

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Utilização de imagens para a determinação automatizada da
qualidade de colagem em painéis compensados**

Caio Cesar Faedo de Almeida

Tese apresentada para obtenção do título de Doutor
em Ciências, Programa: Recursos Florestais.
Opção em: Tecnologia de Produtos Florestais

**Piracicaba
2021**

Caio Cesar Faedo de Almeida
Engenheiro Florestal

**Utilização de imagens para a determinação automatizada da qualidade de
colagem em painéis compensados**

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:

Prof. Dr. **GERALDO BORTOLETTO JÚNIOR**

Tese apresentada para obtenção do título de Doutor
em Ciências, Programa: Recursos Florestais.
Opção em: Tecnologia de Produtos Florestais

Piracicaba
2021

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Almeida, Caio Cesar Faedo de

Utilização de imagens para a determinação automatizada da qualidade de colagem em painéis compensados / Caio Cesar Faedo de Almeida. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2021.

133 p.

Tese (Doutorado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Painéis de Madeira 2. Visão computacional 3. Aprendizado profundo
4. *Pinus kesiya* 5. *Eucalyptus urophylla* x *Eucalyptus grandis* I. Título

AGRADECIMENTOS

Primeiramente agradeço à minha família, mas principalmente aos meus pais e irmãos, pelo amor e apoio incondicional durante todo o percurso desta aventura que me lancei em terras tão distantes.

Ao Professor Dr. Geraldo Bortoletto Júnior que, na função de orientador, sempre foi atento aos detalhes e incentivou a realização de todas as atividades visando os melhores padrões de qualidade.

Ao Professor Dr. Carlos de Oliveira Affonso da UNESP do Campus experimental de Itapeva e sua equipe, representada pelo aluno ao Jaymison Cerqueira, que foram fundamentais para atingir os objetivos deste trabalho.

Estendo também meus agradecimentos a todos os professores e funcionários do Programa de Pós-Graduação em Ciências Florestais (PPGRF) e da ESALQ que, de alguma forma participaram desta jornada, em especial ao professor Dr.IVALDO P. Jankowsky e aos funcionários Alex Canale e Carlito Fernandes do LLAPAM e LEMMAD.

À Universidade de São Paulo e a “Escola Superior de Agricultura Luiz de Queiroz” (ESALQ) pelo ensino e pelas oportunidades de crescimento pessoal e profissional disponibilizadas durante o curso de Doutorado.

Aos colegas que se tornaram grandes amigos e permitiram momentos de descontração em nossos encontros após o almoço, facilitando superar os desafios que surgiram pelo caminho.

Dentre estes novos amigos, não posso deixar de agradecer imensamente à minha namorada, Dra. Denise Miguel Petroni, que se tornou minha verdadeira companheira nos momentos alegres e também nos momentos mais difíceis desta jornada e, sem seu amor e incentivo incondicional, este trabalho não haveria de ser realizado da forma como foi.

Também agradeço ao muito solícito Lucas Correia, aqui representado a empresa Si Group Crios, que foi parceira nesta pesquisa fornecendo os adesivos utilizados nos experimentos.

E por fim, mencionar que o presente trabalho foi realizado com apoio da Comissão de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (Capes), através de bolsa de bolsa de doutorado recebida durante os três anos de doutorado.

“Você deve compreender que há mais de um caminho para o topo da montanha.”

*— Miyamoto Musashi,
Gorin No Sho - O Livro dos Cinco Anéis*

SUMÁRIO

RESUMO.....	8
ABSTRACT	10
1. INTRODUÇÃO	13
1.1. Produtos colados de madeira compensada.....	14
1.2. Principais espécies	16
1.2.1. <i>Gênero Pinus</i>	16
1.2.1.1. <i>Pinus kesiya</i> Royle ex Gordon.....	17
1.2.2. <i>Gênero Eucalyptus</i>	18
1.2.2.1. Híbrido <i>Eucalyptus grandis x Eucalyptus urophylla</i>	19
1.3. Fatores que influenciam a produção de painéis de madeira.....	20
1.4. Métodos de avaliação da qualidade de colagem de produtos engenheirados de madeira.....	21
1.5. Visão computacional e Inteligência artificial aplicados aos produtos de madeira.....	23
1.5.1. <i>CNN aplicadas à análise da qualidade de produtos de madeira</i>	26
1.6. Objetivos.....	31
1.6.1. <i>Objetivo Geral</i>	31
1.6.2. <i>Objetivos específicos</i>	31
Referências.....	31
2. QUALIDADE DA COLAGEM DE PAINÉIS COMPENSADOS DE USO EXTERIOR PRODUZIDOS DE <i>Pinus kesiya</i> E <i>Eucalyptus grandis</i> X <i>Eucalyptus urophylla</i>	41
Resumo.....	41
Abstract.....	42
2.1. Introdução.....	42
2.2. Material e métodos	44
2.2.1. <i>Matéria-Prima</i>	44
2.2.2. <i>Montagem dos painéis e obtenção de corpos de prova</i>	45
2.2.3. <i>Determinação das propriedades mecânicas</i>	46
2.2.4. <i>Análise de Dados</i>	48
2.3. Resultados e discussão	49
2.3.1. <i>Massa específica e Flexão estática</i>	49
2.3.2. <i>Qualidade de colagem</i>	52

2.4. Conclusões	55
Agradecimentos	56
Referências	56
3. LÂMINAS DE <i>Pinus kesiya</i> e <i>Eucalyptus grandis</i> X <i>Eucalyptus urophylla</i> NA PRODUÇÃO DE COMPENSADOS DE USO INTERIOR	61
Resumo	61
Abstract.....	62
3.1. Introdução	62
3.2. Material e métodos.....	64
3.2.1. <i>Matéria-Prima</i>	64
3.2.2. <i>Montagem dos painéis e obtenção de corpos de prova</i>	65
3.2.3. <i>Determinação das propriedades mecânicas</i>	67
3.2.4. <i>Análise de Dados</i>	68
3.3. Resultados e Discussão	69
3.3.1. <i>Resistência e elasticidade à Flexão Estática</i>	69
3.3.2. <i>Qualidade de colagem</i>	72
3.4. Conclusões	74
Agradecimentos	74
Referências	75
4. DEEP LEARNING FOR PLYWOOD BONDING QUALITY CLASSIFICATION.....	79
Abstract.....	79
4.1 Introduction.....	80
4.1.1. <i>Related Work</i>	82
4.1.2. <i>Hypothesis</i>	85
4.1.3. <i>Objective</i>	85
4.2. Materials.....	85
4.2.1. <i>Data</i>	87
4.2.2. <i>Image Processing</i>	88
4.2.3. <i>Classification Technique</i>	89
4.2.4. <i>Active Learning</i>	89
4.2.5. <i>Convolutional neural networks - CNNs</i>	90
4.2.6. <i>Confusion Matrix and evaluation</i>	90
4.2.7. <i>Receiver Operating Characteristic – ROC Curve</i>	91
4.3. Results and discussion.....	91

4.4. Conclusions	95
Acknowledgement	95
References	95
5. CONCLUSÕES GERAIS.....	99
ANEXOS	101

RESUMO

Utilização de imagens para a determinação automatizada da qualidade de colagem em painéis compensados

A indústria de painéis compensados apresenta uma grande flexibilidade no ajuste de seus processos produtivos e esta vantagem permite absorver matérias-primas de espécies florestais não-convencionais disponíveis no mercado, mesmo aquelas que não foram originalmente desenvolvidas para seu segmento. Contudo, é necessário verificar se os novos produtos disponibilizados ao consumidor atendem aos requisitos técnicos regulamentados. Dentre as formas de avaliação de compensados destacam-se os ensaios mecânicos da resistência, rigidez e qualidade de colagem. Entretanto, para a qualidade de colagem é solicitada a mensuração visual do percentual de falha na madeira. Esta etapa é subjetiva, morosa, de difícil treinamento e normalmente negligenciada pelas indústrias. Contudo, nas últimas duas décadas o intenso desenvolvimento da ciência de visão computacional permitiu a automatização de inúmeras análises visuais, oferecendo resultados com acurácia e velocidade superior à classificação humana. Na indústria florestal estes sistemas já são utilizados para a classificação qualitativa de tábuas e lâminas, entretanto, ainda não existem sistemas desenvolvidos para a avaliação visual da qualidade de colagem de painéis compensados. O presente trabalho teve por objetivo desenvolver uma metodologia automatizada para a avaliação visual da qualidade de colagem de painéis compensados com acurácia igual ou superior à classificação humana. Para o desenvolvimento do sistema de visão computacional de determinação da qualidade de colagem foram produzidos 32 painéis de cinco lâminas de 2 mm de espessura com duas espécies não-convencionais, o *Pinus kesiya* (30 anos) e o *Eucalyptus grandis* X *Eucalyptus urophylla* (9 anos). O experimento 1 utilizou o adesivo fenol-formaldeído (FF), enquanto o experimento 2 utilizou ureia-formaldeído (UF). Nos experimentos foram utilizadas as gramaturas de 200 e 175 g/m² e o ciclo de prensagem de 10 minutos para *P. kesiya* e 11 minutos para *E. grandis* x *E. urophylla*. A temperatura de prensagem foi de 150 °C para FF, e 130 °C para UF. Nos experimentos foram avaliadas a massa específica dos painéis (ME) (ABNT – NBR 9.485, 2011), a resistência e rigidez à flexão estática (ABNT – NBR 9.533, 2012) em módulo de ruptura (MOR) e o módulo de elasticidade (MOE). A qualidade de colagem foi verificada pelo cisalhamento na linha de cola (ABNT – NBR 12.466-1, 2012), pela tensão máxima (Tmax) e percentual de falha na madeira (WF%). A análise dos dados foi realizada pelo teste T de Student (5%) e os resultados foram comparados aos requisitos das normas citadas e do Catálogo Técnico nº 1 da ABIMCI (2002). O experimento 3 desenvolveu um sistema de visão computacional com uso de redes neurais convolucionais (CNN) em que foi utilizado um banco de imagens das amostras de WF% dos experimentos anteriores (n = 4.800). Foram avaliados cinco modelos (*Pinus*, *Eucalyptus*, FF, UF e Generalista), para o reconhecimento de cinco classes de qualidade (C1, C2, C3, C4 e C5), adaptado da norma NBR 12.466-1 (ABNT, 2012). Todos os cinco modelos utilizaram 75% das imagens para treinamento e 25% para validação. Como resultados do primeiro experimento, os painéis fenólicos produzidos com lâminas de *E. grandis* X *E. urophylla* apresentaram maiores valores para ME e MOE, enquanto para MOR houve equivalência entre os tratamentos avaliados. Para Tmax e WF%, os painéis

produzidos com *P. kesiya* foram superiores nas três condições avaliadas (seco, água fria e ciclo BDB) e apenas o tratamento que utilizou *E. grandis* X *E. urophylla* e a gramatura de 200 g/m² não atingiu os requisitos da norma NBR 12.466 (2012). Para o segundo experimento, foi verificado que em todas as propriedades avaliadas (ME, MOR, MOE, Tmax e WF%) os tratamentos da espécie *E. grandis* X *E. urophylla* foram superiores aos tratamentos da espécie *P. kesiya*. No terceiro experimento os modelos apresentaram acurácia de classificação superior à classificação humana, *Pinus* (92,46%), *Eucalyptus* (91,84%), FF (94,96%), UF (60,90%) e generalista (94,36%). Os modelos apresentaram maior acurácia para as classes extremas (C1 e C5) e apenas o modelo UF não foi capaz de classificar imagens da classe C1. Como conclusões, no experimento 1 recomenda-se o uso da gramatura de 175 g/m² para as duas espécies na produção de compensados fenólicos. Para o experimento 2, todos os tratamentos atenderam aos requisitos normativos para compensados de uso interno. No experimento 3, foi verificado que a utilização de *CNNs* para a classificação visual da qualidade de colagem de compensados é eficiente e bastante promissora. No entanto, é necessário expandir o banco de imagens para equilibrar o número amostral entre as classes e possibilitar a classificação entre 10 classes como solicita a NBR 12.466 (ABNT, 2012).

Palavras-chave: Painéis de madeira, *Pinus kesiya*, *Eucalyptus urophylla* X *Eucalyptus grandis*, Fenol-formaldeído, Ureia-formaldeído, Visão computacional, Aprendizado profundo

ABSTRACT

Image utilization to plywood panels automated bonding quality analysis

The plywood industry has great flexibility in adjusting its production processes, this advantage allows it to absorb raw-materials from non-conventional forest species available on the market, even those that were not originally developed for its segment. However, it is necessary to verify that the new products made available to the consumer fulfill the regulated technical requirements. Among the manners of plywood evaluation, the mechanical tests of resistance, stiffness, and bonding quality of the panels stand out. However, for the bonding quality, a visual measurement of the of wood failure percentage is required. This step is subjective, time-consuming, difficult to train and often neglected by industries. However, in the last two decades, the intense development of computer vision science allowed the automation of several visual analyses, providing results with higher speed and accuracy than human classification. In the forest industry, these systems are already used for qualitative classification of boards and veneers. However, there are still no systems developed for the visual assessment of the plywood bonding quality. This study aimed to develop an automated methodology for visual assessment of the plywood bonding quality that presents an accuracy equal to or greater than human classification. The development of the computer vision system for bonding quality determination, were produced 32 five-ply panels of 2 mm thick veneer, two non-conventional species were used, the *Pinus kesiya* (30 years) and the *Eucalyptus grandis* x *Eucalyptus urophylla* (9 years). Experiment 1 used the phenol-formaldehyde (FF) adhesive, and the experiment 2 used urea-formaldehyde (UF). The experiments used weights of 200 and 175 g/m² and a pressing cycle of 10 minutes for *P. kesiya* and 11 minutes for *E. grandis* x *E. urophylla*, the pressing temperature was 150 °C for FF, and 130 °C for UF. The experiments evaluated the specific mass of the panels (ME) (ABNT – NBR 9.485, 2011), the resistance and stiffness to static bending (ABNT – NBR 9.533, 2012) in modulus of rupture (MOR) and modulus of elasticity (MOE). Bonding quality was verified by shear test in the glue line (ABNT – NBR 12.466-1, 2012), by maximum tension (Tmax) and percentage of wood failure (WF%). Data analysis was performed by Student's t test (5%) and the results were compared to the requirements of the aforementioned standards and the ABIMCI Catálogo Técnico N 1 (2002). The experiment 3 developed a computer vision system using convolutional neural networks (CNN), using an image bank of WF% samples from previous experiments (n = 4800). Five models were evaluated (*Pinus*, *Eucalyptus*, FF, UF and generalist), for the recognition of five bonding quality classes (C1, C2, C3, C4 and C5), adapted from the NBR 12.466-1 (ABNT, 2012) standard. All five models used 75% of the images for training and 25% for validation. As a result of the first experiment, the phenolic panels produced with *E. grandis* x *E. urophylla* veneer presented higher values for ME and MOE, while for MOR there was equivalence between the evaluated treatments. For Tmax and WF%, the panels produced with *P. kesiya* were superior in the three conditions evaluated (dry, cold water, and BDB cycle). Only the treatment that used *E. grandis* x *E. urophylla* and the weight of 200 g/m² did not reach the requirements of NBR 12.466 (2012) standard. For the second experiment, it was verified that in all evaluated properties (ME, MOR, MOE, Tmax and WF%) the treatments of the species *E. grandis* x *E. urophylla* were superior to the treatments of the species *P.*

kesiya. In the third experiment, the models presented classification accuracy superior to the human classification, *Pinus* (92.46%), *Eucalyptus* (91.84%), FF (94.96%), UF (60.90%) and generalist (94.36%). The models were more accurate for the extreme classes (C1 and C5) and only the UF model was not able to classify images from the C1 class. As conclusions, in experiment 1 it is recommended to use the weight of 175 g/m² for both species in the production of phenolic plywood. For experiment 2, all treatments met the normative requirements for interior use plywood. In experiment 3, it was verified that the use of CNNs for visual classification of the plywood bonding quality is efficient and very promising. However, it is necessary to expand the image bank and balance the sample number between classes and enable classification of 10 classes as required by NBR 12.466 (ABNT, 2012).

Keywords: Wood-panels, *Pinus kesiya*, *Eucalyptus urophylla* X *Eucalyptus grandis*, Phenol-formaldehyde, Urea-formaldehyde, Computer vision, Deep-learning

1. INTRODUÇÃO

O setor de base florestal brasileiro no ano de 2019 apresentou o total de 9 milhões de hectares de florestas plantadas, com taxa de crescimento de 2,4% na área total (IBÁ, 2020). Aumento devido exclusivamente pelo cultivo de espécies do gênero *Eucalyptus*, que ocupa 6,97 milhões de hectares da área de árvores plantadas do País, enquanto, os plantios de *Pinus* ocupam 1,64 milhões de hectares (IBÁ, 2020).

O aumento das áreas de plantio oportuniza a disponibilidade de diversas espécies para novos usos para atender o mercado consumidor, o setor de transformação mecânica da madeira e a indústria de painéis se beneficiam desta diversificação (ABIMCI, 2009).

Painéis de madeira são estruturas fabricadas com madeiras em peças, lâminas ou diferentes estágios de desagregação que, aglutinadas pela ação de pressão, temperatura e resinas, são novamente agregadas (IWAKIRI, 2005).

Os painéis de madeira podem ser divididos em painéis de madeira reconstituída e painéis de madeira processada mecanicamente (BNDES, 2012).

Painéis reconstituídos destacam-se pelo intenso processo de desagregação da madeira que confere uma estrutura mais homogênea, dos quais o *Medium Density Particleboard* (MDP), o *Medium Density Fiberboard* (MDF) e o *Oriented Strand Board* (OSB) configuram entre os produtos com maior produção deste segmento e podem ser utilizados para movelaria e construção civil.

Os painéis processados mecanicamente são formados por camadas de lâminas ou sarrafos de madeira maciça sendo representados principalmente pelos painéis compensados e painéis colados lateralmente (*Edge Glued Panel* – EGP) para a utilização na indústria de móveis e construção civil (BNDES, 2008).

O painel compensado tem o princípio construtivo baseado na utilização de lâminas dispostas em sentidos paralelo e perpendicular ao plano do painel, unidas entre si pela linha de cola, com finalidade de restringir e balancear o comportamento físico-mecânico das lâminas das camadas adjacentes (IWAKIRI *et al.* 2012).

Produzido principalmente com madeira de *Pinus* spp., folhosas tropicais e, *Eucalyptus* spp. os painéis compensados apresentam de 3 a 5 lâminas para uso não-estrutural e de 5 a 11 lâminas para uso estrutural (NBR 12.466, 2012; IWAKIRI *et al.*, 2002; IWAKIRI *et al.*, 2012). Entre os adesivos mais utilizados pela indústria,

se destacam o fenol-formaldeído e melamina-formaldeído em usos externos, enquanto para uso interno, o adesivo ureia-formaldeído é mais comum (MENDES *et al.*, 2012).

Entretanto, é necessária a atenção quanto ao adesivo e sua interação com a madeira, pois os parâmetros relacionados às características da madeira, muitas vezes não podem ser alterados devido à sua origem biológica (ALMEIDA, 2013; REIS *et al.*, 1982).

Decorrente destas limitações, várias formas foram desenvolvidas para determinar a qualidade de colagem de painéis compensados. Entre os testes, se destacam aqueles que aplicam forças perpendicularmente aos painéis como no ensaio de flexão estática (ABNT 9.533, 2012). Enquanto para a avaliação da qualidade de colagem são mais comuns os ensaios mecânicos que aplicam de esforços de tração às linhas de cola dos painéis e que resultam em dados de tensão máxima de ruptura (ABNT 12.466, 2012).

Adicionalmente, para a avaliação da linha de cola é comum a determinação do percentual de falha coesiva na madeira, esta é uma avaliação visual e deve ser realizada por operadores treinados. Contudo, Abraão *et al.* (2003) descrevem que além da subjetividade, o processo tende a ser moroso, sendo necessária a adoção de sistemas de automatização laboratorial.

1.1. Produtos colados de madeira compensada

A madeira como material de construção oferece vantagens que superam outros materiais tradicionais como aço, concreto e alvenaria em diversos aspectos. Entre as potencialidades da madeira, destaca-se o baixo peso em relação à alta resistência, pouco consumo energético para processamento e a capacidade para suportar sobrecargas de curta duração (CUNHA e MATOS, 2010).

Além destas vantagens, a madeira ainda pode ser utilizada em variados produtos após processamento e combinação com outros materiais. Desde a colagem de peças de madeira sólida a produção de painéis *EGP*, vigas de madeira laminada colada (MLC), compensados e painéis reconstituídos como MDF e MDP com aplicações na indústria moveleira e construção civil (IWAKIRI *et al.* 2013).

A transformação da madeira sólida, por processos de desagregação da madeira permite a obtenção de lâminas, partículas e fibras reverte em um elevado aproveitamento da matéria-prima.

Mais recentemente a atividade de laminação apresenta o aumento significativo do rendimento do processo pela popularização dos tornos *spindleless* que atingem taxas de aproveitamento entre 60 a 75% (GUO e ALTANER, 2018). Os painéis de madeira também permitem a criação de produtos com dimensões e estabilidade dimensional superior à madeira sólida (IWAKIRI *et al.* 2013).

