, F. J.; FILGUEIRA AMORIM FRANÇA, T. S.; VIDAURRE, G. B. Effect of growth stress and interlocked grain on splitting of seven different hybrid clones of *Eucalyptus grandis* × *Eucalyptus urophylla* wood. **Holzforschung**, v. 74, n. 10, p. 917–926, 25 out. 2020. doi: 10.1515/hf-2019-0209.
- OLAGUE, G. **Evolutionary Computer Vision**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016.
- PÁDUA, F. A. de; TRUGILHO, P. F.; ROSADO, S. C. da S.; LIMA, J. T.; CARDOSO JÚNIOR, A. A.; OLIVEIRA, A. C. Estimativa de parâmetros genéticos das tensões de crescimento em clones de *Eucalyptus*. **Scientia Forestalis**, v. 66, p. 152–160, 2004.
- PAN, L.; ROGULIN, R.; KONDRASHEV, S. Artificial neural network for defect detection in CT images of wood. **Computers and Electronics in Agriculture**, v. 187, p. 106312, ago. 2021. doi: 10.1016/j.compag.2021.106312.
- PRASANALAKSHMI, B.; MURUGAN, K.; SRINIVASAN, K.; SHRIDEVI, S.; SHAMSUDHEEN, S.; HU, Y.-C. Improved authentication and computation of medical data transmission in the secure IoT using hyperelliptic curve cryptography. **The Journal of Supercomputing**, v. 78, n. 1, p. 361–378, 26 jan. 2022. doi: 10.1007/s11227-021-03861-x.

- RAUT, R.; KRIT, S.; CHATTERJEE, P. **Machine Vision for Industry 4.0**. Boca Raton: CRC Press, 2022.
- RICHTER, C. **Wood Characteristics**. Cham: Springer International Publishing, 2015.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. 18 maio 2015.
- RUSSELL, B. C.; TORRALBA, A.; MURPHY, K. P.; FREEMAN, W. T. LabelMe: A Database and Web-Based Tool for Image Annotation. **International Journal of Computer Vision**, v. 77, n. 1–3, p. 157–173, 31 maio 2008. doi: 10.1007/s11263-007-0090-8.
- RUZ, G. A.; ESTÉVEZ, P. A.; RAMÍREZ, P. A. Automated visual inspection system for wood defect classification using computational intelligence techniques. **International Journal of Systems Science**, v. 40, n. 2, p. 163–172, fev. 2009. doi: 10.1080/00207720802630685.
- SCHACHT, L.; GARCIA, J. N.; VENCOVSKY, R. Variação genética de indicadores de tensão de crescimento em clones de *Eucalyptus urophylla*. **SCIENTIA FORESTALIS**, v. 54, p. 55–68, dez. 1998.
- ŠĚNHOFKA, S.; ZEPS, M.; GAILIS, A.; KĀPOSTIŅŠ, R.; JANSONS, Ā. Development of stem cracks in young hybrid aspen plantations. **Forestry Studies**, v. 65, n. 1, p. 16–23, 1 dez. 2016. doi: 10.1515/fsmu-2016-0008.
- SHAO, M.; NIE, C.; CHENG, M.; YU, X.; BAI, Y.; MING, B.; SONG, H.; JIN, X. Quantifying effect of tassels on near-ground maize canopy RGB images using deep learning segmentation algorithm. **Precision Agriculture**, v. 23, n. 2, p. 400–418, 5 abr. 2022. doi: 10.1007/s11119-021-09842-7.
- SMITH, A. G.; PETERSEN, J.; SELVAN, R.; RASMUSSEN, C. R. Segmentation of roots in soil with U-Net. **Plant Methods**, v. 16, n. 1, p. 13, 8 dez. 2020. doi: 10.1186/s13007-020-0563-0.
- SU, Z.; WANG, Y.; XU, Q.; GAO, R.; KONG, Q. LodgeNet: Improved rice lodging recognition using semantic segmentation of UAV high-resolution remote sensing images. **Computers and Electronics in Agriculture**, v. 196, p. 106873, maio 2022. doi: 10.1016/j.compag.2022.106873.
- SUN, X.; FANG, H.; YANG, Y.; ZHU, D.; WANG, L.; LIU, J.; XU, Y. Robust Retinal Vessel Segmentation from a Data Augmentation Perspective. Em: [s.l.: s.n.] p. 189–198. 2021.
- TAN, M.; LANGENKÄMPER, D.; NATTKEMPER, T. W. The Impact of Data Augmentations on Deep Learning-Based Marine Object Classification in Benthic Image Transects. **Sensors**, v. 22, n. 14, p. 5383, 19 jul. 2022. doi: 10.3390/s22145383.
- TASSIS, L. M.; TOZZI DE SOUZA, J. E.; KROHLING, R. A. A deep learning approach combining instance and semantic segmentation to identify diseases and pests of coffee leaves from in-field images. **Computers and Electronics in Agriculture**, v. 186, p. 106191, jul. 2021. doi: 10.1016/j.compag.2021.106191.