Os painéis compensados podem ser produzidos para uso geral, industrial, decorativo e estrutural em função do adesivo e lâminas utilizadas na sua composição (IWAKIRI *et al.*, 2000). Geralmente formado por um conjunto de lâminas sobrepostas e cada camada apresenta o eixo das fibras disposto ortogonalmente entre as camadas adjacentes (KOLLMANN *et al.*, 1975; TSOUMIS, 1991; IWAKIRI, 2005).

O direcionamento ortogonal de uma lâmina em relação a outra adjacente, restringe a movimentação tangencial das camadas e resulta em valores de retratibilidade similares nas duas direções do plano do painel, conferindo excelente estabilidade dimensional (BORTOLETTO JÚNIOR e GARCIA, 2004).

Em comparação com a madeira maciça, as fibras cruzadas do compensado aumentam significativamente a resistência e a rigidez na direção normal às fibras (DIAS *et al.*, 2003). Por possuir diversas características favoráveis, o compensado encontra utilizações bastante variadas na construção civil, para aplicações estruturais e na fabricação de móveis, instrumentos musicais, embalagens industriais, caixas e outros (BORTOLETTO JÚNIOR e GARCIA, 2004).

Dentre os painéis de madeira, o compensado é o painel mais antigo já produzido em escala comercial. O desenvolvimento da produção de lâminas de madeira ocorreu inicialmente nos Estados Unidos e na Europa no final do século XIX e foi a base para o surgimento da indústria de painéis de madeira (OLIVEIRA, 1988; ALBUQUERQUE, 1999; TOMASELLI, 1999).

No Brasil, as indústrias de compensado foram instaladas inicialmente na década de 1940 na região sul do País, utilizando madeira de *Araucaria angustifolia* (ABIMCI, 2011). A partir da década de 1990, as indústrias começaram a utilizar espécies do gênero *Pinus* como matéria-prima para o suprimento da produção (IWAKIRI *et al.*, 2006).

Atualmente as principais espécies utilizadas pela indústria brasileira de compensados são as espécies do gênero *Pinus*, como o *P. taeda* e *P. elliottii* e os materiais tropicais como o *P. caribaea* e *P. tecunumanii* (TRIANOSKI *et al.* 2013).

No entanto, cada vez mais o gênero *Eucalyptus* vem aumentando sua participação no suprimento de indústrias de compensados, em grande parte devido à maior disponibilidade de matéria-prima, rápido crescimento e massa específica superior à de *Pinus* (IWAKIRI *et al.*, 2000; IWAKIRI *et al.*, 2012b).

1.2. Principais espécies

1.2.1. Gênero *Pinus*

O gênero *Pinus* apresenta 105 espécies identificadas que são fisiologicamente resistentes à seca, muito exigentes com luz (suportando sombreamento apenas na fase jovem). Quanto à temperatura, suportam temperaturas de -65 °C até 50 °C. Apresentam diferentes exigências quanto à fertilidade, textura e profundidade do solo. Devido à sua grande versatilidade, possibilitando o plantio em diferentes condições de ambiente (MARCHIORI, 2005), as espécies de *Pinus* vêm sendo introduzidas no Brasil há mais de um século para várias finalidades.

Muitas delas foram trazidas pelos imigrantes europeus para fins ornamentais e para produção de madeira. As primeiras introduções de que se tem notícia fora de *Pinus canariensis*, provenientes das Ilhas Canárias, e ocorreram no Rio Grande do Sul, em torno de 1880 (MARIN, 2006).

O início da atividade de reflorestamento em grande escala no Brasil deu-se após o evento dos incentivos fiscais em 1966. Na região Sul do País, a opção foi para o gênero *Pinus*, com duas espécies principais: *Pinus elliottii* var. *elliottii* e *Pinus taeda*, visando criar uma base florestal em substituição ao Pinheiro-do-Paraná (*Araucaria angustifolia*), intensamente explorado e com suas reservas naturais comprometidas, para dar suporte ao programa de desenvolvimento do setor de celulose e papel na produção de polpa de fibra longa (KLOCK, 2000).

Pelas características de rápido crescimento, intensa reprodução e facilidade de aplicação de práticas silviculturais e manejo, o *P. taeda* é a espécie mais importante dentre as espécies florestais plantadas comercialmente no sul e sudeste

do Brasil. Entre as espécies do gênero, é mais plantada no Brasil, com cerca de 1 milhão de hectares e os plantios se concentram nos planaltos da região sul, bem como as partes mais chuvosas dos estados de São Paulo e Minas Gerais (PRATA, 2010).

A espécie é mais utilizada para serraria e indústria de celulose e papel e também pode ser utilizada para extração de resina, contudo, essa não possui alta qualidade e quantidade como a produzida por *P. elliottii*. (TRIANOSKI *et al.* 2013).

A madeira das espécies do gênero *Pinus* plantados no Brasil apresentam de maneira geral, cor amarelo-clara a amarelo-alaranjado, cheiro característico de resina, grã reta, brilho moderado, textura média a grossa e anéis de crescimento distintos. Baixa massa específica, entre 0,35 e 0,55 g/cm³, baixa instabilidade dimensional, fácil secagem e boa trabalhabilidade (TRIANOSKI *et al.* 2013).

1.2.1.1. *Pinus kesiya* Royle ex Gordon

A espécie tem ocorrência natural nas montanhas dos estados indianos Khani, a oeste e sul da grande curva do rio Brahmaputra, passando pelas montanhas de Assam e mais ao longe, pelo sudeste em Sikang e Yunnan. Ocorre também, nas regiões nordeste da Tailândia e Laos em locais com altitude de 1200 a 1400 m (SOUZA, 2009).

No gênero *Pinus*, a espécie pertence filogeneticamente à seção e subseção *Pinus*. Este grupo tem distribuição natural na Eurásia, Mediterrâneo, América do Norte e Cuba.

O *P. kesiya* geneticamente mais próxima das espécies *P. yunnanensis* e *P. densata*. A planta apresenta de duas a três acículas por fascículo e as árvores podem atingir 30 m de altura e diâmetro a altura do peito (DAP) de 120 cm.

A casca marrom-acinzentada com profundos sulcos é característica da espécie, a copa longa e densa quando jovens e quando adulta apresenta copa arredondada e achatada (LAMPRECHT, 1990; GERNANDT *et al.*, 2005).

A madeira é bastante resinosa, semelhante à espécie *P. caribaea*, com densidade variando entre 0,45 a 0,75 g/cm³ e semelhante ao *P. oocarpa* quando considerado o processamento mecânico da madeira (LAMPRECHT, 1990; SOUZA, 2009).

Souza (2009) utilizando a lâminas de madeira de *P. kesiya* para produção de *Laminated Veneer Lumber (LVL)* obteve resultados superiores à espécie *P. oocarpa* para todas as propriedades mecânicas avaliadas, possibilitando a indicação da espécie para usos com maiores requisitos de resistência.

1.2.2. Gênero *Eucalyptus*

O gênero *Eucalyptus* pertence à família Myrtaceae, com distribuição natural entre a Oceania até a Indonésia e Filipinas, onde apresenta mais de 600 espécies distribuídas principalmente na Austrália.

As espécies mais conhecidas de *Eucalyptus* são árvores típicas de florestas altas atingindo de 30 a 50 metros e, em florestas abertas, apresenta árvores menores, com altura entre 10 e 25 metros, além de 30 a 40 espécies de porte arbustivo (MORA e GARCIA, 2000).

Por suas características silviculturais, as espécies de *Eucalyptus* foram gradativamente introduzidas no Brasil, e hoje as espécies do gênero são a maior fonte de matéria-prima florestal plantada no país, com ampla gama de utilização, totalizando 6,97 milhões de hectares de área plantada em 2019 (OLIVEIRA *et al.*, 1999; IBÁ, 2019).

As espécies do gênero *Eucalyptus* apresentam rápido crescimento, boa forma do fuste e desrama natural, apesar de variações das suas propriedades tecnológicas (OLIVEIRA *et al.*, 1999). Várias espécies de *Eucalyptus* já são empregadas comercialmente na produção de celulose e papel, carvão vegetal, painéis aglomerados e de fibras de madeira (TRIANOSKI *et al.*, 2013).

Dentre as espécies plantadas no Brasil podem ser destacadas para regiões de clima tropical o *Corymbia citriodora* (anteriormente *Eucalyptus citriodora*), *Eucalyptus tereticornis*, *E. paniculata*, *E. pilularis*, *E. urophylla*, *E. grandis*, *E. saligna* e o híbrido *E. grandis* x *E. urophylla*, popularmente conhecida como eucalipto urograndis.

Enquanto para as regiões de clima temperado, destacam-se as espécies *E. viminalis*, *E. dunnii*, e *E. benthamii*, que podem atingir incremento médio anual de até 45 m³/ha/ano (OLIVEIRA *et al.*, 1999; ARAUJO *et al.*, 2012; ALVES *et al.*, 2011; TRIANOSKI *et al.*, 2013).

A madeira de árvores do gênero *Eucalyptus* apresentam como características gerais, cor amarelo-clara à bege no albarno e laranja a vermelho-escuro no cerne, grã reversa entrecruzada, brilho moderado, textura média a grossa e anéis de crescimento indistintos.

A massa específica varia entre 0,35 e 0,65 g/cm³, apresenta elevada instabilidade dimensional, com difícil secagem, qualidade de acabamento variável, baixo rendimento em desdobro mecânico devido à ocorrência de tensões de crescimento e elevada gravidade de rachaduras de topo (ALVES *et al.*, 2011; HASELEIN *et al.*, 2004).

Devido a estas características, no Brasil, o gênero ocupa uma posição de destaque na escolha de espécies para a implantação de povoamentos florestais, estando a maior parte da produção comprometida com os usos tradicionais, como celulose e papel, carvão vegetal, lenha e chapas de fibras (ROCHA, 2000).

1.2.2.1. Híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*

Embora o gênero *Eucalyptus* seja o de maior importância para a silvicultura nacional, existem as características naturais do material que dificultam a produção de madeira de boa qualidade para múltiplos usos. Desta forma a seleção artificial pode ser utilizada para a obtenção de materiais de melhor qualidade para a utilização em indústrias de transformação mecânica.

A produção de híbridos entre espécies que possuam características complementares é indicada para atingir estes objetivos (ALMEIDA *et al.*, 2004). A possibilidade do uso de clones e híbridos na eucaliptocultura têm se mostrado um grande diferencial produtivo, principalmente para a produção de celulose.

Dentre os híbridos temos o *E. grandis* x *E. urophylla*, comercialmente conhecido como Eucalipto urograndis, que representa grande parcela do suprimento de madeira para uso industrial, com uso em destaque no Congo e Brasil. No ano de 2001 a área ocupada pelo híbrido no Brasil atingiu 400.000 ha (QUILHÓ *et al.* 2006; GOMINHO *et al.* 2001; SHARMA *et al.*, 2015).

Este híbrido foi desenvolvido pela empresa Aracruz e tem como características principais a combinação de elevado crescimento do *E. grandis* (até 12 ton./ha/ano em ciclos de 6 anos) em conjunto das propriedades de qualidade de

fibra, elevada massa específica e resistência ao cancro observadas em *E. urophylla*. (QUILHÓ *et al.* 2006; SHARMA *et al.*, 2015).

1.3. Fatores que influenciam a produção de painéis de madeira

Para a tecnologia de painéis compensados de madeira existem vários fatores que podem influenciar a qualidade do produto final, como a matéria-prima, os processos e insumos utilizados.

Das características da matéria-prima deve-se destacar as características anatômicas da madeira, principalmente relacionadas à movimentação do adesivo na madeira. A porosidade e permeabilidade da madeira afetam diretamente o desempenho da colagem, dificultando ou facilitando a fixação do adesivo por ancoramento nos espaços vazios da madeira (ALBUQUERQUE e LATORRACA, 2005; PRATA, 2010; IWAKIRI, 2005).

A composição química da madeira também é um fator a ser observado com atenção na produção de painéis de madeira, pois interfere na ligação madeira-adesivo (LIMA, 2006). Sendo recomendadas espécies com baixo teor de extrativos para produção de painéis de madeira. (SANTOS, 2008; HILIG, 2000).

Madeiras com elevados teores de extrativos e de cinzas podem afetar negativamente a colagem dos painéis, a interação destes compostos com os adesivos pode retardar o processo de cura durante a etapa de prensagem, sendo necessário ajustar o ciclo de prensagem (KLOCK *et al.*, 2005; IWAKIRI, 2005).

Para a produção compensados também é necessário estar atento às propriedades físicas da madeira, pois o baixo nível de desagregação da matéria-prima confere um comportamento mais próximo à madeira sólida do que os painéis reconstituídos (ALMEIDA, 2013).

Em especial a massa específica e o teor de umidade da madeira, assim como os coeficientes de anisotropia e de retratibilidade volumétrica.

Marra (1992) descreve que a massa específica da madeira afeta a colagem pela porosidade e a capacidade de absorção de água e, com isso, o aumento da instabilidade dimensional e da tensão exercida na linha de cola. O coeficiente de anisotropia da madeira é uma das características mais importantes à produção de painéis processados mecanicamente.

As variações dimensionais da madeira, ocorridas durante e após a cura do adesivo, podem contribuir para a deterioração das ligações adesivas, por introduzirem tensões elevadas nas faces coladas (PRATA, 2010). Por estes motivos, o controle preciso da umidade da madeira é primordial para o sucesso da produção de painéis e o uso de lâminas com baixo teor de umidade pode ser prejudicial para a colagem.

Nestes casos, há a tendência de o adesivo perder umidade mais rapidamente, distanciando-se da linha de cola original, conhecido como “linha de cola faminta” (IWAKIRI, 2005; NOCK e RICHTER, 1978). No entanto, a situação oposta também é limitante, visto que madeiras coladas com elevado teor de umidade, tendem a apresentar tensões nas linhas de cola durante o acondicionamento dos painéis (RAKNES, 1982).

1.4. Métodos de avaliação da qualidade de colagem de produtos engenheirados de madeira

Dentre as várias formas para a inferência da qualidade da montagem e colagem de produtos de madeira colada e painéis compensados, estão os testes que aplicam tensões cisalhantes sobre as peças e/ou linhas de cola.

São utilizados os resultados numéricos de tensão de ruptura e deformação da amostra, o tipo da fratura e o percentual de falha coesiva aparente para determinar se os parâmetros utilizados para a construção foram adequados aos painéis (NBR 12.466-1, 2012).

O percentual de falha coesiva aparente da madeira permite avaliar a qualidade de ancoragem de um adesivo com a madeira. A colagem é considerada eficiente quando ocorre a ruptura na estrutura da madeira (NBR 12.466-2, 2012). A qualidade de colagem é afetada pelas características químicas do adesivo, ciclo de prensagem e categoria de uso (BS EN 314, 1993).

Contudo, na maioria das normas que tratam destes painéis, não há uma descrição clara dos procedimentos de avaliação do percentual de falha coesiva aparente, e em alguns casos, apenas é considerada a tensão de ruptura como parâmetro para o atendimento dos requisitos de qualidade (NBR 12.466-1, 2012; NBR 12.466-2, 2012).

A norma brasileira que trata de painéis compensados NBR 12.466 (2012), apresenta um padrão referencial, mas, apenas para adesivos de coloração marrom, como o fenol-formaldeído e resorcinol-formaldeído, e madeiras de coloração clara como o *Pinus*, como pode ser verificado na figura 1.




Figura 1. Exemplos de classes de percentual de falha na madeira (fonte: NBR 12.466-1, 2012)

Enquanto a norma para compensados ASTM D-5.266 (2005) apresenta procedimento semelhante à norma NBR 12.466 (2012), e a mensuração é realizada com auxílio de um gabarito para medição manual das áreas do corpo de prova (figura 2.).

Contudo, este procedimento é considerado subjetivo e de difícil mensuração entre as faixas de 35 a 85% de falha coesiva aparente.




Figura 2. Gabarito para medição e exemplos de classes de percentual de falha na madeira (fonte: ASTM D-5.266, 2005)

Abraão *et al.* (2003) descrevem que além da subjetividade, o processo tende a ser moroso e necessária a adoção de sistemas de automatização laboratorial.

Vieira (2016) e Almeida (2014), em estudos sobre a classificação tradicional de tábuas de *Pinus*, demonstram que a adoção de sistemas de classificação automatizada por visão computacional e aprendizado de máquinas permitem o aumento da acurácia quando comparado à avaliação tradicional subjetiva e dependente de operadores treinados.

1.5. Visão computacional e Inteligência artificial aplicados aos produtos de madeira

A classificação da qualidade de produtos baseados na avaliação visual e qualitativa realizada por humanos é uma atividade comum em boa parte das indústrias que utilizam matéria-prima de origem biológica, seja pela ocorrência de defeitos naturais ou por algum valor subjetivo desejável como textura, cor, desenho, cheiro e gosto.

A realização de inspeções permite a correção de problemas e o descarte de produtos defeituosos resultando em uma melhor qualidade do produto final (AFFONSO *et al.* 2017). Contudo, é uma atividade repetitiva e propensa à fadiga após longos períodos de execução, revertendo em uma redução significativa na taxa de reconhecimento e acurácia das avaliações e erros de detecção ocorrerão (YANG *et al.*, 2018).

A recorrência de erros provenientes da classificação visual incorreta é comum para produtos de origem biológica como os produtos agrícolas e florestais devido à estrutura complexa e a imprevisibilidade de arranjos estruturais (GOGUL e KUMAR, 2017).

Além da dificuldade de treinamento, a alta rotatividade dos colaboradores que realizam esta atividade também é um dos principais fatores causadores de erros de classificação, como descrevem Huber *et al.* (1985) sobre a avaliação visual de tábuas em serrarias.

Reconhecendo este contexto e visando atender mercados consumidores mais exigentes quanto à qualidade e uniformidade dos produtos comercializados, as indústrias vem investido na aquisição de sistemas automatizados de avaliação visual para aumentar a acurácia e uniformidade de seus processos, pela redução de erros de origem humana.

Estes sistemas automatizados utilizam das técnicas de visão computacional, sendo a ciência que trata da construção explícita e significativa da descrição de objetos físicos por imagens provenientes de diversos sensores e dispositivos como câmeras digitais, raios-X, ultrassom e outros sensores hiper espectrais (BALLARD e BROWN, 1982; BARELLI, 2019).

Este campo da ciência iniciou seu desenvolvimento juntamente ao princípio da computação no final dos anos de 1950 e muitos dos conceitos essenciais foram desenvolvidos até o início da década de 1980 com aplicações em diversas áreas, como, inteligência artificial, psicologia, computação gráfica e processamento de imagens (BALLARD e BROWN,1982). Entretanto, estes sistemas eram pouco eficientes ou não apresentavam a eficiência necessária para a utilização em tempo real para superfícies complexas como madeira ou outros produtos de origem biológica.

Esta dificuldade foi verificada por Connors *et al.* (1990), que desenvolveram um protótipo baseado em visão computacional para a classificação de defeitos em

tábuas de madeira. Os autores verificaram que o uso de imagens foi pouco eficiente para a detecção de defeitos, pela dificuldade de processamento computacional e baixa resolução das câmeras digitais.

Contudo, a utilização de imagens digitais para detecção de defeitos de madeiras apresentou resultados promissores em experimentos em que foram aplicadas técnicas de inteligência artificial para o processamento das imagens e identificação dos defeitos.

Entre os algoritmos mais promissores destacava-se o K-vizinhos mais próximos (*K-nearest neighbor – KNN*), máquinas de suporte de vetores (*Support Vectors Machine – SVM*) e as redes neurais artificiais (*Artificial Neural Network – ANN*), obtendo classificações com qualidade superior à classificação realizada por avaliadores humanos (ALAPURANEN e WESTMAN, 1992; CHO *et al.*; 1991).

Entretanto, o processamento de imagens ainda era uma tarefa trabalhosa e os algoritmos baseados em ANN começaram a se destacar como alternativa para sistemas de visão computacional (CHO *et al.*; 1991).

Ainda no final da década de 1980 a detecção de características por imagens digitais recebeu um grande impulso pelo trabalho publicado por LeCun *et al.* (1989).

O estudo sobre a identificação de dígitos numéricos escritos a mão e que se tornaria a base para os algoritmos conhecidos posteriormente como Redes Neurais Convolucionais (*Convolutional Neural Network - CNN*).

LeCun e Bengio (1995) descrevem que esta metodologia utiliza diferentes camadas de neurônios para a realização de diferentes funções, divididas entre camadas conhecidas e camadas ocultas.

As camadas de entrada dos dados e a de saída são as camadas conhecidas do modelo. No entanto, diferentemente das ANN nas camadas ocultas de uma CNN ocorrem ao menos três etapas: as convolações, uma função de ativação e o Pooling (LeCun *et al.*, 1989).

As Convoluições são as etapas que a programação aplica diversos filtros (*kernels*) capazes de identificar feições relevantes nas imagens. A cada nova camada de convolação os filtros reconhecem feições cada vez mais complexas (LeCun *et al.*, 1989).

As funções de ativação são responsáveis por remover a linearidade dos modelos permitindo um aprendizado mais amplo, normalmente para CNNs a função ReLu é a mais utilizada. Esta função converte para zero todos os valores negativos

existentes nas matrizes dos mapas de características das convolações e permite um processamento mais rápido nas camadas subsequentes da *CNN* (LeCun *et al.*, 1989).

Seguido da etapa de *Pooling* com a criação de mapas condensados que reduzem o tamanho das imagens analisadas, mas sem a perda das informações relevantes, o que aumenta a velocidade de processamento das camadas subsequentes até a camada de saída (LECUN *et al.*, 1989; LECUN e BENGIO, 1995).

Por fim, as camadas completamente conectadas (*Fully connected*) ao final da rede, esta camada apresenta uma quantidade de neurônios igual à quantidade de classes para qual o modelo foi desenvolvido para classificar (LeCun *et al.*, 1989).

Para exemplificar uma arquitetura de *CNN* desenvolvida para a classificação de imagens a rede LeNet5 é apresentada na figura 3.




Figura 3. CNN LeNet-5 desenvolvida para reconhecimento de números por imagens digitais (LeCun *et al.*, 1989)

1.5.1. CNN aplicadas à análise da qualidade de produtos de madeira

A superioridade das CNN para classificação de imagens complexas foi demonstrada por Huang e LeCun (2006), os autores compararam as taxas de acerto na classificação visual de imagens por CNN, SVM e um sistema híbrido (CNN + SVM), em um conjunto de 291.600 imagens (*NORB dataset*).

Os autores obtiveram taxas de erro de classificação de 43,3% para SVM, enquanto para CNN e CNN + SVM apenas 7,2% e 5,9%, respectivamente e além da melhor acurácia, a CNN ainda tem como vantagem a maior velocidade de processamento entre todos os algoritmos.

Os autores destacam que a associação de SVM aplicados às imagens tratadas por CNN permitiu o acréscimo na acurácia, demonstrando ser uma opção viável para a utilização em imagens complexas ou para classificação em tempo real.

Devido à grande eficiência das CNNs, a metodologia se tornou a principal ferramenta para estudos complexos de classificação visual como a inspeção de produtos de origem florestal como apresentado nos trabalhos de diversos autores.

Drake e Packianather (1998), obtiveram 88% de acerto na classificação de defeitos em lâminas de madeira para a produção de compensados, no entanto, os autores utilizaram apenas imagens digitais em escala de cinza (*grayscale*).

A identificação e classificação de tábuas de *Pinus*, conforme a ocorrência de defeitos foi realizada por Affonso *et al.* (2017) utilizando imagens coloridas (RGB) convertidas para *grayscale*, para comparar a eficiência de classificação de três qualidades de tábuas por CNN, ANN, KNN e SVM.

Os autores verificaram que a CNN apresentou 77,69% de acerto de classificação e foi inferior a todos os outros algoritmos avaliados. Contudo, este resultado pode ser atribuído ao elevado desbalanceamento de amostras das classes (A= 144, B= 177, C= 53) e pelo pequeno espaço amostral (n= 374), fatores estes que são conhecidamente limitantes às CNNs, as quais se beneficiam de conjuntos amostrais maiores e mais homogêneos.

A utilização de imagens RGB apresentam maior complexidade computacional e custo de processamento, e dependendo do algoritmo pode resultar em classificações de menor confiabilidade.

Este evento foi demonstrado por Funk *et al.* (2003), em um trabalho de classificação de defeitos de lâminas de compensado, em que, para o mesmo algoritmo quando utilizadas imagens RGB, os resultados de classificação foram inferiores aos observados para imagens em *grayscale*.

Todorokia *et al.* (2011) apresentou um dos primeiros trabalhos com imagens coloridas para identificação e mensuração de nós em lâminas de madeira.

Neste trabalho verificou que o algoritmo utilizado para a banda de cor vermelha apresentou resultado semelhante ao observado para as mesmas imagens processadas em *grayscale*, com taxas de acerto de classificação de 96% e 99%, respectivamente.

O bom desempenho de CNNs utilizadas para o segmento florestal foi também verificado para a identificação de espécies florestais a partir de imagens

macro e microscópicas do lenho e pode ser considerado um passo importante para o desenvolvimento de sistemas automatizados para produtos de origem natural.

A identificação de espécies através da estrutura anatômica da madeira é de difícil treinamento, principalmente pela elevada quantidade de estruturas e suas diversas combinações que tornam cada espécie única.

No entanto, pode causar confusão entre espécies que apresentam conjuntos anatômicos semelhantes, seja por pertencerem à mesma família ou gênero, ou mesmo aquelas originadas por convergência evolutiva em famílias botânicas distintas.

Ravindran *et al.* (2018), utilizaram imagens do lenho de 10 espécies da família *Meliaceae* nativas da América do Sul, África e Sudeste Asiático para composição de uma CNN que obteve uma elevada taxa de acerto para a identificação das espécies (87,40%) e do gênero (97,50%). Estes resultados excedem o percentual de acerto da classificação tradicional realizada por humanos.

Da mesma maneira, Hafemann *et al.* (2014) em estudo sobre a classificação de 22 espécies florestais tropicais, utilizou imagens macro e microscópicas do lenho, obtendo taxas de acerto de 95,77% para imagens macroscópicas e 97,32% para imagens microscópicas.

A utilização de algoritmos para classificação de espécies florestais a partir de imagens microscópicas do lenho também foi eficiente para identificação de 52 espécies tropicais com 97,01% de acurácia apresentados por Zamri *et al.* (2016). A identificação de espécies de coníferas foi o objeto de trabalho de Kwon *et al.* (2017) em que obtiveram 99,03% de acerto de classificação por imagens macroscópicas de cinco espécies de coníferas através de modelos de CNN.

Cabe destacar que os trabalhos apresentados utilizaram em sua maioria imagens provenientes de câmeras de celulares com pouco controle de iluminação e, mesmo em condições não ideais, as CNN foram eficientes na identificação das espécies.

Estes modelos demonstraram que a utilização de CNNs pode ser uma ferramenta poderosa para identificação de características visuais de difícil avaliação por seres humanos e podem ser aplicadas para aparelhos portáteis e utilização em campo ou na indústria em tempo real.

Neste contexto, a indústria de compensados é um dos segmentos florestais que mais é afetado negativamente pela classificação visual, pois, a utilização de

lâminas de baixa qualidade pode afetar negativamente o desempenho físico e mecânico dos painéis.

Isto se deve ao elevado rendimento da atividade de laminação, entre 60 a 75% (GUO e ALTANER, 2018), que além de madeira limpa, acaba por utilizar áreas do tronco que apresentam maior ocorrência de defeitos como os nós, medula e madeira juvenil.

O desenvolvimento de equipamentos mais modernos com objetivo de maximizar o aproveitamento de madeira, como os tornos *spindleless*, acaba por obter uma maior proporção de lâminas com ocorrência de defeitos, e agrava a necessidade de identificação e classificação de lâminas para a produção adequada de compensados.

Contudo, majoritariamente as indústrias brasileiras ainda se utilizam da classificação visual humana, propensa a erros oriundos da repetitividade da atividade e, para evitar estes erros, são propostos sistemas de visão computacional para automatizar a inspeção visual, com capacidade de localizar e identificar estes defeitos.

Entre os estudos mais recentes sobre visão computacional aplicada às lâminas de madeira utilizando algoritmos de CNN, foi verificado que existe a tendência de focar seus objetivos na localização, identificação e mensuração dos defeitos apresentados nas lâminas, assim como identificar quais abordagens se mostram mais adequadas para cada defeito.

Destes trabalhos, podemos citar Urbonas *et al.*, (2019), que compararam quatro diferentes algoritmos para realização da etapa de Transferência de Conhecimento para a CNN no reconhecimento de quatro defeitos (nós, trincas, medula e manchas) e a diferenciação entre lâminas e o fundo (*background*). Os resultados obtidos apresentaram acurácia média de 80,6% de acerto para a correta identificação de defeitos e são eficientes para a utilização em escala industrial.

No trabalho de Hu *et al.* (2020), considerando apenas três defeitos (nó vivo, nó morto e furos de insetos), as taxas de acerto em classificação dos defeitos variaram de 86,1% a 98,4% entre os algoritmos utilizados, no entanto, os resultados iniciais foram melhorados graças à técnica de criação de imagens sintéticas (*Augmentation*).

Esta técnica produz digitalmente novas imagens baseadas no conjunto inicial com o objetivo para expandir o conjunto amostral sem a necessidade de

retornar à indústria para a coleta de novas imagens. Este procedimento pode ser utilizado também para uniformizar o tamanho amostral de cada classe em estudo e se mostrou adequado para melhorar o desempenho das CNNs na aferição da qualidade de lâminas de madeira.

Um resultado semelhante foi obtido por Shi *et al.* (2020), no entanto, além da elevada acurácia de classificação o estudo também almejava identificar um algoritmo para atender a necessidade de velocidade de classificação para ser utilizado em tempo real no ambiente industrial.

Ao final do estudo, os autores selecionaram um algoritmo que possibilitava identificar um lote de 50 imagens com o padrão de qualidade desejada pela indústria e um lote de 50 imagens de lâminas com defeitos em apenas 2,5 segundos, com acurácia média de 95,31% e comparativamente à outros métodos de detecção de defeitos a abordagem apresentada foi mais acurada e mais rápida.

Yang *at al.* (2020), objetivando otimizar uma CNN para classificação de lâminas de madeira, utilizaram técnicas de *Extreme Machine Learning* (EML) durante a etapa de transferência de conhecimento e obtiveram um aumento significativo da acurácia da CNN para a extração dos contornos dos defeitos, atingindo 96,7% de acerto, em apenas 187 ms.

Os avanços nas metodologias, na acurácia e velocidade de identificação, mensuração e classificação de defeitos é perceptível para o campo de visão computacional aplicado aos painéis de madeira e, em especial, aos painéis compensados.

No entanto, com relação à determinação da qualidade de colagem pela avaliação visual, ainda não existem trabalhos que abordem esta temática sob a perspectiva da utilização de CNNs e ainda há muito a ser desenvolvido e avaliado sobre quais os fatores limitantes e como proceder para supera-los para possibilitar o uso industrial.

1.6. Objetivos

1.6.1. Objetivo Geral

Desenvolver uma metodologia automatizada para a avaliação visual da qualidade de colagem de painéis compensados que apresente acurácia igual ou superior à classificação manual.

1.6.2. Objetivos específicos

— Verificar o efeito dos adesivos Fenol-formaldeído e Ureia-formaldeído utilizados em duas gramaturas na produção de compensados com lâminas das espécies de *Eucalyptus urophylla* x *Eucalyptus grandis* e de *Pinus kesiya*.

— E desenvolver um sistema de visão computacional para a avaliação automatizada da qualidade de colagem de painéis compensados.

Referências

- ABRAHÃO, C. P.; VARELLA, C. A. A.; PINTO, F. A. C.; JUNIOR, J. K. K. Quantificação da falha na madeira em juntas coladas utilizando técnicas de visão artificial. **Revista Árvore**, Viçosa-MG, v.27, n.1, p.71-78, 2003.
- AFFONSO, C. O.; ROSSI, A. L. D.; VIEIRA, F. H. A.; CARVALHO, A. C. P. L. F. Deep learning for biological image classification. **Expert systems with applications**, 85 (2017) 114–122. <http://dx.doi.org/10.1016/j.eswa.2017.05.039>
- ALAPURANEN, P., WESTMAN, T. Automatic visual inspection of wood surfaces. **Proceedings. 11th IAPR International Conference on Pattern Recognition**. 1992. doi:10.1109/icpr.1992.201578
- ALBUQUERQUE, C. E. C.; LATORRACA, J. V. F. Adesivos. **Revista da Madeira**, Ed. 88. Curitiba, 2005.
- ALMEIDA, O. C. P. Classificação de tábuas de madeira usando processamento de imagens digitais e aprendizado de máquina. 2014, 107p. **Tese (Doutorado em Agronomia)** – Universidade Estadual Paulista “Júlio de Mesquita Filho” UNESP, Botucatu, 2014.

- ALMEIDA, R. R. Potencial da madeira de clones do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla* para a produção de lâminas e manufatura de painéis compensados. 2002. 80 p. Dissertação (Mestrado) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2002.
- ALMEIDA, R. R.; BORTOLETTO JÚNIOR, G.; JANKOWSKY, I. P. Produção de compensados a partir da madeira de clones do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*. **Floresta e ambiente**, 11, n.1, p. 14 - 24, ago./dez. 2004b.
- ALMEIDA, R. R.; BORTOLETTO JÚNIOR, G.; JANKOWSKY, I. P. Produção de lâminas a partir da madeira de clones do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*. **Scientia Forestalis** (IPEF), Piracicaba, v. jun., n.65, p. 49-58, 2004a.
- ARAÚJO, H. J. B.; MAGALHÃES, W. L. E; OLIVEIRA, L. C. Durabilidade de madeira de eucalipto citriodora (*Corymbia citriodora* (Hook.) K.D. Hill & L.A.S. Johnson) tratada com CCA em ambiente amazônico. **Acta Amazônica**, v. 42(1), p. 49-58, 2012.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE (ABIMCI). **Estudo setorial 2009: indústria de madeira processada mecanicamente: ano base 2008**. Curitiba, 2009. 52p.
- ABIMCI - ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE. **Programa Nacional de Qualidade da Madeira: compensado de *Pinus***. Curitiba, 2002. 20 p. (Catálogo Técnico, n.1).
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 9485 - Compensado - Determinação da massa específica aparente**. Brasil, 2011.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 9533 - Compensado - Determinação da resistência à flexão estática**. Brasil, 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12466 - 1 Madeira compensada – Qualidade de colagem Parte 1: Métodos de ensaio**, Brasil 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12466 - 2 Madeira compensada – Qualidade de colagem Parte 2: Requisitos**, Brasil 2012.
- ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS (ABRAF). **Anuário estatístico da ABRAF 2012, ano base 2011**. ABRAF, Brasília: 2012. 150p.

- BAL, B. C. Screw and nail holding properties of plywood panels reinforced with glass fiber fabric. **Cerne**, v. 23 n. 1, p. 11-18, 2017.
- BAL, B. C., BEKTAŞ, I. Some mechanical properties of plywood produced from *Eucalyptus*, beech, and poplar veneer. **Maderas. Ciencia y tecnología** 16(1): 99-108, 2014. DOI 10.4067/S0718-221X2014005000009.
- BARBOSA, B. M.; COLODETTE, J. L.; CABRAL, C. P. T.; GOMES, F. J. B.; SILVA, V. L. Efeito da fertilização na qualidade da madeira de *Eucalyptus* spp. **Scientia Forestalis**, volume 42, n. 101, p.29-39, março de 2014.
- BARELLI, F. **Introdução à visão computacional**. Casa do Código, São Paulo, Brasil, 2019.
- BIAZUS, A.; HORA, A. B.; LEITE, B. G. P.; BANCO NACIONAL DO DESENVOLVIMENTO ECONÔMICO E SOCIAL (BNDES) Panorama de mercado: Painéis de madeira; **BNDES Setorial**, Rio de Janeiro, n. 32, p. 49-90; 2008.
- BORTOLETTO JÚNIOR, G. Produção de compensados com 11 espécies do gênero *Eucalyptus*, avaliação das suas propriedades físico-mecânicas e indicações para utilização. **Scientia Forestalis (IPEF)**, Piracicaba, v. n.63, p. 65-78, 2003.
- BORTOLETTO JÚNIOR, G; Avaliação da qualidade da madeira de *Pinus merkusii* para produção de lâminas. **Sci. For.**, Piracicaba, v. 36, n. 78, p. 95-103, jun. 2008.
- BORTOLETTO JÚNIOR, G.; GARCIA, J. N. Propriedades de resistência e rigidez à flexão estática de painéis OSB e compensados. **R. Árvore**, Viçosa-MG, v.28, n.4, p.563-570, 2004.
- CHO, T.; CONNERS, R. W.; ARAMAN, P. A.; A Comparison of Rule-Based, K-Nearest Neighbor, and Neural Net Classifiers for Automated Industrial Inspection **Annals of IEEE/ACM International Conference on Developing and Managing Expert System Programs**, September 30 - October 2, 1991 Washington, D.C.
- CONHECA, D.; CARVALHO, R. Comparação de métodos de classificação OBIA, máxima verossimilhança e distância mínima em imagem OLI/Landsat-8 em área de alta diversidade de uso do solo. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.
- CONNER, A. H. **Wood: Adhesives. Encyclopedia of Materials: Science and Technology**. USA: Elsevier Science, 2001.

- CONNERS, R. W.; CHO, T.; NG, C. T.; DRAYER, T. T.; ARAMAN, P. A.; BRISBON, R. L.; A multisensory machine vision system for hardwood defect detection. **Annals of Process Control/Production Management of Wood Products: Technology for the '90s**. Athens, Georgia, October 31- November 1, 1990.
- CUNHA, A. B.; FRANÇA, M. C.; ALMEIDA, C. C. F.; GORSKI, L.; CRUZ, R. C.; SANTOS, D. Avaliação do rendimento em madeira serrada de *Eucalyptus benthamii* e de *Eucalyptus grandis* por meio do desdobro tangencial e radial. **Floresta** (UFPR. Impresso), v. 45, p. 241-250, 2015.
- CUNHA A. B.; MATOS J. L. M.; Determinação do módulo de elasticidade em madeira laminada colada por meio de ensaio não destrutivo ("stress wave timer"). **R. Árvore**, v.34(2):345-354, 2010.
- DIAS, F. M.; FIORELLI, J.; LAHR, F. A. R.; DIAS, A. A.; A utilização de fibra de vidro como reforço em madeira compensada. **MADEIRA: arquitetura e engenharia** Jan.-jun., 2003.
- DRAKE, P. R.; PACKIANATHER, M. S. A Decision Tree of Neural Networks for Classifying Images of Wood Veneer. **Int. J. Adv. Manuf. Technol.** 14:280-285, 1998.
- FRIHART, C. R. **Wood adhesion and adhesives: handbook of wood chemistry and wood composites**. Boca Raton: CRC, 2005.
- FONSECA, S. M.; RESENDE, M. D. V.; ALFENAS, A. C.; GUIMARÃES, L. M. S.; ASSIS, T. F.; GRATTPAGLIA, D. **Manual prático de melhoramento genético do eucalipto**. Viçosa: UFV, 2010. 200 p.
- FUNCK, J. W.; ZHONG, Y.; BUTLER, D.A.; BRUNNER, C.C.; FORRER, J.B. Image segmentation algorithms applied to wood defect detection. **Computers and Electronics in Agriculture**, 41 (2003) 157/179
- GALPARSORO, L.; FERNÁNDEZ, S. P. Medidas de concordância: el índice Kappa. 2010. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em: 04 fev. 2017.
- GERNANDT, D. S.; LÓPEZ, G. G.; GARCÍA, S. O.; LISTON, A. Phylogeny and classification of *Pinus*. **TAXON**, 54 (1), February, p. 29-42. 2005.
- GOGUL, I.; KUMAR, V. Flower species recognition system using convolution neural networks and transfer learning. **4th International Conference on Signal Processing, Communications and Networking (ICSCN -2017)**, March 16 – 18, 2017, Chennai, India, 2017 DOI: 10.1109/ICSCN.2017.8085675.

- GOMINHO J., FIGUEIRA J., RODRIGUES J. C., PEREIRA H. Within-tree variation of heartwood, extractives and wood density in the *Eucalyptus* hybrid urograndis (*Eucalyptus grandis* x *E. urophylla*). **Wood Fibre Sci** 33:3–8, 2001.
- GUIMARÃES JÚNIOR, J. B.; MENDES, L. M.; MENDES, R. F.; MORI, F. A. Painéis compensado de Eucalipto: estudo de caso de espécies e procedências. **CERNE**, vol. 15, n.1, Jan.-mar, 2009, pp. 10-18. Lavras, Brasil.
- GUO, F.; ALTANER, C. M. Properties of rotary peeled veneer and laminated veneer lumber (LVL) from New Zealand grown *Eucalyptus globoidea*. **New Zealand Journal of Forestry Science** (2018) 48:3
- HAFEMANN, L. G.; OLIVEIRA, L. S.; CAVALIN, P. Forest species recognition using deep convolutional neural networks. **22nd International Conference on Pattern Recognition**, 1103 – 1107 p. 2014.
- HASELEIN, C. R.; LOPES, M. C.; SANTINI, E. J.; LONGHI, S. J.; ROSSO, S.; FERNANDES, D. L. G.; MENEZES, L. F.; Características tecnológicas da madeira de árvores matrizes de *EUCALYPTUS GRANDIS*. **Ciência Florestal**, Santa Maria, v. 14, n. 2, p. 145-155 2004.
- HILLIG, E. Qualidade de chapas aglomeradas estruturais, fabricadas com madeiras de *Pinus*, eucalipto e acácia negra, puras ou misturadas, coladas com tanino-formaldeído. 2000. 96 p. **Dissertação (Mestrado em Ciência Florestal)** – Santa Maria, Universidade Federal de Santa Maria, 2000.
- HU, K.; WANG, B.; SHEN, Y.; GUAN, J.; CAI, Y. Defect identification method for poplar veneer based on progressive growing generated adversarial network and MASK R-CNN model. **BioResources** 15(2), 3041-3052, 2020.
- HUANG, F. J.; LECUN, Y. Large-scale Learning with SVM and Convolutional Nets for Generic Object Categorization. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)**, 2006, pp. 284-291, doi: 10.1109/CVPR.2006.164.
- HUBER, H. A.; MCMILLIN, C. W.; MCKINNEY, J. P. Lumber defect detection abilities of furniture rough mill employees. **FOREST PRODUCTS JOURNAL** Vol. 35, 79-82 p. No Nov/Dez, 1985.
- INDÚSTRIA BRASILEIRA DE ÁRVORES. IBÁ, **Relatório anual 2018**. Brasília, p. 80, 2019.
- INDÚSTRIA BRASILEIRA DE ÁRVORES. IBÁ, **Relatório anual 2019**. Brasília, p. 100, 2020.