- THOMBARE, S. S. The Future of Car Automation Field with Smart Driverless Technologies. Em: KUMAR, A.; ZURADA JACKED M; GUNJAN, V. K.; BALASUBRAMANIAN, R. (Ed.). **Computation Intelligence in Machine Learning**. 1. ed. Singapore: Springer Nature, 2022. 1 p. 103–121. 2022.
- TODA, Y.; OKURA, F.; ITO, J.; OKADA, S.; KINOSHITA, T.; TSUJI, H.; SAISHO, D. Training instance segmentation neural network with synthetic datasets for crop seed phenotyping. **Communications Biology**, v. 3, n. 1, p. 173, 15 dez. 2020. doi: 10.1038/s42003-020-0905-5.

- TRUGILHO, P. F.; LIMA, J. T.; ROSADO, S. C. da S.; MENDES, L. M.; MORI, F. A.; SOUZA, M. A. M. de. AVALIAÇÃO DA TENSÃO DE CRESCIMENTO EM CLONES DE *Eucalyptus*. **Floresta e Ambiente**, v. 9, p. 38–44, 2002.
- VOULODIMOS, A.; DOULAMIS, N.; DOULAMIS, A.; PROTOPAPADAKIS, E. Deep Learning for Computer Vision: A Brief Review. **Computational Intelligence and Neuroscience**, v. 2018, p. 1–13, 2018. doi: 10.1155/2018/7068349.
- WANG, B.; YANG, C.; DING, Y.; QIN, G. Detection of wood surface defects based on improved YOLOv3 algorithm. **BioResources**, v. 16, n. 4, p. 6766–6780, 20 ago. 2021. doi: 10.15376/biores.16.4.6766-6780.
- WANG, J.; CHEN, L.; ZHANG, J.; YUAN, Y.; LI, M.; ZENG, W. CNN Transfer Learning for Automatic Image-Based Classification of Crop Disease. Em: WANG, Y.; JIANG, Z.; PENG, Y. (Ed.). **Image and Graphics Technologies and Applications**. 1. ed. Singapore: Springer Nature, 2018. 875 p. 319–329. 2018.
- WIMMERS, G. Wood: a construction material for tall buildings. **Nature Reviews Materials**, v. 2, n. 12, p. 17051, 11 dez. 2017. doi: 10.1038/natrevmats.2017.51.
- WU, H.; GU, X. Max-Pooling Dropout for Regularization of Convolutional Neural Networks. (S. Arik, T. Huang, W. Lai, Q. Liu, Eds.) Em: Neural Information Processing, 1., Cham. **Anais...** Cham: Springer, 12 nov. 2015. doi: 10.1007/978-3-319-26532-2\_6.
- YANG, J. L. The impact of log-end splits and spring on sawn recovery of 32-year-old plantation *Eucalyptus globulus* Labill. **Holz als Roh- und Werkstoff**, v. 63, n. 6, p. 442–448, 22 dez. 2005. doi: 10.1007/s00107-005-0035-2.
- YANG, Y.; WANG, H.; JIANG, D.; HU, Z. Surface Detection of Solid Wood Defects Based on SSD Improved with ResNet. **Forests**, v. 12, n. 10, p. 1419, 18 out. 2021. doi: 10.3390/f12101419.
- YANG, Y.; ZHOU, X.; LIU, Y.; HU, Z.; DING, F. Wood Defect Detection Based on Depth Extreme Learning Machine. **Applied Sciences**, v. 10, n. 21, p. 7488, 24 out. 2020. doi: 10.3390/app10217488.
- ZELTIŅŠ, P.; KATREVIČS, J.; GAILIS, A.; MAATEN, T.; BĀDERS, E.; JANSONS, Ā. Effect of Stem Diameter, Genetics, and Wood Properties on Stem Cracking in Norway Spruce. **Forests**, v. 9, n. 9, p. 546, 6 set. 2018. doi: 10.3390/f9090546.
- ZELTIŅŠ, P.; KATREVIČS, J.; GAILIS, A.; MAATEN, T.; JANSONS, J.; JANSONS, Ā. Stem cracks of Norway spruce (*Picea abies* (L.) Karst.) provenances in Western Latvia. **Forestry Studies**, v. 65, n. 1, p. 57–63, 1 dez. 2016. doi: 10.1515/fsmu-2016-0012.
- ZHANG, Y.; XU, C.; LI, C.; YU, H.; CAO, J. Wood defect detection method with PCA feature fusion and compressed sensing. **Journal of Forestry Research**, v. 26, n. 3, p. 745–751, 30 set. 2015. doi: 10.1007/s11676-015-0066-4.
- ZHONG, Z.; ZHENG, L.; KANG, G.; LI, S.; YANG, Y. Random Erasing Data Augmentation. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 34, n. 07, p. 13001–13008, 3 abr. 2020. doi: 10.1609/aaai.v34i07.7000.
- ZOU, K.; CHEN, X.; WANG, Y.; ZHANG, C.; ZHANG, F. A modified U-Net with a specific data argumentation method for semantic segmentation of weed images in the field. **Computers and Electronics in Agriculture**, v. 187, p. 106242, ago. 2021. doi: 10.1016/j.compag.2021.106242.