- IWAKIRI S. **Painéis de madeira reconstituída**. Curitiba: Fupef; 2005.
- IWAKIRI, S.; DEL MENEZZI, C. S.; LATORRACA, C.; VENSON, I.; MATOSKI, S. S. Produção de compensados de *Pinus taeda* e *Pinus oocarpa* com resina Fenol-formaldeído. **Cerne**, V.8, n. 2, p. 092- 0,97, 2002.
- IWAKIRI, S.; MANHIÇA, A. A.; RAMIREZ, M. G. L.; MATOS, J. L. M. de; BONDUELLE, G. M.; PRATA J. G. Avaliação da qualidade de painéis compensados de *Pinus maximinoi*, *Pinus oocarpa* e *Pinus tecunumannii* com diferentes composições estruturais. **Ciência Florestal**, Santa Maria, v. 22, n. 2, p. 315-321, abr.-jun., 2012.
- IWAKIRI S.; MATOS, J. L. M.; FERREIRA, E. S.; PRATA J. G.; TRIANOSKI, R. Produção de painéis compensados estruturais com diferentes composições de lâminas de *Eucalyptus saligna* e *Pinus caribaea*. **Revista Árvore**, Viçosa-MG, v.36, n.3, p.569-576, 2012.
- IWAKIRI, S.; NETO, A. R.; ALMEIDA, B. C.; BIASI, C. P.; CHIES, D.; GUI SANTES, F. P.; FRANZONI, J. A.; RIGATTO, P. A.; BETTEGA W. P. Avaliação da qualidade do compensado fenólico de *Eucalyptus grandis*. **Ciência Florestal**, Santa Maria, v. 16, n. 4, p. 437-443, 2006.
- IWAKIRI, S.; NIELSEN, I. R.; ALBERTI, R. A. R. Avaliação da influência de diferentes composições de lâminas de compensados estruturais de *Pinus elliottii* e *Eucalyptus saligna*. **CERNE**, V. 6, N. 2, P. 019-024, 2000.
- IWAKIRI, S.; SANCHES, F. G.; POTULSKI, D. C.; SILVA, J. B.; ANDRADE, M.; MARCHESAN, R. Avaliação do potencial de uso de espécies de *Pinus* tropicais e eucalipto na produção de painéis compensados uréicos. **FLORESTA**, Curitiba, PR, v. 42, n. 2, p. 277 - 284, abr./jun. 2012b.
- IWAKIRI S., TRIANOSKI R., CUNHA A. B., PRATA J. G., HARA M., BILA N. F. *et al.* Avaliação da resistência de juntas coladas da madeira de *Eucalyptus benthamii* com diferentes adesivos e faces de colagem. **Scientia Forestalis**, 2013; 41(99).
- KLOCK, U.; MUÑIZ, G. I. B. DE; HERNANDEZ, J. A.; ANDRADE, A. S. de; **Química da madeira**, 3° ed., Curitiba, 2005.
- KOLLMANN, F. F.P., KUENZI, E. W., STAMM, A. J. **Principles of Wood Science and Technology - II Wood Based Materials**. Springer-Verlag Berlin Heidelberg XII, 703p. 1975. DOI: 10.1007/978-3-642-87931-9.

- KWON, O.; LEE, H. G.; LEE, M.; JANG, S.; YANG, S.; PARK, S.; CHOI, I.; YEO, H. Automatic Wood Species Identification of Korean Softwood Based on Convolutional Neural Networks. **J. Korean Wood Sci. Technol.** 2017, 45(6): 797~808.
- LAMPRECHT, H. **Silvicultura nos trópicos: ecossistemas florestais e respectivas espécies arbóreas – possibilidades e métodos de aproveitamento sustentado.** GTZ Eschborn (tradução de Guilherme de Almeida-Sedas e Gilberto Calcagnatto) – Rossdorf: TZ – Verl. – Ges, 1990.
- LECUN, Y.; BENGIO, Y. Convolutional networks for images, Speech, and time-series. **The handbook of brain theory and neural networks** 3361.10 (1995): 1995.
- 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** 1989;1(4):541–551.
- MARCHIORI, J. N. C.; **Dendrologia das gimnospermas.** Santa Maria, Editora UFSM, 161p. 2005.
- MARRA, F. S. **Technology of wood bonding – principles in practice.** Van Nostrand Reinhold, New York. 453p. 1992.
- MATTOS, P. P.; BORTOLI, C.; MARCHESAN, R.; ROSOT, M. C. Caracterização Física, Química e Anatômica da Madeira de *Araucaria angustifolia* (Bert.) O. Kuntze. **Comunicado Técnico**, Colombo, n. 160 2006.
- MENDES, R. F.; BORTOLETTO JÚNIOR, G.; GARLET, A.; VIDAL, J. M.; ALMEIDA, N. F., JANKOWSKY, I. P. Resistência de painéis compensados de *Pinus taeda* tratados com preservantes ao ataque de fungos xilófagos. **Cerne**, Lavras, v. 20, n. 1, p. 105-112, jan./mar. 2014
- MORA, A. L.; GARCIA, C. H. **A cultura do eucalipto no Brasil.** São Paulo: Sociedade Brasileira de Silvicultura, 2000. 111 p.
- MUNIZ, G. I. B.; IWAKIRI, S.; VIANA, L. C.; ANDRADE, M.; WEBER, C.; ALMEIDA, V. C. Production of plywood panels from *Pinus taeda* using veneers of differing densities and phenol-formaldehyde resin with high and low molecular weights. **Cerne**, v.19, n.2, p.315-321, abr/jun., 2013.
- NOCK, H. P., RICHTER, H. G.; Adesão e Adesivos – Adesivos e sua aplicação na indústria madeireira. **Tópicos de Tecnologia da Madeira.** Universidade Federal do Paraná, 94p., Curitiba, 1978.

- OLIVEIRA, A. P. A. Um método para classificação de imagens de madeira usando Local Binary Patterns. **Dissertação (Mestrado em Ciência da Computação)**. Universidade Federal de Pernambuco - UFP Recife, PB, p. 127, 2013.
- OLIVEIRA, J. T. S.; HELLMEISTER, J. C.; SIMÕES, J. W.; TOMAZELLO FILHO, M. Caracterização da madeira de sete espécies de eucaliptos para a construção civil: 1- avaliações dendrométricas das árvores. **Scientia Forestalis**, n. 56, p. 113-124, dez. 1999.
- PALMA, H. A. L.; MARCO, J. T.; BALLARIN, A. W. Propriedades físicas e mecânicas de compensados com lâminas de *Pinus taeda* L. tratadas com CCA. **Anais do II Congresso Latinoamericano de Estructuras de Madera / II Congresso Ibero-Latinoamericano de la Madera en la construcción**. T4-04, Buenos Aires, Argentina.
- PRATA, J. G.; Estudo da viabilidade tecnológica do uso de espécies de *Pinus* tropicais para produção de painéis colados lateralmente (Edge Glued Panels – EGP). **Tese (Doutorado em Engenharia Florestal)** – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2010.
- QUILHÓ, T.; MIRANDA, I.; PEREIRA, H. Within-tree variation in wood fiber biometry and basic density of the urograndis eucalypt hybrid (*Eucalyptus grandis* × *E. urophylla*). *IAWA Journal*, Vol. 27 (3), 2006: 243–254
- RAKNES, E.; The Influence of Production Conditions on the Strength of Finger-Joints, Production, marketing and use of finger-jointed sawnwood. **Forestry Sciences** p.282, Hague, Holland. 1982.
- RAVINDRAN, P.; COSTA, A.; SOARES, R.; WIEDENHOEFT, A. C. Classification of CITES-listed and other neotropical Meliaceae wood images using convolutional neural networks. **Plant Methods** (2018) 14:25 <https://doi.org/10.1186/s13007-018-0292-9>.
- REIS, M. S., CARNEIRO, C. M. R., GALVÃO, A. P. M., SOBRAL Filho, M., PAIXÃO, J. C., LISBOA, C. D. J., SIQUEIRA, J. D. P. Adesão e Adesivos para Madeira – Teorias de Adesão e a Natureza das Colagens com Madeira. **Série Técnica**. Ministério da Agricultura, Laboratório de Produtos Florestais, 22p. Brasília, DF. 1982.
- RIBEIRO, B. M. G., KUX, H. J. H. Classificação orientada a objeto para mapeamento do uso do solo – métodos de análise de expansão urbana. **Anais do XIV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Natal. 2009

- SÁ, V. A.; GUIMARÃES JÚNIOR, J. B.; BUFALINO, L.; COUTO, A. M.; MENDES, L. M.; SANTOS R. C. Absorção de superfície de painéis compensados. **Cerne**, Lavras, V. 16, Suplemento, p 53-57, jul. 2010.
- SELLERS JR., T. Adhesive in the Wood Industry. In: PIZZI. A.; MITTAL, K. L. **Handbook of adhesive technology**. New York: Marcel Dekker, 1994.
- SHARMA S. K.; SHUKLA, S. R.; SHASHIKALA, S.; SRI POORNIMA, V. Axial variations in anatomical properties and basic density of Eucalypt urograndis hybrid (*Eucalyptus grandis* × *E. urophylla*) clones. **Journal of Forestry Research** Volume 26, Issue 3, pp 739–744, sep. 2015.
- SHI, J.; LI, Z.; ZHU, T.; WANG, D.; NI, C. Defect detection of industry wood veneer based on NAS and multi-channel mask R-CNN. **Sensors** 2020, 20, 4398; doi:10.3390/s20164398.
- SI GROUP CRIOS RESINAS S/A. Resina para madeira ARGOS 660 HT. Rio Claro, SP, 2018. 2p. (**Boletim Técnico**).
- SI GROUP CRIOS RESINAS S/A. Resina para madeira CR-7015/12. Rio Claro, SP, 2018 2p. (**Boletim Técnico**).
- SOUZA, F. Propriedades mecânicas, físicas, biológicas e avaliação não destrutiva de painéis de lâminas paralelas (LVL) com madeira de *Pinus oocarpa* e *P. kesiya*. 133p. **Dissertação (Mestrado)** – Universidade de Brasília, Faculdade de tecnologia, Brasília, 2009.
- SOUZA, M. M.; SILVA, D. A.; ROCHADELLI, R.; SANTOS, R. C.; Estimativa de poder calorífico e caracterização para uso energético de resíduos da colheita e do processamento de *Pinus taeda*. **FLORESTA**. Curitiba, PR, v. 42, n. 2, p. 325 - 334, abr./jun. 2012.
- TODOROKIA, C. L.; LOWELL, E.C.; DYKSTRA, D. Automated knot detection with visual post-processing of Douglas-fir veneer images. **Computers and Electronics in Agriculture** 70 (2010) 163–171
- TRIANOSKI, R.; MATOS, J. L. M.; IWAKIRI, S.; PRATA, J. G. Avaliação da estabilidade dimensional de espécies de *Pinus* tropicais. **Floresta e Ambiente** 2013; v. 20 (3) p.398-406.
- TSOUMIS, George T. **Science and technology of wood: structure, properties, utilization**. Vol. 115. New York: Van Nostrand Reinhold, 1991.

- URBONAS, A.; RAUDONIS, V.; MASKELIUNAS, R.; DAMAŠEVICIUS, R. Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning. **Appl. Sci.** 2019, 9, 4898; doi:10.3390/app9224898
- VIEIRA, F. H. A. Image processing through machine learning for wood quality classification. **Tese (Doutorado em Engenharia Mecânica)**. Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP, Guaratinguetá, Brasil, 119 p. 2016.
- WELLONS, J. D.; KRAHMER, R. L.; SANDOE, M. D.; JOKERST, R. W. Thickness loss in hot-pressed plywood. **FOREST PRODUCTS JOURNAL** VOL. 33, No. 1. jan. 1983.
- YANG, F.; WANG, Y.; WANG, S.; CHENG, Y. Wood Veneer Defect Detection System Based on Machine Vision at International Symposium on Communication Engineering & Computer Science (CECS 2018) **Advances in Computer Science Research**, v. 86, 2018.
- YANG, Y.; ZHOU, X.; LIU, Y.; HU, Z.; DING, F. Wood defect detection based on depth extreme learning machine. **Appl. Sci.** 2020, 10, 7488; doi:10.3390/app10217488
- ZAMRI, M. I. P.; CORDOVA, F.; KHAIRUDDIN, A. S. M.; MOKHTAR, N.; YUSOF, R. Tree species classification based on image analysis using Improved-Basic Gray Level Aura Matrix. **Computers and Electronics in Agriculture**, 124 (2016) 227–233.
- ZHANG J, YAO M, CHEN J, JIANG Z, MA Y. Synthesis and properties of polyurethane elastomers based on renewable castor oil polyols. **J. Appl. Polym. Sci.**; 136,47309, 2019.

2. QUALIDADE DA COLAGEM DE PAINÉIS COMPENSADOS DE USO EXTERIOR PRODUZIDOS DE *Pinus kesiya* E *Eucalyptus grandis* X *Eucalyptus urophylla*

BONDING QUALITY OF EXTERNAL-USE PLYWOOD PANEL PRODUCED WITH *PINUS KESIYA* AND *EUCALYPTUS GRANDIS* X *EUCALYPTUS UROPHYLLA*

Caio Cesar Faedo de Almeida e Geraldo Bortoletto Júnior

RESUMO

A crescente demanda por madeira para o suprimento das indústrias florestais estimula o cultivo de espécies de alta produtividade. Entretanto, as características da matéria-prima de rápido crescimento diferem daquelas obtidas de florestas tradicionais e as indústrias necessitam adaptar seus processos para manter o atendimento do mercado consumidor. O estudo objetivou avaliar a resistência, rigidez e a qualidade de colagem de painéis compensados de uso exterior de *Pinus kesiya* e *Eucalyptus grandis* x *Eucalyptus urophylla*. Foram produzidos 16 painéis com as espécies citadas e em duas gramaturas do adesivo fenol-formaldeído, 200 e 175 g/m². Os painéis foram produzidos com cinco lâminas de 2 mm de espessura, o ciclo de prensagem utilizou a temperatura de 150 °C por 10 minutos para *P. kesiya* e 11 minutos para *E. grandis* x *E. urophylla*. As propriedades avaliadas foram massa específica – ME (ABNT – NBR 9.485, 2011), flexão estática (ABNT – NBR 9.533, 2012) em módulo de ruptura (MOR) e módulo de elasticidade (MOE). A qualidade de colagem foi verificada pelo ensaio de cisalhamento na linha de cola (ABNT – NBR 12.466-1, 2012), por meio da tensão máxima (Tmax) e do percentual de falha na madeira (WF%). A análise dos dados foi realizada pelo teste T de Student (5%) e os resultados foram comparados aos requisitos das normas supracitadas e com o Catálogo Técnico nº1 da ABIMCI (2002). Como resultados, verificam-se os maiores valores de ME para os tratamentos de *E. grandis* x *E. urophylla*. Quanto à resistência (MOR) houve equivalência entre os tratamentos avaliados. Para a rigidez (MOE) foi verificada a superioridade dos tratamentos de *Eucalyptus* em ambas as direções. Para o cisalhamento na linha de cola, os painéis produzidos com *Pinus kesiya* foram superiores em Tmax e WF% nas três condições avaliadas (seco, água fria, e ciclo BDB). Apenas o tratamento que utilizou *E. grandis* x *E. urophylla* e a gramatura de 200 g/m² não atingiu os requisitos da norma NBR 12.466 (2012). O experimento demonstrou que ambas as espécies podem ser recomendadas para a produção de compensados e a gramatura de 175 g/m² se mostrou mais adequada à utilização industrial pelo atendimento dos requisitos e pela economia de insumos.

Palavras-chave: fenol-formaldeído; espécies florestais não-convencionais; resistência e rigidez; cisalhamento na linha de cola.

ABSTRACT

The growing demand for wood to supply forestry industries favors the cultivation of high-productivity species. However, the characteristics of the fast-growing raw material differ from those obtained from traditional forests and industries need to adapt their processes to fulfill the consumer market. The study aimed to evaluate the resistance, stiffness, and bonding quality of plywood panels for outdoor use of *Pinus kesiya* and *Eucalyptus grandis* x *Eucalyptus urophylla*. Sixteen panels were produced with the species mentioned and in two weights of the phenol-formaldehyde adhesive, 200 and 175 g/m². The panels were produced with five 2 mm thick veneers, the pressing cycle used a temperature of 150 °C for 10 minutes for *Pinus kesiya* and 11 minutes for *E. grandis* x *E. urophylla*. The properties evaluated were specific mass – ME (ABNT – NBR 9485, 2011), static bending (ABNT – NBR 9533, 2012) in modulus of rupture (MOR), and modulus of elasticity (MOE). Bonding quality was verified by the glue-line shear test (ABNT – NBR 12466-1, 2012), through the maximum tension (Tmax) and the percentage of wood failure (WF%). Data analysis was performed using Student's t-test (5%) and the results were compared to the requirements of the aforementioned standards and the Technical Catalog No. 1 of ABIMCI (2002). As a result, the highest ME values were verified for the treatments of *E. grandis* X *E. urophylla*. The resistance (MOR), the evaluated treatments were equivalent. For stiffness (MOE) the superiority of *Eucalyptus* treatments in both directions was verified. For glue-line shear, the panels produced with *P. kesiya* were superior in Tmax and WF% in the three evaluated conditions (dry, cold water, and BDB cycle). Only the treatment that used *E. grandis* X *E. urophylla* and the weight of 200 g/m² did not meet the requirements of standard NBR 12.466 (2012). The experiment showed that both species can be recommended for plywood production, and the weight of 175 g/m² proved to be more suitable for industrial use by meeting the requirements and saving resources.

Key-words: phenol-formaldehyde; unconventional forest species; resistance and stiffness; glue-line shear test.

2.1. Introdução

Para o suprimento das indústrias de produtos de madeira é necessário a seleção e o plantio de espécies ou genótipos com elevadas taxas de crescimento e menores ciclos de produção e diversas espécies de *Eucalyptus* vem sendo utilizadas

como opções viáveis para diferentes ambientes e condições climáticas (IWAKIRI *et al.*, 2013; ALMEIDA *et al.*, 2004a; GUIMARÃES JÚNIOR *et al.*, 2009).

Segundo a IBÁ (2020), no ano de 2019 o Brasil apresentava o total de 9,0 milhões de hectares de florestas plantadas, com aumento de 2,4% em relação a 2018. Deste total, 77% é representada pelo cultivo de eucalipto, com 6,97 milhões de hectares, e 18% de *Pinus*, com 1,64 milhões de hectares.

Entre os materiais promissores do gênero *Eucalyptus* pode-se destacar o híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla* desenvolvido com a combinação das características de elevado crescimento do *E. grandis* e da alta massa específica e qualidade de fibra de *E. urophylla* (QUILHÓ *et al.* 2006; SHARMA *et al.*, 2015).

Enquanto entre as coníferas os materiais de *Pinus* tropicais como o *Pinus caribaea*, *P. tecunumanni*, *P. oocarpa* e o *P. kesiya* destacam-se por apresentarem características tecnológicas da madeira muito próximas às principais espécies do gênero como o *P. taeda* e o *P. elliottii* (IWAKIRI 2012; TRIANOSKI, 2012; MATOS *et al.* 2019).

No contexto de aumento das áreas de plantio e da disponibilidade de espécies alternativas ao mercado consumidor, o setor de transformação mecânica e a indústria de painéis de madeira apresentam maior capacidade de para absorver estes recursos (ABIMCI, 2009).

No segmento de painéis de madeira a indústria de compensados demonstra ainda maior eficiência na utilização da matéria-prima de espécies alternativas, principalmente pela maior flexibilidade do processo produtivo dos painéis.

O painel compensado é formado através da colagem de lâminas de madeira em camadas ortogonais e sobrepostas, sendo que o direcionamento entre lâminas resulta em excelente estabilidade dimensional e uniformidade das propriedades mecânicas nas duas direções do plano do painel (TSOUMIS, 1991; IWAKIRI, 2005; BORTOLETTO JÚNIOR e GARCIA, 2004).

No entanto, mesmo apresentando boa estabilidade dimensional, a utilização de lâminas de madeira na construção do painel compensado causa uma maior susceptibilidade aos problemas recorrentes das características da madeira das espécies utilizadas.

Dentre as características da madeira que afetam a qualidade de painéis compensados, Iwakiri (2005), destaca a necessidade de atenção às características

anatômicas de porosidade e permeabilidade da madeira, e sua influência na formação das linhas de cola. Sendo necessário o ajuste da viscosidade do adesivo dependendo da facilidade ou não da penetração do adesivo na estrutura da madeira.

Kolck *et al.* (2005), também cita as propriedades químicas como relevantes à produção de painéis de madeira, sendo importante evitar a utilização de espécies com elevados teores de extrativos na madeira. A interação dos extrativos com o adesivo pode causar alterações prejudiciais ao ciclo de prensagem e comprometer todo o lote em produção.

Com relação às propriedades físicas da madeira Prata (2010), descreve que a massa específica e os coeficientes de variação dimensional podem contribuir significativamente para o enfraquecimento ou mesmo ruptura das ligações adesivas durante e após a cura do adesivo que (PRATA, 2010). Sendo preferível utilizar espécies mais estáveis para a produção de compensados.

O conhecimento destas propriedades permite selecionar espécies não convencionais disponíveis no mercado para a utilização na indústria de compensados. No entanto, é necessário avaliar o desempenho destas espécies como produto a que se destinam.

O presente estudo objetivou avaliar a resistência, rigidez e qualidade de colagem de painéis compensados de uso exterior de *Pinus kesiya* e *Eucalyptus grandis* x *Eucalyptus urophylla*, em duas gramaturas de adesivo a base de resina fenol-formaldeído.

2.2. Material e métodos

2.2.1. Matéria-Prima

A matéria-prima utilizada para a realização do trabalho foi selecionada a partir de dois lotes de lâminas de *Pinus kesiya* e de um híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*, disponíveis no Laboratório de Laminação e Painéis de Madeira (LLAPAM) da Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ) da Universidade de São Paulo (USP).

As lâminas de *P. kesiya* foram originalmente obtidas a partir de árvores de 30 anos, de um talhão experimental localizado na ESALQ, em Piracicaba (SP). As lâminas de *E. grandis* x *E. urophylla* foram obtidas de um talhão experimental de 9 anos na cidade de Aguaí (SP) (Almeida *et al.* 2004).

2.2.2. Montagem dos painéis e obtenção de corpos de prova

Para montagem dos painéis foram utilizadas lâminas de madeira com dimensões de 500 × 500 × 2 mm em largura, comprimento e espessura, respectivamente, as lâminas foram secas em estufa com circulação forçada de ar com temperatura de 60 °C até a umidade de 6 e 8% para ambas as espécies.

A resina utilizada para a produção dos painéis compensados foi a fenol-formaldeído CR-7015/12 com teor de sólidos de 50,61%. As formulações dos adesivos seguiram as recomendações contidas no Boletim Técnico do fornecedor (CRIOS, 2018) e utilizaram os componentes resina, farinha de trigo e água, as proporções por peso foram ajustadas conforme a espécie.

Para a produção dos painéis de *P. kesiya* foi utilizada a proporção de 100:10:5 partes, enquanto para os painéis de *E. grandis* x *E. urophylla* foi utilizada a proporção de 100:10:10 partes de resina, farinha de trigo e água.

A diferença entre as espécies foi necessária pela ocorrência de excesso de penetração do adesivo nos painéis de *P. kesiya* (linha de cola faminta) e pela dificuldade de penetração do adesivo nos painéis de *E. grandis* x *E. urophylla* durante os testes preliminares.

Os adesivos foram aplicados manualmente utilizando espátulas de plástico em linha dupla nas lâminas de madeira, nas gramaturas de 175 e 200 g/m² para a produção de painéis compensados de cinco lâminas.

Após a montagem dos painéis foi realizada a prensagem a frio, com pressão de 2 kgf/cm² por 10 minutos para os compensados de *P. kesiya* e 20 minutos para os painéis de *E. grandis* x *E. urophylla*.

A prensagem a quente foi realizada com temperatura de 150 °C para ambas as espécies como recomendado pelo fornecedor do adesivo no Boletim Técnico disponibilizado (CRIOS, 2018). A pressão e os ciclos de prensagem foram ajustados durante a produção das chapas teste sendo verificada a necessidade de ciclos específicos para cada espécie.

Os painéis de *P. kesiya* utilizaram pressão de 11 kgf/cm² e tempo total de 10 minutos (1 + 8 + 1) entre fechamento, prensagem e abertura da prensa, enquanto, para *E. grandis* x *E. urophylla* foi aplicada a pressão de 13 kgf/cm² e ciclo de prensagem totalizando 11 minutos (1 + 8 + 2).

O delineamento experimental foi inteiramente casualizado em arranjo fatorial 2 × 2, foram analisados dois fatores, espécie e gramatura, com dois níveis cada,

perfazendo quatro tratamentos (T1, T2, T3 e T4) com quatro repetições cada, totalizando 16 painéis produzidos.

O tratamento T1 foi composto pela espécie *P. kesiya* e gramatura de 200 g/m², enquanto o tratamento T2 utilizou a mesma espécie na gramatura de 175 g/m². O tratamento T3 foi produzido com a espécie a *E. urophylla* x *E. grandis* na gramatura de 200 g/m², e por fim, o tratamento T4 utilizou a espécie a *E. urophylla* x *E. grandis* na gramatura de 175 g/m².

Após a produção os painéis foram acondicionados por 45 dias no Laboratório de Ensaios Mecânicos de Madeira e Derivados (LEMMAD) da ESALQ/USP do campus de Piracicaba (SP), em ambiente climatizado com temperatura de 22 ± 2° C e umidade relativa do ar de 65% ± 5 para uniformização da umidade. Após a climatização, foi realizado o esquadrejamento e a obtenção dos corpos de prova para os ensaios de flexão estática e de cisalhamento na linha de cola.

A obtenção dos corpos de prova para o ensaio de flexão estática foi conduzida conforme a norma NBR 9.533 (ABNT, 2012), nas dimensões de 300 × 75 × 10 mm em comprimento, largura e espessura, respectivamente, dois na direção perpendicular e dois na direção paralela, totalizando 16 amostras por tratamento.

Os corpos de prova de cisalhamento na linha de cola foram obtidos segundo a norma NBR 12.466-1 (ABNT, 2012), nas dimensões de 100 × 25,4 × 10 mm em comprimento, largura e espessura, respectivamente, totalizando 120 corpos de prova por tratamento.

Para a obtenção da massa específica (ME) dos painéis foi necessário adaptar a norma NBR 9.485 (ABNT, 2011) pela indisponibilidade de área do painel nas dimensões requisitadas pela norma. Para estimar a ME dos painéis, foram utilizados os corpos de prova de flexão estática para a mensuração dimensional e de massa.

2.2.3. Determinação das propriedades mecânicas

A determinação das propriedades mecânicas dos painéis compensados foi realizada em máquina universal de ensaio da marca Contenco, modelo UMC300 com capacidade de aplicação de até 30 toneladas de força, instalada no LEMMAD.

O ensaio de flexão estática foi conduzido seguindo o procedimento descrito na norma NBR 9.533 (ABNT, 2012), com a obtenção dos valores do módulo de ruptura e do módulo de elasticidade ambos expressos na unidade de MPa.

Os ensaios de cisalhamento das lâminas de cola centrais das amostras foram realizados seguindo os parâmetros apresentados pela norma NBR 12.466-1 (ABNT, 2012) para a obtenção da tensão máxima de ruptura expressa em MPa e o percentual de falha na coesiva na madeira mensurado através de avaliação visual.

Os painéis foram projetados para atender a classe de uso 3 – Alta umidade / Ambiente externo da norma NBR 12.466-2 (ABNT, 2012), e por isto, aos ensaios de cisalhamento na linha de cola, foram realizados após a aplicação de pré-tratamentos: seco (D); após imersão em água fria por 24 horas (CW); imersão em água fria seguido da aplicação de um ciclo de fervura, secagem e fervura (BDB). Cada condição de ensaio contou com 40 corpos de prova por tratamento.

A mensuração do percentual de falha coesiva aparente considerou ambas as faces das peças ensaiadas, totalizando 80 amostras por condição em cada tratamento.

A mensuração do WF% foi realizada seguindo as recomendações da norma NBR 12.466-1 (ABNT, 2012a) NBR 12.466-2 (ABNT, 2012b), que descrevem que cada amostra deve se enquadrar em uma das 10 classes de qualidade de colagem, como apresenta a tabela 1 abaixo.

Tabela 1. Definição de classes de WF%

Table 1. WF% classes definition

WF% mensurado	Classe de WF%
Ruptura fora da área de avaliação	Descarte
$WF\% \leq 10\%$	1
$10\% < WF\% \leq 20\%$	2
$20\% < WF\% \leq 30\%$	3
$30\% < WF\% \leq 40\%$	4
$40\% < WF\% \leq 50\%$	5
$50\% < WF\% \leq 60\%$	6
$60\% < WF\% \leq 70\%$	7
$70\% < WF\% \leq 80\%$	8
$80\% < WF\% \leq 90\%$	9
$90\% < WF\%$	10

Para a avaliação de WF% além das recomendações presentes na norma utilizada foi implementada uma metodologia complementar para aumentar a precisão das medições.

Foi utilizada uma grade quadriculada de acrílico transparente com dimensões externas de 25 × 25 mm, composta por 25 unidades quadradas com 5 mm em largura e altura, correspondendo a 4% da área total em avaliação.

A sobreposição da grade sobre a área de análise contabilizou as unidades preenchidas por falha na madeira e o somatório foi multiplicado por 4% para a obtenção do percentual de falha na madeira das amostras.

A classificação das unidades como falha na madeira seguiu a recomendação da NBR 12.466-2 (ABNT, 2012). A contabilização das unidades utilizou um sistema binário de classificação, foram consideradas unidades de falha na madeira aquelas que apresentavam superfície de falha na madeira superior a 50% da área da unidade. Caso contrário a unidade era considerada unidade de falha no adesivo.

Os resultados obtidos para as faces das amostras foram anotados, variando de 0 a 100 de WF% e enquadrados em uma das 10 classes conforme a norma utilizada.

2.2.4. Análise de Dados

As análises estatísticas consistiram na aplicação de testes para verificação da homoscedasticidade e normalidade dos dados pelos testes de Levene, Kolmogorov-Smirnov e Shapiro-Wilk a 5% de probabilidade.

Atendidos os devidos pressupostos, foi realizada a análise de variância (ANOVA) em esquema fatorial 2 X 2 para verificar a existência de diferença estatística entre tratamentos ao nível de 5% de probabilidade. Para as análises em que foi verificada diferença estatística foi aplicado o teste de T de Student a 5% de probabilidade para distinção entre médias.

Para ambos os ensaios mecânicos realizados, além da verificação do atendimento dos requisitos mínimos para o ensaio de flexão estática apresentado pela norma NBR 9.533 (ABNT, 2012), e dos requisitos para o ensaio de cisalhamento na linha de cola pelas normas NBR 12.466-1 (ABNT, 2012a) e NBR 12.466-2 (ABNT, 2012b).

Adicionalmente foi utilizado o Catálogo Técnico para Compensados de *Pinus* (ABIMCI, 2002) como parâmetro de avaliação. Os tratamentos foram comparados aos painéis de *Pinus* de cinco lâminas e espessura de 9 mm.

2.3. Resultados e discussão

Os resultados de resistência, rigidez e qualidade de colagem dos quatro tratamentos de compensados produzidos no experimento são apresentados a seguir, bem como a comparação de desempenho com experimentos realizados em condições semelhantes de produção.

2.3.1. Massa específica e Flexão estática

A avaliação da Massa Específica (ME) resistência e rigidez dos painéis à flexão estática obteve os módulos de ruptura (MOR) e elasticidade (MOE) para as direções perpendicular e paralela.

Para as três propriedades avaliadas foi verificada a normalidade e homogeneidade de variâncias para as duas direções de ensaio.

Para ME foi verificada diferença estatística apenas para o fator Espécie em ambas as direções avaliadas, os tratamentos compostos por lâminas de *E. urophylla* x *E. grandis* apresentaram média superior ao observado para *P. kesiya*.

Nos ensaios de flexão estática foi verificado que para a direção perpendicular não houve diferença estatística para MOR, enquanto para MOE apenas o fator Espécie foi significativo com maiores valores observados para a espécie *Eucalyptus*.

Para a direção paralela foi verificada diferença estatística em MOR para o fator gramatura, o tratamento T4 apresentou melhor resultado para a espécie *Eucalyptus* apenas.

Para MOE apenas o fator Espécie foi significativo e os painéis produzidos com lâminas de *Eucalyptus* apresentaram resultados superiores aos de *P. kesiya*.

Os resultados das Anovas de ME, MOR e MOE são exibidos na Tabela 2.

Tabela 2. Análise de variância para ME, MOR, MOE nas direções perpendicular e paralela

Table 2. Analysis of variance of ME, MOR, MOE in the perpendicular and parallel directions

Propriedade	Fator		
	Espécie (E)	Gramatura (G)	Interação (E * G)
ME Perpendicular	0,001*	0,670 ^{ns}	0,491 ^{ns}
ME Paralela	0,001*	0,271 ^{ns}	0,321 ^{ns}
MOR Perpendicular à flexão	0,326 ^{ns}	0,186 ^{ns}	0,889 ^{ns}
MOE Perpendicular à flexão	0,026*	0,317 ^{ns}	0,920 ^{ns}
MOR Paralela à flexão	0,083 ^{ns}	0,031*	0,063 ^{ns}
MOE Paralela à flexão	0,001*	0,883 ^{ns}	0,489 ^{ns}

* = Fator significativo verificado pela ANOVA a 5% de probabilidade. Ns= Fator não significativo pelo teste de ANOVA a 5% de probabilidade.

* = Significant factor verified by ANOVA at 5% of probability. NS = Non-significant factor by ANOVA test at 5% of probability.

As médias de ME, MOR e MOE dos tratamentos desenvolvidos nas duas direções avaliadas e seus respectivos coeficientes de variação (CV) são apresentados na Tabela 3.

Tabela 3. Massa específica (ME), Módulo de ruptura (MOR) e de elasticidade (MOE) à flexão estática para os painéis produzidos.

Table 3. Specific gravity (ME), Modulus of rupture (MOR) and elasticity (MOE) on static bending for the produced panels.

Propriedade	Tratamento	N	ME (g/cm ³)	MOR (MPa)	MOE (MPa)
Perpendicular	T1	8	0,679 B (3,46)	43,10 A (9,06)	975 B (13,79)
	T2	8	0,669 B (3,78)	40,75 A (17,78)	940 B (13,17)
	T3	8	0,707 A (2,06)	41,44 A (10,54)	1.078 A (4,04)
	T4	8	0,709 A (3,86)	38,55 A (14,84)	1.032 A (12,12)
	Total	32			
Paralela	T1	8	0,684 B (2,80)	82,07 B (13,20)	3.242 B (15,81)
	T2	8	0,683 B (3,54)	83,15 B (13,82)	3.121 B (20,43)
	T3	8	0,713 A (2,48)	81,63 B (8,43)	3.567 A (6,33)
	T4	8	0,696 A (3,41)	94,99 A (5,32)	3.418 A (4,71)
	Total	32			

Médias com letra igual na mesma coluna, não diferem estatisticamente entre si pelo teste T de Student a 5% de probabilidade. O Coeficiente de variação (CV) das médias é apresentado em parênteses.

Means Followed by the same letter in the columns did not differ by Student's T test at 5% of probability. The means Variation Coefficient (CV) is presented in the parenthesis.

Os resultados de ME dos painéis compensados apresentaram a tendência esperada, com maiores valores observados para os tratamentos T3 e T4, compostos por lâminas da espécie *Eucalyptus*.

A ME verificada para os tratamentos T1 e T2 foi semelhante aos resultados verificados para painéis de cinco lâminas construídos com *P. taeda* apresentados

por Iwaikiri *et al.* (2006). É superior ao verificado para painéis de 10 mm de espessura produzidos com cinco lâminas de *P. oocarpa* (MATOS *et al.*, 2019), *P. sylvestris* e *P. nigra* (DEMIRKIR *et al.*, 2016).

Os painéis construídos com lâminas de *Eucalyptus* apresentaram médias de ME superiores aos tratamentos produzidos com lâminas de *P. kesiya*, no entanto, T3 e T4 apresentam médias de ME inferiores aos resultados verificados para diversas espécies de *Eucalyptus* apresentados por Guimarães Júnior *et al.* (2009) e Bortoletto Júnior (2003).

Este comportamento foi decorrente da pouca idade do material de *E. grandis* x *E. urophylla* utilizado no experimento (9 anos), o predomínio de madeira juvenil tem como característica uma menor massa específica quando comparado ao lenho adulto.

Comportamento verificado nos artigos citados anteriormente, os materiais de *Eucalyptus* que apresentaram maior ME foram provenientes de plantios mais antigos e por consequência, uma maior proporção de lâminas compostas por lenho adulto.

A relação entre ME e a resistência mecânica de produtos engenheirados apresenta-se geralmente como uma tendência diretamente proporcional, especialmente para os painéis de madeira (LIMA *et al.*, 2013; IWAKIRI *et al.*, 2013).

A influência da ME no desempenho dos painéis sob o esforço de flexão estática foi evidente no MOR e no MOE, com efeito significativo do fator espécie, propriedade características da madeira que refletiu em maiores médias de T3 e T4.

Os tratamentos avaliados apresentaram resultados semelhantes aos observados em estudos com compensados produzidos em condições semelhantes de gramatura, ciclos e temperaturas de prensagem, utilização de lâminas de mesmos gêneros e espessuras das utilizadas no experimento.

Os tratamentos que utilizaram a espécie *P. kesiya* apresentaram resultados semelhantes ao observado por Iwakiri *et al.* (2013) e Reis *et al.* (2019) para o MOR e o MOE nas duas direções avaliadas de compensados de *P. taeda*, *P. caribaea* e *P. oocarpa* provenientes de plantios de idades variando de 22 a 28 anos.

Os tratamentos produzidos com lâminas do híbrido *E. grandis* x *E. urophylla* apresentaram resultados próximos aos valores do MOR e MOE em ambas as direções para compensados de 10 mm de espessura e cinco lâminas provenientes de diferentes clones de *E. grandis* x *E. urophylla* de 31 anos (GUIMARÃES JÚNIOR *et al.*, 2009).

Contudo, ao analisar os resultados de compensados de cinco lâminas com espessura final de 10 mm, produzidos com onze espécies de *Eucalyptus* com idades variando entre 17 a 23 anos apresentados por Bortoletto Júnior (2003), os tratamentos T3 e T4 apresentaram resultados inferiores para o MOR e o MOE nas duas direções avaliadas.

No entanto, o desempenho inferior dos tratamentos de *E. grandis* x *E. urophylla* aos estudos comparados pode ser devido à pouca idade das árvores utilizadas (9 anos), em que predomina a madeira juvenil, enquanto para *P. kesiya* os resultados são mais próximos à bibliografia por ser proveniente de um plantio de 33 anos.

Quando os resultados dos tratamentos são comparados aos requisitos apresentados pelo Catálogo Técnico nº1 (ABIMCI, 2002), foi verificado que todos os tratamentos apresentam valores médios de ME e MOR superiores ao máximo indicado para compensados de cinco lâminas e espessura nominal de 9 mm.

Contudo, para MOE nenhum dos tratamentos atingiu os requisitos mínimos de rigidez solicitado pelo Programa Nacional de Qualidade da Madeira PNQM (ABIMCI, 2021).

2.3.2. Qualidade de colagem

Para avaliar a qualidade de colagem dos painéis compensados foi realizado o ensaio de cisalhamento na linha de cola e as propriedades avaliadas foram a tensão máxima de ruptura (Tmax), e o percentual de falha coesiva da madeira (WF%).

A normalidade dos dados foi confirmada para Tmax nas três condições de ensaio pelos testes de Shapiro-Wilk e Kolmogorov-Smirnov a 5%. A análise de variância (ANOVA), e confirmou a existência de diferença entre estatística e entre as médias dos tratamentos pelo teste T de Student a 5%.

Para o WF% foram obtidas e apresentadas as médias e respectivos coeficientes de variação (CV%) dos tratamentos como descreve a norma NBR 12.466 (2012).

Para Tmax, a Anova verificou que apenas o fator espécie foi estatisticamente significativo para condição seca (D) e para condição água fria (CW). Os painéis compostos pela espécie de *Pinus* apresentaram resultado superiores aos compostos por *Eucalyptus*.

No ciclo (BDB) foi verificado efeito significativo da espécie e da gramatura, mas não foi confirmada a interação entre os fatores para Tmax. Os resultados das Anovas podem ser observados na Tabela 4.

Tabela 4. Análise de variância para Tmax nas três condições de ensaio

Table 4. Analysis of variance of Tmax at three test conditions

Propriedade	Fator		
	Espécie (E)	Gramatura (G)	Interação (E * G)
Tmax – D	0,000*	0,315 ^{ns}	0,242 ^{ns}
Tmax – CW	0,000*	0,302 ^{ns}	0,249 ^{ns}
Tmax – BDB	0,000*	0,048*	0,372 ^{ns}

* = Fator significativo verificado pela ANOVA a 5% de probabilidade. Ns= Fator não significativo pelo teste de ANOVA a 5% de probabilidade.

* = Significant factor verified by ANOVA at 5% of probability. NS = Non-significative factor by ANOVA test at 5% of probability.

Os comportamentos para Tmax observados nas três condições de ensaio demonstrou forte efeito da espécie utilizada, com o *P. kesiya* apresentando as melhores médias.

Para a utilização em ambiente externo ou em contato direto com umidade (classe 3) os tratamentos devem atender aos requisitos de resistência na linha de cola apresentados pela norma NBR 12.466 (ABNT NBR, 2012).

Para a condição D e CW todos os tratamentos apresentaram médias de Tmax acima dos limites mínimos de Tmax e WF% e podem ser destinados para esta condição de uso.

Enquanto na condição BDB apenas os tratamentos T1, T2 e T4 atenderam aos requisitos apresentados pela referida norma. O tratamento T3 não apresentou média de Tmax acima de 1,0 MPa e para ser considerado aprovado para o uso externo deveria apresentar WF% acima de 40%, valor que não foi atingido.

Contudo, devido ao elevado coeficiente de variação (CV) de Tmax do tratamento T3 (46,39%), acredita-se que o aumento do número amostral possibilitaria uma melhoria na distribuição dos dados que resultaria em uma média que atenderia ao requisito de 1,0 MPa para Tmax, permitindo aprovar o tratamento para uso externo.

Os resultados médios de Tmax e WF% dos tratamentos avaliados podem ser observados na Tabela 5.

Tabela 5. Tensão máxima e percentual de falha na madeira para compensados de *Pinus* e *Eucalyptus*.Table 5. Maximum tension and wood failure percentage of *Pinus* and *Eucalyptus* phenolic Plywood.

Condição Tratamento	D		CW		BDB	
	Tmax (MPa)	WF%	Tmax (MPa)	WF%	Tmax (MPa)	WF%
T1	3,02 A (11,55)	70,83 (33,99)	2,24 A (12,52)	39,25 (70,97)	1,45 A (14,92)	20,50 (98,73)
T2	3,01 A (13,39)	58,71 (55,16)	2,24 A (13,80)	34,25 (87,09)	1,51 A (22,42)	21,79 (98,85)
T3	2,02 B (20,47)	30,52 (107,80)	1,68 B (18,59)	22,25 (134,12)	0,91 C (46,39)	16,25 (211,33)
T4	2,15 B (19,06)	49,36 (56,52)	1,79 B (19,27)	19,00 (132,12)	1,06 B (30,33)	12,50 (191,30)
Total	160	320	160	320	160	320

Tmax = tensão máxima, WF% = percentual de falha na madeira; D = Condição seca; CW = Condição Água Fria; BDB = Condição ciclo. Médias seguidas de mesma letra na coluna não diferem estatisticamente pelo teste T de Student a 5%, Coeficientes de variação percentual (CV%) apresentados em parênteses.

Tmax = maximum tension, WF% = wood failure percentage; D = Dry condition; CW = Cold Water condition; BDB = cycle condition. Means followed by the same letter in the column do not differ statistically by Student's T test at 5%, the percentual coefficient of variance (CV%) is presented in parentheses.

Na condição seca (D) os tratamentos T1 e T2 apresentaram desempenho semelhante ao observado para *P. taeda* (SILVA *et al.*, 2012), e *P. oocarpa* de 18 e 28 anos (REIS *et al.*, 2019; MATOS *et al.*, 2019). Os tratamentos T3 e T4 apresentaram desempenho semelhante aos painéis produzidos com diversas espécies do gênero *Eucalyptus* estudas por Iwakiri *et al.* (2013) e Bortoletto Júnior (2003).

Na condição CW os tratamentos de *Pinus* obtiveram resultados aproximados aos verificados para compensados produzidos com *P. taeda* e *Araucaria angustifolia* apresentados por Iwakiri *et al.* (2006).

Os resultados de T3 e T4 obtiveram médias inferiores às nove espécies de *Eucalyptus* apresentados por Bortoletto Júnior (2003), e pode ser resultado da pouca idade do clone utilizado em comparação com materiais de maior idade utilizado pelo referido autor.

O ciclo BDB apresentou uma redução elevada nos valores de Tmax independente dos fatores avaliados e as bruscas variações de temperatura e umidade aumentaram as tensões nas linhas cola, que reduziu Tmax e WF%.

Resultados semelhantes são observados em trabalhos com as espécies *P. caribaea*, *E. dunnii*, *E. robusta*, *E. phaeotrica* e *E. Pellita* em compensados fenólicos (IWAKIRI *et al.*, 2012; IWAKIRI *et al.*, 2013; BORTOLETTO JÚNIOR, 2003), cabe ressaltar que estes compensados foram produzidos com madeira proveniente de

plantios com idade superior a 20 anos e maior ME do que os materiais utilizados no experimento, demonstrando o potencial das espécies utilizadas neste trabalho.

Conforme os resultados obtidos para Tmax e WF% podemos afirmar que os tratamentos T1, T2 e T4 atenderam aos requisitos de resistência e percentual de falha coesiva aparente solicitados pela norma NBR 12.466 (ABNT NBR, 2012).

Apenas T3 foi considerado reprovado por não apresentar média de WF% acima de 40% solicitado pela Tmax do tratamento ser inferior a 1,0 MPa.

Quando comparado aos padrões apresentados no Catálogo Técnico nº1 (ABIMCI, 2002), os tratamentos apresentaram médias superiores aos requisitos mínimos de Tmax e de WF% para as condições Seco e Úmido.

Contudo, o catálogo não apresenta requisitos para a condição BDB, o que não possibilita classificar os painéis para uso externo ou em contato direto com umidade, devendo-se utilizar os padrões de avaliação apresentados pela norma 12.466 (ABNT NBR, 2012).

2.4. Conclusões

A espécie foi o fator determinante para o desempenho dos tratamentos para todas as análises realizadas.

O efeito das diferentes gramaturas não foi estatisticamente significativo e não resultou na melhoria de ME, MOE, MOR, Tmax ou WF% dos tratamentos.

Para os ensaios de resistência à flexão estática (MOE e MOR), os painéis produzidos com o clone de *E. grandis* x *E. urophylla* apresentaram os melhores resultados. No entanto, nenhum dos tratamentos atingiu os requisitos para o MOE apresentados no Catálogo Técnico nº1 (ABIMCI, 2002). Contudo, todos os tratamentos atingiram os requisitos mínimos para o MOR para painéis de 10 mm de espessura.

Para a qualidade de colagem (Tmax e WF%), o *P. kesija* apresentou desempenho superior independente dos pré-tratamentos aplicados, e todos os tratamentos superaram os requisitos mínimos apresentados no Catálogo Técnico nº1 (ABIMCI, 2002).

Apenas o tratamento T3 não atendeu aos requisitos de Tmax e WF% na condição BDB, enquanto os demais tratamentos atenderam os requisitos da norma NBR 12.466 (2012) para a utilização em ambientes úmidos e/ou externo.

É possível recomendar ambas as espécies à utilização pela indústria de compensados e a gramatura de 175 g/m² em linha simples se mostrou mais adequada à utilização industrial pelo atendimento dos requisitos de resistência qualidade de colagem e pelo menor custo produtivo.

Agradecimentos

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pela Bolsa PROEX - DR.

Referências

- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE (ABIMCI). **Estudo setorial 2009: indústria de madeira processada mecanicamente: ano base 2008**. Curitiba, 2009. 52p.
- ABIMCI - ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE. **Programa Nacional de Qualidade da Madeira: compensado de *Pinus***. Curitiba, 2002. 20 p. (Catálogo Técnico, n.1).
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 9485 - Compensado - Determinação da massa específica aparente**. Brasil, 2011.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 9533 - Compensado - Determinação da resistência à flexão estática**. Brasil, 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12466 - 1 Madeira compensada – Qualidade de colagem Parte 1: Métodos de ensaio**, Brasil 2012a.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12466 - 2 Madeira compensada – Qualidade de colagem Parte 2: Requisitos**, Brasil 2012b.
- BORTOLETTO JÚNIOR, G.; GARCIA, J. N. Propriedades de resistência e rigidez à flexão estática de painéis OSB e compensados. **R. Árvore**, Viçosa-MG, v.28, n.4, p.563-570, 2004.
- BORTOLETTO JÚNIOR, G. Produção de compensados com 11 espécies do gênero *Eucalyptus*, avaliação das suas propriedades físico-mecânicas e indicações para utilização. **Scientia Forestalis (IPEF)**, Piracicaba, v. n.63, p. 65-78, 2003.

- CUNHA, A. B.; FRANÇA, M. C.; ALMEIDA, C. C. F.; GORSKI, L.; CRUZ, R. C.; SANTOS, D. Avaliação do rendimento em madeira serrada de *Eucalyptus benthamii* e de *Eucalyptus grandis* por meio do desdobro tangencial e radial. **Floresta** (UFPR. Impresso), v. 45, p. 241-250, 2015.
- DEMIRKIR, C.; COLAKOGLU, G.; COLAK, S.; AYDIN, I.; CANDAN, Z. Influence of aging procedure on bonding strength and thermal conductivity of plywood panels. **Acta Physica Polonica**, Series A, Vol. 129, June 2016.
- DIAS, F. M.; FIORELLI, J.; LAHR, F. A. R.; DIAS, A. A.; A utilização de fibra de vidro como reforço em madeira compensada. **MADEIRA: arquitetura e engenharia**. Janeiro a junho, 2003.
- GUIMARÃES JÚNIOR, J. B.; MENDES, L. M.; MENDES, R. F.; MORI, F. A. Painéis compensado de Eucalipto: estudo de caso de espécies e procedências. **CERNE**, vol. 15, n.1, jan. Mar, 2009, pp. 10-18. Lavras, Brasil.
- INDÚSTRIA BRASILEIRA DE ÁRVORES. IBÁ, **Relatório anual 2019**. Brasília, p. 100, 2020.
- IWAKIRI, S. **Painéis de madeira reconstituída**. Curitiba: FUPEF, 247 p.; 2005.
- IWAKIRI, S.; MATOS, J. L. M.; PRATA, J. G.; TRIANOSKI, R.; SILVA, L. S. Valuation of the use potential of nine species of genus *Eucalyptus* for production of veneers and plywood panels. **Cerne**, Lavras, v. 19, n. 2, p. 263-269, abr./jun. 2013
- IWAKIRI, S.; MATOS, J. L. M.; FERREIRA, E. S.; PRATA, J. G.; TRIANOSKI, R. Produção de painéis compensados estruturais com diferentes composições de lâminas de *Eucalyptus saligna* e *Pinus caribaea*. **Revista Árvore**, Viçosa-MG, v.36, n.3, p.569-576, 2012.
- IWAKIRI, S.; NETO, A. R.; ALMEIDA, B. C.; BIASI, C. P.; CHIES, D.; GUI SANTES, F. P.; FRANZONI, J. A.; RIGATTO, P. A.; BETTEGA, W. P. Avaliação da qualidade do compensado fenólico de *Eucalyptus grandis*. **Ciência Florestal**, Santa Maria, v. 16, n. 4, p. 437-443, 2006.
- KAZMIERCZAK, S.; HILLIG, E.; IWAKIRI, S. Painéis compensados fabricados com lâminas de três espécies de eucaliptos. **Floresta e Ambiente** 2017; 24: e00111614
- KOLLMANN, F. F.P., KUENZI, E. W., STAMM, A. J. **Principles of Wood Science and Technology - II Wood Based Materials**. Springer-Verlag Berlin Heidelberg XII, 703p. 1975. DOI: 10.1007/978-3-642-87931-9.

- LIMA, N. N.; MENDES, L. M.; SÁ, V. A.; BUFALINO, L. Propriedades físico-mecânicas de painéis LVL produzidos com três espécies amazônicas. *Cerne*, Lavras, v. 19, n. 3, p. 407-413, jul./set. 2013.
- MATOS, A. C.; GUIMARÃES JÚNIOR, J. B.; BORGES, C. C.; MATOS, L. C.; FERREIRA, J. C.; MENDES, L. M. Influência de diferentes composições de lâminas de *Schizolobium parahyba* var. *amazonicum* (Huber ex Ducke) Barneby e *Pinus oocarpa* var. *oocarpa* (Schiede ex Schltdl) para produção de compensados multilaminados. **Sci. For.**, Piracicaba, v. 47, n. 124, p. 799-810, dez. 2019.
- PRATA, J. G.; Estudo da viabilidade tecnológica do uso de espécies de *Pinus* tropicais para produção de painéis colados lateralmente (Edge Glued Panels – EGP). **Tese (Doutorado em Engenharia Florestal)** – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2010.
- QUILHÓ, T.; MIRANDA, I.; PEREIRA, H. Within-tree variation in wood fiber biometry and basic density of the urograndis eucalypt hybrid (*Eucalyptus grandis* × *E. urophylla*). **IAWA Journal**, Vol. 27 (3), 2006: 243–254
- REIS, M. S., CARNEIRO, C. M. R., GALVÃO, A. P. M., SOBRAL Filho, M., PAIXÃO, J. C., LISBOA, C. D. J., SIQUEIRA, J. D. P. Adesão e Adesivos para Madeira – Teorias de Adesão e a Natureza das Colagens com Madeira. **Série Técnica**. Ministério da Agricultura, Laboratório de Produtos Florestais, 22p. Brasília, DF. 1982.
- REIS, A. H. S.; SILVA, D. W.; VILELA, A. P.; MENDES, R. F.; MENDES, L. M. Physical-mechanical properties of plywood produced with *Acrocarpus fraxinifolius* and *Pinus oocarpa* **Floresta e Ambiente** 2019; 26(4): e20170157.
- SHARMA S. K.; SHUKLA, S. R.; SHASHIKALA, S.; SRI POORNIMA, V. Axial variations in anatomical properties and basic density of Eucalypt urograndis hybrid (*Eucalyptus grandis* × *E. urophylla*) clones. **Journal of Forestry Research** Volume 26, Issue 3, pp 739–744, sep. 2015.
- SI GROUP CRIOS RESINAS S/A. Resina para madeira CR-7015/12. Rio Claro, SP, 2018 2p. (**Boletim Técnico**).
- SILVA, B. C.; VIEIRA, M. C.; OLIVEIRA, G. L.; GONÇALVES, F. G.; RODRIGUES, N. D.; LELIS, R. C. C.; IWAKIRI, S. Qualidade de Compensados Fabricados com Adesivos à Base de Tanino-formaldeído de *Pinus oocarpa* e Fenol-formaldeído. **Floresta e Ambiente** 2012; 19(4):511-519.

TSOUMIS, George T. **Science and technology of wood: structure, properties, utilization**. Vol. 115. New York: Van Nostrand Reinhold, 1991.

3. LÂMINAS DE *Pinus kesiya* E *Eucalyptus grandis* X *Eucalyptus urophylla* NA PRODUÇÃO DE COMPENSADOS DE USO INTERIOR

PINUS KESIYA AND EUCALYPTUS GRANDIS X EUCALYPTUS UROPHYLLA

VENEER TO INTERIOR-USE PLYWOOD PRODUCTION

Caio Cesar Faedo de Almeida e Geraldo Bortoletto Júnior

RESUMO

A seleção de espécies florestais mais produtivas aumenta a disponibilidade de matérias-primas alternativas às indústrias florestais e o segmento de painéis de madeira tem grande capacidade para absorver estes materiais. No entanto, é necessário verificar se estes materiais atendem aos requisitos técnicos necessários para sua utilização em segmentos para os quais não foram originalmente propostos. O objetivo deste trabalho foi avaliar a resistência, rigidez e qualidade de colagem de painéis compensados de uso interno produzidos com lâminas de *Pinus kesiya* e *Eucalyptus grandis* x *Eucalyptus urophylla*. Foram produzidos 16 painéis com as espécies avaliadas e em duas gramaturas de 200 e 175 g/m² do adesivo ureia-formaldeído. Todos os painéis foram produzidos com cinco lâminas de 2 mm de espessura, o ciclo de prensagem utilizou a temperatura de 130 °C por 10 minutos para *P. kesiya* e 11 minutos para *E. grandis* x *E. urophylla*. As propriedades avaliadas no experimento foram massa específica dos painéis (ME) (ABNT – NBR 9.485, 2011), resistência à flexão estática (ABNT – NBR 9.533, 2012) em módulo de ruptura (MOR) e módulo de elasticidade (MOE). A qualidade de colagem foi verificada pelo ensaio de cisalhamento na linha de cola (ABNT – NBR 12.466-1, 2012), por meio da tensão máxima (Tmax) e do percentual de falha na madeira (WF%). A análise dos dados foi realizada pelo teste T de Student (5%) e os resultados foram comparados aos requisitos das normas supracitadas e com o Catálogo Técnico nº1 da ABIMCI (2002). Dos resultados obtidos, foi verificada maior ME dos painéis produzidos com *E. grandis* X *E. urophylla*. Quanto à resistência (MOR) não houve diferença entre os painéis na direção perpendicular, entretanto, na direção paralela os tratamentos de *E. grandis* X *E. urophylla* apresentaram médias superiores ao *P. kesiya*. Considerando a rigidez (MOE), os tratamentos de *E. grandis* X *E. urophylla* foram superiores, independente da direção avaliada. Para a qualidade de colagem (Tmax), novamente os tratamentos de *E. grandis* X *E. urophylla* apresentaram resultados superiores, independente do pré-tratamento aplicado e cabe ressaltar que a espécie *P. kesiya* foi significativamente afetada pelo uso de menor gramatura. No entanto, mesmo com a ocorrência de diferença estatística, todos os tratamentos atendem aos requisitos de desempenho apresentados pelas normas utilizadas e pela ABIMCI (2002).

Palavras-chave: ureia-formaldeído; espécies florestais não-convencionais; resistência e rigidez; cisalhamento na linha de cola.

ABSTRACT

The selection of more productive forest species increases the availability of alternative raw materials for forest industries, and the wood panel segment has a prominent capacity to absorb these materials. However, it is necessary to verify that these materials meet the technical requirements necessary for their use in segments for which they were not originally proposed. The objective of this work was to evaluate the strength, stiffness, and bonding quality of plywood panels for indoor use produced with veneers of *Pinus kesiya* and *Eucalyptus grandis* x *Eucalyptus urophylla*. Sixteen panels were produced with the evaluated species and in two weights of 200 and 175 g/m² of the urea-formaldehyde adhesive. All panels were produced with five 2 mm thick veneers, the pressing cycle used a temperature of 130 °C for 10 minutes for *P. kesiya* and 11 minutes for *E. grandis* x *E. urophylla*. The properties evaluated in the experiment were a specific mass of the panels (ME) (ABNT – NBR 9.485, 2011), static bending strength (ABNT – NBR 9.533, 2012) in modulus of rupture (MOR), and modulus of elasticity (MOE). The bonding quality was verified by the glue-line shear test (ABNT – NBR 12.466-1, 2012), through the maximum tension (Tmax) and the percentage of wood failure (WF%). Data analysis was performed using Student's t-test (5%) and the results were compared to the requirements of the aforementioned standards and the Technical Catalog No. 1 of ABIMCI (2002). From the results obtained, a higher ME of the panels produced with *E. grandis* X *E. urophylla* was verified. As for the strength (MOR), there was no difference between the panels in the perpendicular direction, however, in the parallel direction the treatments of *E. grandis* X *E. urophylla* presented means higher than *P. kesiya*. Considering the stiffness (MOE), the treatments of *E. grandis* X *E. urophylla* were superior, regardless of the evaluated direction. For bonding quality (Tmax), the treatments of *E. grandis* X *E. urophylla* presented superior results, regardless of the pre-treatment applied, and it is noteworthy that the species *P. kesiya* was significantly affected by the use of lesser weight. However, even with the occurrence of statistical difference, all treatments meet the performance requirements presented by the standards used and by ABIMCI (2002).

Key-words: urea-formaldehyde, unconventional forest species, static bending, glue-line shear test.

3.1. Introdução

As indústrias de base florestal brasileiras interessadas no aumento da produtividade de suas áreas cultivadas, investem na seleção de espécies e

genótipos com maiores taxas de crescimento e menores ciclos de produção (IBÁ, 2019). Segundo relatório da Indústria Brasileira de Árvores (IBÁ, 2020), no ano de 2019, a área total de árvores plantadas atingiu 9,0 milhões de ha, um aumento de 2,4% sobre a área verificada em 2018.

Deste total, 77% é representada pelo cultivo de eucalipto (6.970.000 ha) e 18% de *Pinus* (1.640.000 ha). No mesmo período foi verificada a substituição de 200.000 ha de plantios por espécies do gênero *Eucalyptus* (IBÁ, 2020).

A tendência de substituição se deve aos avanços nos programas de melhoramento que buscam o aumento da produtividade de madeira e pela grande variedade de espécies de *Eucalyptus* que apresentam potencial para diversos ambientes e condições climáticas do Brasil (Fonseca *et al.*, 2010).

Dentre as espécies que vem sendo utilizadas industrialmente, podem ser citados o *E. urophylla*, *E. grandis*, *E. saligna*, *E. globulus*, *E. viminalis*, *E. robusta*, *E. phaeotrica*, *E. deanei*, *E. cloeziana*, assim como materiais híbridos, por exemplo, o *Eucalyptus grandis* x *Eucalyptus urophylla*, com plantios em todas as macrorregiões do país (IWAKIRI *et al.*, 2013; BORTOLETTO JÚNIOR, 2003; ALMEIDA *et al.*, 2004a; FONSECA, *et al.*, 2010 e QUILHÓ *et al.* 2006).

Um dos materiais que vem se destacando neste contexto, principalmente para produção de celulose, é o híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla* desenvolvido com a combinação das características de elevadas taxas de crescimento do *E. grandis* e de alta qualidade de fibra do *E. urophylla* (QUILHÓ *et al.* 2006; SHARMA *et al.*, 2015).

O aumento da disponibilidade de novas espécies para o mercado consumidor favorece o setor de transformação mecânica e a indústria de painéis de madeira se beneficia desta diversificação (ABIMCI, 2009). Entretanto, o aumento da disponibilidade e do uso de matéria-prima alternativa não melhorada para painéis de madeira pode gerar obstáculos durante a utilização em escala industrial.

As novas espécies podem apresentar madeiras com propriedades que dificultam o uso em processos já estabelecidos e como estas características são de origem biológica de cada espécie, é mais viável a adequação do processo produtivo (ALMEIDA, 2013; REIS *et al.*, 1982).

Estes fatores biológicos são ainda mais importantes quando se considera a indústria de compensados, pois este painel utiliza lâminas de madeira e o produto

ainda mantém parte das características vantajosas e desvantajosas da madeira sólida (KOLLMANN *et al.*, 1975; TSOUMIS, 1991; DIAS *et al.*, 2003).

Dentre as características da madeira que afetam a qualidade de painéis Prata (2010) e Iwakiri (2005) destacam a porosidade e permeabilidade da madeira como os principais fatores com influência direta no desempenho da colagem, podendo dificultar ou facilitar a fixação do adesivo.

A massa específica (ME) e as variações dimensionais da madeira, também podem contribuir para o enfraquecimento e até a ruptura das ligações adesivas (PRATA, 2010).

Neste contexto, as espécies do gênero *Eucalyptus* apresentam maiores dificuldades durante a etapa de colagem quando comparados às espécies de *Pinus* mais utilizadas para a atividade (BORTOLETTO JÚNIOR e GARCIA, 2004; GUIMARÃES JÚNIOR *et al.*, 2009; ALMEIDA *et al.*, 2004b).

Dentre os fatores produtivos influentes aos painéis compensados o adesivo e a sua interação com a madeira são decisivos para a qualidade do painel.

Experimentos com painéis produzidos com espécies de *Eucalyptus* e o adesivo ureia-formaldeído (UF) apresentaram resultados de resistência, rigidez e qualidade de colagem superiores às espécies *Pinus taeda*, *Fagus orientalis*, *Populus x euramericana*, *P. oocarpa*, *P. caribaea*, *P. maximinoi*, *P. tecunumanii* e *P. kesiya* (IWAKIRI *et al.*, 2012; IWAKIRI *et al.*, 2013; BAL e BEKTAŞ, 2014).

Os autores também verificaram que lâminas de *Eucalyptus* coladas com UF apresentaram desempenho superior ao esforço mecânico quando comparado a painéis colados com adesivo fenol-formaldeído (FF), o que pode estar relacionado à interação entre a viscosidade do adesivo e a porosidade da madeira.

O presente estudo teve como objetivo avaliar a resistência, a rigidez e a qualidade da colagem de painéis compensados de uso interno de *Pinus kesiya* e *Eucalyptus grandis* X *Eucalyptus urophylla*, em duas gramaturas de adesivo a base de resina ureia-formaldeído.

3.2. Material e métodos

3.2.1. Matéria-Prima

A matéria-prima utilizada para a realização do trabalho foi selecionada a partir de dois lotes de lâminas de madeiras de *Pinus kesiya* e de um clone do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*, as quais se encontravam disponíveis no

Laboratório de Laminação e Painéis de Madeira (LLAPAM), da Escola Superior de Agricultura “Luiz de Queiroz” – ESALQ da Universidade de São Paulo – USP.

As lâminas de *P. kesiya* foram originalmente obtidas de árvores de 30 anos, em um talhão experimental localizado em Piracicaba (SP). As lâminas de *E. grandis* x *E. urophylla* foram obtidas de um plantio de 9 anos, localizado na cidade de Aguaí (SP) (Almeida *et al.* 2004b).

3.2.2. Montagem dos painéis e obtenção de corpos de prova

Para montagem dos painéis foram utilizadas lâminas com dimensões de 500 x 500 x 2 mm. A umidade das lâminas foi padronizada por secagem em estufa de circulação forçada de ar por 30 minutos a 60 °C até a estabilização entre 10 a 12%.

O adesivo ARGOS 660 HT utilizou a resina ureia-formaldeído (UF), com teor de sólidos de 61,38%. As formulações dos adesivos foram ajustadas conforme as recomendações contidas no Boletim Técnico do fornecedor (CRIOS, 2018) e o tempo de escoamento foi obtido utilizando um Copo Ford nº 8.

A formulação do adesivo empregado na colagem das lâminas de *P. kesiya*, em partes por peso, seguiu a proporção: 100:45:40:3 em resina, farinha de trigo, água e catalisador, respectivamente. Para as lâminas de *E. grandis* x *E. urophylla* a proporção adotada foi de 100:30:30:3 dos mesmos componentes.

Os adesivos formulados apresentaram tempos de escoamento entre 45 e 60 segundos para *P. kesiya* e entre 30 e 45 segundos para *E. grandis* x *E. urophylla*.

Após a formulação, os adesivos foram aplicados manualmente sobre as lâminas de madeira utilizando espátulas de plástico, em linha simples, nas gramaturas de 175 e 200 g/m².

O delineamento adotado no experimento foi inteiramente casualizado com arranjo fatorial 2 x 2 para os tratamentos, compostos por 2 fatores, cada um deles em dois níveis, sendo: espécie (*P. kesiya* e *E. grandis* x *E. urophylla*) e gramatura de adesivo UF (175 e 200 g/m²), perfazendo quatro tratamentos, para os quais foram produzidas quatro painéis (repetições), totalizando 16 painéis compensados para a realização do experimento.

O tratamento T1 foi composto pela espécie *P. kesiya* e gramatura de 200 g/m², enquanto o tratamento T2 utilizou a mesma espécie na gramatura de 175 g/m². O tratamento T3 foi produzido com a espécie a *E. urophylla* x *E. grandis* na

gramatura de 200 g/m², e por fim, o tratamento T4 utilizou a espécie a *E. urophylla* x *E. grandis* na gramatura de 175 g/m².

Após a aplicação do adesivo e montagem dos painéis com cinco lâminas, foi realizada a prensagem a frio com pressão de 2 kgf/cm² por 10 minutos para os compensados de *P. kesiya* e 20 minutos para os de *E. grandis* x *E. urophylla*.

Na etapa de prensagem à quente foi realizada seguindo as recomendações apresentada no Boletim Técnico do adesivo (CRIOS, 2018), fornecido pelo fabricante. Para as duas espécies em estudo foi utilizada a temperatura de 110 °C, no entanto, o ciclo de prensagem apresentou especificidades dependendo da espécie.

O ciclo de prensagem para os painéis de eucalipto utilizou pressão de 13 kgf/cm² e o tempo total de prensagem de 11 minutos (1 + 8 + 2), sendo 1 minuto para o fechamento dos pratos, 8 minutos sob pressão máxima e 2 minutos para abertura total. Para os compensados de *P. kesiya* a pressão utilizada foi de 11 kg/cm² e o tempo total de prensagem foi de 10 minutos (1 + 8 + 1) entre fechamento, prensagem e abertura.

Imediatamente após a prensagem à quente, os painéis compensados foram dispostos verticalmente para o resfriamento uniforme de ambas as faces por 24 horas, em temperatura ambiente.

Em seguida, os painéis foram acondicionados por 45 dias no Laboratório de Ensaio Mecânicos de Madeira e Derivados (LEMMAD) da ESALQ, em ambiente climatizado com temperatura de 22 ± 2° C e umidade relativa do ar de 65% ± 5 para uniformização da umidade.

Após a climatização, foi realizado o esquadrejamento e regularização das dimensões dos painéis e obtidas os corpos de prova para os ensaios de flexão estática seguindo as recomendações da norma NBR 9.533 (2012) e o ensaio de cisalhamento na linha de cola segundo as normas NBR 12.466-1 (2012) e NBR 12.466-2 (2012).

De cada painel foram retirados 4 corpos de prova para o ensaio de flexão estática, dois na direção perpendicular e dois na direção paralela. As amostras possuíam dimensões de 300 × 75 × 10 mm em comprimento, largura e espessura, respectivamente, totalizando 16 amostras por tratamento.

Os corpos de prova de cisalhamento na linha de cola foram obtidos com dimensões de 100 × 25,4 × 10 mm em comprimento, largura e espessura,

respectivamente, sendo obtidas 30 amostras por painel, totalizando 120 corpos de prova por tratamento.

Para a obtenção da massa específica dos painéis (ME) foi necessário adaptar a norma NBR 9.485 (2011) pela indisponibilidade de área do painel nas dimensões requisitadas. Para tanto, foram utilizados os corpos de prova de flexão estática para a mensuração dimensional e de massa.

3.2.3. Determinação das propriedades mecânicas

A determinação das propriedades mecânicas dos painéis compensados foi realizada por ensaios destrutivos em máquina universal de ensaios da marca Contenco, modelo UMC300, com capacidade de 30 toneladas no LEMMAD da ESALQ/USP.

O ensaio de flexão estática foi conduzido seguindo o procedimento descrito na norma NBR 9.533 (ABNT, 2012), com a obtenção dos valores do módulo de ruptura (MOR) e do módulo de elasticidade (MOE) ambos expressos em MPa.

No ensaio de cisalhamento na linha de cola NBR 12.466 (ABNT, 2012), foi aplicado o pré-tratamento de imersão em água fria em parte das amostras analisadas. O procedimento consiste na imersão das amostras em água fria (± 20 °C) por um período não menor do que 24 horas.

Neste experimento foi avaliada apenas a resistência (Tmax) das linhas de cola centrais dos corpos de prova, tanto para a condição úmida quanto para a condição seca. Cada condição contou com 10 corpos de prova por painel, totalizando 40 corpos de prova por tratamento em cada condição de ensaio.

Após a realização do ensaio, foi contabilizado o percentual de falha coesiva aparente na madeira (WF%) por inspeção visual em ambas as faces de cada peça ensaiada, totalizando 80 corpos de prova por tratamento para cada condição de ensaio.

A mensuração do WF% foi realizada segundo as recomendações da norma NBR 12.466-1 (ABNT, 2012a) e NBR 12.466-2 (ABNT, 2012b), que descrevem que as amostras devem ser classificadas entre uma das 10 classes WF%, como apresenta a Tabela 1.

Tabela 1. Definição de classes de WF%

Table 1. WF% classes definition

WF% mensurado	Classe de WF%
Ruptura fora da área de avaliação	Descarte
$WF\% \leq 10\%$	1
$10\% < WF\% \leq 20\%$	2
$20\% < WF\% \leq 30\%$	3
$30\% < WF\% \leq 40\%$	4
$40\% < WF\% \leq 50\%$	5
$50\% < WF\% \leq 60\%$	6
$60\% < WF\% \leq 70\%$	7
$70\% < WF\% \leq 80\%$	8
$80\% < WF\% \leq 90\%$	9
$90\% < WF\%$	10

Para a mensuração do WF% foi aplicada uma metodologia complementar à norma NBR 12.466 (ABNT NBR, 2012), com a finalidade de aumentar a precisão da medição.

Foi utilizada uma grade quadriculada de acrílico transparente, com dimensões externas de 25 x 25 mm, dividida em 25 unidades quadradas com 5 mm de lado, cada uma das unidades correspondendo a 4% da área total em avaliação.

A mensuração foi realizada manualmente com a sobreposição da grade sobre a área em avaliação e seguindo os parâmetros de avaliação da norma NBR 12.466 (ABNT, 2012). As unidades foram contabilizadas como unidades binárias de acordo com proporção de falha na madeira e limiar de 50% como parâmetro de classificação.

Unidades que apresentavam falha na madeira em área igual ou superior ao limiar foram consideradas como unidades de falha na madeira, caso contrário, eram consideradas como unidades de falha no adesivo.

Os resultados obtidos para cada uma das faces das amostras foram anotados, variando de 0 a 100 de WF%. Nas análises estatísticas foram utilizados os valores de classe da qual as faces das amostras se inserem, variando de 1 a 10.

3.2.4. Análise de Dados

As análises estatísticas consistiram na aplicação de testes para verificação da homoscedasticidade e normalidade dos dados pelo teste de Levene a 5% de probabilidade.

Quando atendidos os pressupostos de normalidade, foi realizada a análise de variância (ANOVA) para verificar diferença estatística entre os tratamentos ao nível de 5% de probabilidade. Para as análises em que foi confirmada a diferença entre os tratamentos foi aplicado o teste T de Student a 5% para distinção entre médias.

Para ambos os ensaios mecânicos realizados, além da verificação do atendimento dos requisitos mínimos para o ensaio de flexão estática apresentado pela norma NBR 9.533 (ABNT, 2012), e dos requisitos para o ensaio de cisalhamento na linha de cola pelas normas NBR 12.466-1 (ABNT, 2012a) e NBR 12.466-2 (ABNT, 2012b).

Adicionalmente foi utilizado o Catálogo Técnico nº1 para Compensados de Pinus (ABIMCI, 2002) como parâmetro adicional de avaliação do desempenho dos painéis produzidos.

As variáveis ME, MOR, MOE, Tmax e WF% dos quatro tratamentos avaliados foram comparados aos requisitos apresentados para painéis de *Pinus* de cinco lâminas e espessura nominal do painel de 9 mm.

3.3. Resultados e Discussão

Os resultados de resistência, rigidez e qualidade de colagem dos quatro tratamentos de compensados produzidos com adesivo UF são apresentados a seguir, bem como a comparação de desempenho com experimentos realizados em condições semelhantes de produção.

3.3.1. Resistência e elasticidade à Flexão Estática

Os valores de massa específica (ME) e os módulos de ruptura (MOR) e o de elasticidade (MOE) nas duas direções, apresentaram distribuição normal dos dados e permitiram a utilização da análise de variância (ANOVA) e o teste T de Student a 5%.

A ME apresentou diferença estatística e a ANOVA identificou efeito significativo apenas do fator Espécie nas duas direções avaliadas.

Os tratamentos compostos por lâminas de *E. urophylla* x *E. grandis* apresentaram médias de ME estatisticamente superiores aos tratamentos produzidos com lâminas de *P. kesiya*.

Os ensaios de flexão estática na direção perpendicular não apresentaram diferença estatística entre os fatores ou sua interação para o MOR.

Para MOE apenas o fator Espécie foi significativo, com valores superiores observados para painéis da espécie *Eucalyptus*.

Para a direção paralela foi verificada diferença estatística para o fator Espécie para o MOR e para o MOE, o fator gramatura e a interação entre gramatura e espécie não apresentaram diferença estatística.

Os resultados das análises de variância podem ser visualizados na Tabela 2.

Tabela 2. Resultados das análises de variância das propriedades ME, MOR e MOE dos painéis compensados nas direções perpendicular e paralela.

Table 2. Analysis of variance results of ME, MOR and MOE properties in the perpendicular and parallel directions of plywood panels.

Propriedade	Fator		
	Espécie (E)	Gramatura (G)	Interação (E * G)
ME Perpendicular	0,001*	0,393 ^{ns}	0,726 ^{ns}
ME Paralela	0,001*	0,674 ^{ns}	0,223 ^{ns}
MOR Perpendicular à flexão	0,056 ^{ns}	0,649 ^{ns}	0,352 ^{ns}
MOE Perpendicular à flexão	0,002*	0,676 ^{ns}	0,958 ^{ns}
MOR Paralela à flexão	0,000*	0,704 ^{ns}	0,302 ^{ns}
MOE Paralela à flexão	0,000*	0,653 ^{ns}	0,121 ^{ns}

Fatores e/ou interação seguidos por asterisco (*) apresentam diferença estatística pela ANOVA ao nível de 5%.

Fatores e/ou interação seguidos por ns (^{ns}) não apresentam diferença estatística pela ANOVA ao nível de 5%.

Factors and/or interaction followed by asterisk (*) differ statistically by ANOVA test at 5%.

Factors and/or interaction followed by ns (^{ns}) do not differ statistically by ANOVA test at 5%.

As médias dos tratamentos para ME e flexão estática nas direções perpendicular e paralela, bem como os coeficientes de variação (CV) são apresentados na Tabela 3.

Tabela 3. Valores médios de Massa específica (ME) módulos de ruptura (MOR) e elasticidade (MOE) à flexão estática dos compensados.

Table 3. Mean values of Specific gravity (ME), modulus of rupture (MOR) and Elasticity (MOE) on static bending of the plywood.

Direção	Tratamento	N	ME (g/cm ³)	MOR (MPa)	MOE (MPa)
Perpendicular	T1	8	0,661 B (3,42)	36,41 A (28,66)	2.957 B (20,56)
	T2	8	0,656 B (4,96)	39,71 A (15,12)	2.898 B (19,72)
	T3	8	0,713 A (2,48)	43,30 A (12,26)	3.502 A (8,53)
	T4	8	0,701 A (4,69)	42,16 A (3,93)	3.426 A (5,00)
	Total	32			
Paralela	T1	8	0,665 B (4,14)	75,32 B (9,03)	8.841 B (21,56)
	T2	8	0,650 B (3,11)	79,94 B (16,03)	9.843 B (17,07)
	T3	8	0,700 A (4,16)	91,70 A (6,44)	12.128 A (7,11)
	T4	8	0,693 A (3,31)	89,55 A (10,43)	11.570 A (5,63)
	Total	32			

Médias seguidas de mesma letra na coluna não diferem entre si pelo teste de T de Student a 5%; CV (%): Coeficiente de variação percentual por tratamento.

Means followed to the same letters in the columns do not differ statistically by Student's T test at 5%. CV (%): Treatments percentual Variance Coefficient.

O fator Espécie foi a principal fonte de variação verificada estatisticamente no experimento tanto para a ME dos painéis produzidos, como para MOR e MOE e acredita-se que os resultados de resistência e rigidez dos painéis estejam diretamente relacionados à ME.

Sobre a ME, a hipótese inicial considerava que o predomínio de madeira juvenil no material de *E. grandis* x *E. urophylla* (9 anos), em contraste ao predomínio de madeira adulta de *P. kesiya* (30 anos), resultariam painéis com ME estatisticamente iguais.

Comportamento que não foi verificado, os tratamentos T3 e T4 compostos pela espécie *E. grandis* x *E. urophylla* apresentaram médias estatisticamente superiores aos tratamentos T1 e T2. No entanto, os painéis construídos com lâminas de *Eucalyptus* apresentaram médias de ME inferiores quando comparado aos resultados de espécies de *Eucalyptus* com idades entre 17 e 22 anos apresentados por Guimarães Júnior *et al.* (2009) e Bortoletto Júnior (2003).

Comparando os resultados de ME aos valores de referência apresentados pelo Catálogo Técnico nº1 (ABIMCI, 2002), foi possível verificar que todos os tratamentos apresentam médias superiores aos requisitos mínimos e máximos estipulados.

Os resultados do MOR e do MOE dos tratamentos produzidos no presente estudo são semelhantes aos compensados ureicos produzidos utilizando lâminas de

diversas espécies de *Pinus* tropicais e do gênero *Eucalyptus* provenientes de plantios de 20 a 25 anos apresentados por Iwakiri *et al.* (2012) e Iwakiri *et al.* (2013).

O desempenho dos tratamentos T3 e T4 apresentaram médias de MOR e MOE semelhantes ao verificado por Almeida *et al.* (2004) para compensados com mesmo adesivo, gramatura e mesmo lote de lâminas de *E. grandis* x *E. urophylla* utilizados neste estudo.

A falta de requisitos mínimos do MOR e do MOE pela norma NBR 9.485 (ABNT, 2012), obrigou a utilização do Catálogo Técnico nº1 (ABIMCI, 2002), para a classificação dos tratamentos. Foi verificado que todos os tratamentos apresentaram média superior aos requisitos mínimos para o MOR e o MOE nas duas direções avaliadas.

3.3.2. Qualidade de colagem

O resultado da análise de variância (ANOVA) para a resistência à tração (Tmax) não verificou diferença estatística entre os tratamentos na condição de ensaio seca, e para a condição úmida foi verificada diferença estatística para espécie, adesivo e a interação espécie e adesivo.

Os resultados obtidos pela ANOVA para a qualidade de colagem em ambas as condições de ensaio são apresentados na Tabela 4.

Tabela 4. Análise de variância para a resistência de colagem de painéis compensados colados com resina ureia-formaldeído.

Table 4. Analysis of variance of bonding resistance of plywood panels bonded with urea-formaldehyde resin.

Propriedade	Fator			Fator		
	Espécie (E)	Gramatura (G)	Interação (E * G)	Espécie (E)	Gramatura (G)	Interação (E * G)
Tmax	0,440 ns	0,752 ns	0,477 ns	0,000 *	0,000 *	0,000 *

Fatores e/ou interação seguidos por asterisco (*) apresentam diferença estatística pela ANOVA ao nível de 5%.

Fatores e/ou interação seguidos por ns (^{ns}) não apresentam diferença estatística pela ANOVA ao nível de 5%.

Factors and/or interaction followed by asterisk (*) differ statistically by ANOVA test at 5%.

Factors and/or interaction followed by ns (^{ns}) do not differ statistically by ANOVA test at 5%.

A interação entre os fatores, espécie e adesivo foi desdobrada pelo teste T a 5% de probabilidade e verificou diferença estatística causada pela Gramatura utilizada nos tratamentos produzidos com *P. kesiya* para Tmax.

Entretanto, mesmo verificada a diferença entre os tratamentos T1 e T2, ambos foram inferiores aos produzidos com lâminas de *Eucalyptus* que não apresentaram diferença estatística causada pela Gramatura.

As médias de Tmax e de WF% dos tratamentos avaliados podem ser observadas na Tabela 5.

Tabela 5. Resistência na linha de cola (Tmax) para compensados na condição seca e úmida.

Table 5. Glue-line shear strength (Tmax) of the plywood at dry and wet condition.

Condição	Seca				Úmido			
	Tratamento	N	Tmax (MPa)	N	WF%	N	Tmax (MPa)	N
T1	40	2,30 A (16,20)	58	50,52 (79,06)	40	2,10 B (19,03)	76	54,34 (56,98)
T2	40	2,32 A (12,97)	80	27,78 (115,31)	40	1,44 C (31,53)	80	12,63 (184,16)
T3	40	2,29 A (15,36)	78	79,49 (66,80)	40	2,48 A (25,25)	78	95,38 (10,79)
T4	40	2,24 A (15,23)	74	85,54 (24,55)	40	2,56 A (20,18)	72	95,69 (8,64)
Total	160	-	290	-	160	-	306	-

Tmax = tensão máxima na linha de cola (MPa); WF% = percentual de falha na madeira; D = condição seca; CW = condição após imersão em água fria por 24 horas; Médias seguidas de mesma letra na coluna não diferem entre si pelo teste T de Student a 5% de probabilidade, coeficientes de variação percentual (CV%) apresentados em parênteses.

Tmax = maximum glue-line tension (MPa); WF% = wood failure percentual; D = dry condition; CW = cold water 24 hour immersion condition; Means followed by the same letter in the column do not differ by Student's T test at 5% of probability, and the variation coefficient (CV) is presented in the parenthesis.

A condição seca avalia o máximo potencial de resistência dos painéis compensados e os fatores não demonstraram diferença estatística para a resistência, no entanto, para WF% houve uma grande diferença entre os tratamentos, principalmente, quando considerado o fator espécie. Contudo, segundo a norma NBR 12466-2 (2012) os resultados de WF% podem ser desconsiderados devido às elevadas médias de Tmax dos tratamentos.

A condição úmida promoveu o aumento das tensões nas linhas de cola e possibilitou a visualização da influência da Gramatura nos tratamentos T1 e T2, seja quantitativamente (Tmax) como qualitativamente (WF%), no entanto, a redução de Tmax não foi suficientemente para reprovar os tratamentos.

Os resultados de WF% na condição úmida acompanharam a tendência de desempenho observada em Tmax entre os tratamentos, os quais novamente foram elevados o suficiente para desconsiderar o WF% para a aprovação dos tratamentos pela norma NBR 12.466-2 (2012).

Os tratamentos desenvolvidos tiveram desempenho semelhante à maioria dos painéis compensados de espécies de *Pinus* tropicais com idade entre 20 e 25

anos e de *Eucalyptus* de nove anos produzidos por Iwakiri *et al.* (2012) e Almeida *et al.* (2004a), respectivamente, que utilizaram adesivo à base de ureia-formaldeído, com lâminas de mesma espessura, gramatura e ciclo de prensagem próximos às utilizadas no experimento.

Para a avaliação da qualidade de colagem dos painéis compensados, verificou-se que todos os tratamentos atenderam aos requisitos de Tmax e WF% da norma NBR 12.466-2 (2012). Bem como, atendendo aos requisitos apresentados pela ABIMCI (2002), para Tmax e WF% nas duas condições de ensaio.

3.4. Conclusões

Os painéis compensados construídos com lâminas de madeira de *E. grandis* x *E. urophylla* e de *P. kesiya* colados com adesivo Ureia-formaldeído atenderam aos requisitos das normas NBR 9.533 (ABNT, 2012), NBR 12.466-1 (ABNT, 2012), NBR 12.466-2 (ABNT, 2012) e o Catálogo técnico nº1 (ABIMCI, 2002) e podem ser considerados adequados para a produção industrial de compensados.

Para a maioria dos ensaios e condições avaliadas o aumento da gramatura não configurou como elemento significativo para a melhoria da resistência dos painéis. Possibilitando a utilização da gramatura de 175 g/m² de adesivo ureia-formaldeído na produção industrial de compensados de *Pinus kesiya* e *E. grandis* x *E. urophylla*.

O clone de *E. grandis* x *E. urophylla*, mesmo se tratando de um material de apenas 9 anos e originalmente desenvolvido para a indústria de celulose, demonstrou grande potencial para a utilização na indústria de compensados, apresentando elevado desempenho de resistência mecânica e qualidade de colagem.

Agradecimentos

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pela Bolsa PROEX-DR.

Referências

- ALMEIDA, R. R.; BORTOLETTO JÚNIOR, G.; JANKOWSKY, I. P. Produção de compensados a partir da madeira de clones do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*. **Floresta e Ambiente** v11, n.1, p. 14 - 24, ago./dez. 2004.
- ALMEIDA, R. R.; BORTOLETTO JÚNIOR, G.; JANKOWSKY, I. P. Produção de lâminas a partir da madeira de clones do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla*. **Scientia Forestalis** (IPEF), Piracicaba, v. jun., n.65, p. 49-58, 2004a.
- ALMEIDA, R. R.; BORTOLETTO JÚNIOR, G.; JANKOWSKY, I. P. Produção de compensados a partir da madeira de clones do híbrido. **Floresta e Ambiente** 11, n.1, p. 14 - 24, ago./dez. 2004b.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE (ABIMCI). **Estudo setorial 2009: indústria de madeira processada mecanicamente: ano base 2008**. Curitiba, 2009. 52p.
- ABIMCI - ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE. **Programa Nacional de Qualidade da Madeira: compensado de *Pinus***. Curitiba, 2002. 20 p. (Catálogo Técnico, n.1).
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 9.485 - Compensado - Determinação da massa específica aparente**. Brasil, 2011.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 9.533 - Compensado - Determinação da resistência à flexão estática**. Brasil, 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12.466 - 1 Madeira compensada – Qualidade de colagem Parte 1: Métodos de ensaio**, Brasil 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12.466 - 2 Madeira compensada – Qualidade de colagem Parte 2: Requisitos**, Brasil 2012.
- BAL, B. C., BEKTAŞ, I. Some mechanical properties of plywood produced from *Eucalyptus*, beech, and poplar veneer. **Maderas. Ciencia y tecnología** 16(1): 99-108, 2014. DOI 10.4067/S0718-221X2014005000009.
- BORTOLETTO JÚNIOR, G.; GARCIA, J. N. Propriedades de resistência e rigidez à flexão estática de painéis OSB e compensados. **R. Árvore**, Viçosa-MG, v.28, n.4, p.563-570, 2004.

- BORTOLETTO JÚNIOR, G. Produção de compensados com 11 espécies do gênero *Eucalyptus*, avaliação das suas propriedades físico-mecânicas e indicações para utilização. **Scientia Forestalis (IPEF)**, Piracicaba, v. n.63, p. 65-78, 2003.
- CUNHA, A. B.; FRANÇA, M. C.; ALMEIDA, C. C. F.; GORSKI, L.; CRUZ, R. C.; SANTOS, D. Avaliação do rendimento em madeira serrada de *Eucalyptus benthamii* e de *Eucalyptus grandis* por meio do desdobro tangencial e radial. **Floresta** (UFPR. Impresso), v. 45, p. 241-250, 2015.
- DIAS, F. M.; FIORELLI, J.; LAHR, F. A. R.; DIAS, A. A.; A utilização de fibra de vidro como reforço em madeira compensada. **MADEIRA: arquitetura e engenharia**. Janeiro a junho, 2003.
- FONSECA, S. M.; RESENDE, M. D. V.; ALFENAS, A. C.; GUIMARÃES, L. M. S.; ASSIS, T. F.; GRATTPAGLIA, D. **Manual prático de melhoramento genético do eucalipto**. Viçosa: UFV, 2010. 200 p.
- GUIMARÃES JÚNIOR, J. B.; MENDES, L. M.; MENDES, R. F.; MORI, F. A. Painéis compensado de Eucalipto: estudo de caso de espécies e procedências. **CERNE**, vol. 15, n.1, jan. Mar, 2009, pp. 10-18. Lavras, Brasil.
- INDÚSTRIA BRASILEIRA DE ÁRVORES. IBÁ, **Relatório anual 2018**. Brasília, p. 80, 2019.
- INDÚSTRIA BRASILEIRA DE ÁRVORES. IBÁ, **Relatório anual 2019**. Brasília, p. 100, 2020.
- IWAKIRI, S. **Painéis de madeira reconstituída**. Curitiba: FUPEF, 247 p.; 2005.
- IWAKIRI, S.; SANCHES, F. G.; POTULSKI, D. C.; SILVA, J. B.; ANDRADE, M.; MARCHESAN, R. Avaliação do potencial de uso de espécies de *Pinus* tropicais e eucalipto na produção de painéis compensados uréicos. **FLORESTA**, Curitiba, PR, v. 42, n. 2, p. 277 - 284, abr./jun. 2012b.
- KOLLMANN, F. F.P., KUENZI, E. W., STAMM, A. J. **Principles of Wood Science and Technology - II Wood Based Materials**. Springer-Verlag Berlin Heidelberg XII, 703p. 1975. DOI: 10.1007/978-3-642-87931-9.
- PRATA, J. G.; Estudo da viabilidade tecnológica do uso de espécies de *Pinus* tropicais para produção de painéis colados lateralmente (Edge Glued Panels – EGP). **Tese (Doutorado em Engenharia Florestal)** – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2010.

- QUILHÓ, T.; MIRANDA, I.; PEREIRA, H. Within-tree variation in wood fiber biometry and basic density of the urograndis eucalypt hybrid (*Eucalyptus grandis* × *E. urophylla*). **IAWA Journal**, Vol. 27 (3), 2006: 243–254.
- REIS, M. S., CARNEIRO, C. M. R., GALVÃO, A. P. M., SOBRAL Filho, M., PAIXÃO, J. C., LISBOA, C. D. J., SIQUEIRA, J. D. P. Adesão e Adesivos para Madeira – Teorias de Adesão e a Natureza das Colagens com Madeira. **Série Técnica**. Ministério da Agricultura, Laboratório de Produtos Florestais, 22p. Brasília, DF. 1982.
- SELLERS JR., T. Adhesive in the Wood Industry. In: PIZZI. A.; MITTAL, K. L. **Handbook of adhesive technology**. New York: Marcel Dekker, 1994.
- SHARMA S. K.; SHUKLA, S. R.; SHASHIKALA, S.; SRI POORNIMA, V. Axial variations in anatomical properties and basic density of Eucalypt urograndis hybrid (*Eucalyptus grandis* × *E. urophylla*) clones. **Journal of Forestry Research** Volume 26, Issue 3, pp 739–744, sep. 2015.
- SI GROUP CRIOS RESINAS S/A. Resina para madeira ARGOS 660 HT. Rio Claro, SP, 2018. 2p. (**Boletim Técnico**).
- SI GROUP CRIOS RESINAS S/A. Resina para madeira CR-7015/12. Rio Claro, SP, 2018 2p. (**Boletim Técnico**).
- TSOUMIS, George T. **Science and technology of wood: structure, properties, utilization**. Vol. 115. New York: Van Nostrand Reinhold, 1991.

4. DEEP LEARNING FOR PLYWOOD BONDING QUALITY CLASSIFICATION

Caio Cesar Faedo de Almeida, Jaymison Emanuel Alecrim Cerqueira, Carlos de

Oliveira Affonso, Geraldo Bortoletto Júnior

ABSTRACT

The visual classification of product quality performed by humans is a common activity in most industries that use raw materials of biological origin, and these inspections allow the removal of defects and the improvement of products' final quality. In plywood industries, this activity is difficult to train and prone to errors. However, the development of computer vision systems is the main alternative to automate the analyses, with emphasis on the convolutional neural networks (CNN) for images processing in real-time. Thus, this work aimed to evaluate the accuracy of five CNNs for visual classification of the bonding quality of four types of plywood panels, produced with two wood species (*Pinus* spp. and *Eucalyptus* spp.) and two adhesives (Phenol-formaldehyde and Urea-formaldehyde). Were used 1,600 samples in the glue-line shear test (NBR 12,466-1, 2012) experiment, the samples were visually classified with aid of an acrylic grid following the recommendations of the norms NBR 12,466-1 (2012) and NBR 12,466-2 (2012). The CNN models were developed to identify five classes of plywood wood failure percentage (WF%) (C1, C2, C3, C4, and C5). Was used 4,800 color images and the knowledge transfer technique, to obtain five models, *Pinus* (n= 2400), *Eucalyptus* (n= 2400), Phenol-formaldehyde (FF) (n= 2880), Urea-formaldehyde (UF) (n= 1920), and Generalist (n= 4800), using 75% of the images for training and 25% for validation. The models presented satisfactory results for the classification of WF% with high accuracy in *Pinus* (92.46%), *Eucalyptus* (91.84%), FF (94.96%), and Generalist (94.36%), only the UF model (60.90%) did not present satisfactory results, as well as not being able to classify samples of class C1. The algorithms presented higher difficulty for the identification of the intermediate classes (C2, C3, and C4) and greater ease for the extreme classes (C1 and C5). However, these results are negatively influenced by the imbalance in the number of samples between the classes, mainly the UF model (n= 1920). The study showed that the approach was efficient for the correct identification of WF% and that the development of an automated computer vision system from CNNs is possible. Despite this, it is necessary to increase and standardize the number of samples between classes for more accurate classification.

Key-words: Image classification, computer vision, machine learning, CNN

4.1 Introduction

The classification of product quality based on the visual and qualitative assessment carried out by humans is a common activity in most industries that use raw materials of biological origin, either due to the occurrence of natural defects or due to some desirable subjective value, such as texture, color, design, smell, and taste.

The performance of inspections allows the correction of problems and the disposal of defective products, resulting in a better quality of the final product (AFFONSO *et al.* 2017).

However, it is a repetitive activity and prone to fatigue after long periods of execution, which reverts to a significant reduction in the rate of recognition and accuracy of assessments, and detection errors will eventually occur (YANG *et al.*, 2018).

The recurrence of errors resulting from the incorrect visual classification is common for products of biological origin, such as agricultural and forest products, due to the complex structure and the unpredictability of structural arrangements (GOGUL and KUMAR, 2017).

In addition to the difficulty of training, Huber *et al.* (1985), described the high turnover of workers who carry out the visual evaluation activity is also one of the main factors of classification errors.

Recognizing this context, the industries have been investing in the acquisition of automated systems of visual assessment to increase the accuracy and uniformity of their processes by reducing errors of human origin.

Automated systems use computer vision techniques, which is the science that deals with the explicit and significant description of physical objects by images, produced from different sensors and devices (BALLARD and BROWN, 1982; BARELLI, 2019).

This field of science starts its development at the origins of computing in the late 1950s, and many of the essential concepts were developed until the early 1980s, with applications in several areas, such as artificial intelligence, computer graphics, and computer processing images (BALLARD and BROWN, 1982).

However, these systems were not very efficient or did not have the necessary efficiency to be used in real-time for complex surfaces, such as wood or other products of biological origin.

This difficulty was verified by Connors *et al.* (1990) who developed a prototype based on computer vision for the classification of wooden boards according to the occurrence of defects such as knots and cracks.

However, at that time the use of images proved to be inefficient for detecting defects due to the difficulty of computational processing and low resolution of digital cameras.

The use of digital images for the detection of wood defects has shown promising results at experiments where artificial intelligence techniques were applied for image processing and identification of defects.

The most promising algorithms was K-Nearest Neighbors (KNN), Support Vectors Machine (SVM) and Artificial Neural Networks (ANN) obtained better classifications than human evaluators (ALAPURANEN and WESTMAN, 1992; CHO *et al.*, 1991).

However, image processing still was a laborious task and the ANN-based algorithms began to stand out for presenting faster processing and easier obtaining and automatic adjustment of the parameters during the training model stage presented itself as the most viable alternative for use in computer vision systems (CHO *et al.*, 1991).

In the late 1980s the detection of characteristics by digital images received a great boost from the work published by LeCun *et al.* (1989), in the study on the identification of handwritten numeric digits, that would become the basis for the algorithms later known as convolutional neural networks (CNN).

LeCun and Bengio (1995) describe that this methodology uses different layers of neurons to perform different functions, divided between known layers and hidden layers. The input and output data layers are the known layers of the model.

However, unlike ANNs in the hidden layers of a CNN, convolutions occur, which are steps of applying filters to identify and extract important features in the images, followed by the pooling step, which creates condensed maps to reduce image size without losing relevant information. These steps increase the processing speed of the subsequent layers by reducing the processional effort (LECUN *et al.*, 1989; LECUN and BENGIO, 1995).

The number of hidden layers of each model depends on the type of data under study and must be adjusted according to each situation.

The superiority of CNNs for the classification of complex images was demonstrated by Huang and LeCun (2006), the authors compared the accuracy rates of images visual classification by CNN, SVM, and a hybrid system (CNN + SVM), the tests used a set of 50 images (NORB dataset), at different inclinations, illumination intensity and background, totaling 291,600 images.

The authors obtained classification error rates of 43.3% for SVM, while for CNN and CNN + SVM, only 7.2% and 5.9%, respectively. In addition to the better accuracy, the CNN still has the advantage of higher processing speed among all algorithms.

The authors point out that the association of SVM applied to images treated by CNN is interesting, since the production of smaller images allowed the increase in accuracy, caused by the greater efficiency of SVM in smaller images, proving to be an interesting option for use in more complex images, such as in case of real-time classification or video applications.

4.1.1. Related Work

Due to the great efficiency, the CNN methodology has become widely used for increasingly complex visual classification studies, and the inspection of forest products has benefited greatly as presented in the works of several authors. Drake and Packianather (1998) obtained 88% accuracy in the classification of defects in wood veneers for plywood production.

The identification and classification of pine boards according to the occurrence of defects were carried out by Affonso *et al.* (2017) using color images (RGB) converted to grayscale, to compare the classification efficiency of three board qualities (A, B, and C) by CNN, ANN, KNN, and SVM.

The authors found that CNN had 77.69% of correct answers and was inferior to all the other evaluated algorithms, however, this result can be attributed to the imbalance of samples from the classes (A = 144, B = 177, C = 53) and the small data-set (n = 374), factors that are known limitations to CNN, which are benefit from larger and more homogeneous data-sets.

The use of RGB images presents greater computational complexity and processing costs, which, depending on the algorithm used, may result in lower reliability classifications. Demonstrated by Funk *et al.* (2003), in a work of classification of defects of plywood sheets, in which, for the same algorithm when

using RGB images, the classification results were lower than those observed for grayscale images.

Todorokia *et al.* (2011) were one of the first works that used color images to identify and measure knots in veneers, the red band algorithm presented similar results as grayscale, with a classification accuracy of 96% and 99%, respectively.

The good performance of CNNs used for the forestry segment was also verified for the identification of forest species from macro and microscopic images of the wood and can be considered an important step for the development of automated systems for products of natural origin.

The similarity of anatomical sets between species enhances the difficulty of identification through the wood anatomy, due to the high number of structures and their various combinations that make each species unique.

Ravindran *et al.* (2018), used wood images of 10 species of the Meliaceae family native to South America, Africa, and Southeast Asia to test a CNN. The authors obtained a high rate of accuracy for species (87.40%) and genus (97.50%) identification, the results exceed the accuracy of the traditional classification carried out by humans.

Similar results were obtained by Hafemann *et al.* (2014), in a study on the classification of 22 tropical forest species, using macro and microscopic wood images and obtained 95.77% correct rates for macroscopic and 97.32% for microscopic images.

The use of algorithms for the classification of forest species from microscopic images of the wood was also efficient for the identification of 52 tropical species with 97.01% accuracy presented by Zamri *et al.* (2016).

The identification of conifer species was the object of work by Kwon *et al.* (2017), who obtained 99.03% of correct classification by macroscopic images of five conifer species using CNN models. It should be noted that the works presented used mostly images from cell phone cameras with little light control and even under non-ideal conditions, CNNs were efficient in identifying species.

These models demonstrated that the use of CNNs can be a powerful tool for the identification of visual characteristics that are difficult to evaluate by humans and can be applied to the industry in real-time.

In this context, the plywood industry is one of the forestry segments that are most negatively affected by visual classification, as the use of low-quality veneers can negatively affect the physical and mechanical performance of the panels.

This is due to the lamination high yield, between 60 to 75% (GUO and ALTANER, 2018), which, in addition to clean wood, ends up using areas of the trunk that present a higher occurrence of defects such as knots, pith, and juvenile wood.

The development of more modern equipment to maximize the use of wood, such as spindleless lathes, ends up obtaining a higher occurrence of veneer defects and aggravates the necessity of veneers classification for the proper production of plywood.

However, most Brazilian industries still use human visual classification, which is prone to errors due to the repetitiveness of the activity, and computer vision systems are proposed to automate visual inspection, with the ability to locate and identify these defects.

In the most recent studies on computer vision to wood veneers using CNN algorithms, there is a tendency to focus on the identification and measurement of veneers defects, and what approaches are most suitable for each defect type.

In these works, can be mention Urbonas *et al.* (2019), which applied the knowledge transfer for a recognition CNN of four wood defects, the results presented an average accuracy of 80.6% of correct identification and is efficient for industrial use.

Hu *et al.* (2020), considering only three types of defects (sound knots, dead knots, and insect holes), presented classification accuracy rates of 86.1% to 98.4% of the tested algorithms.

A similar result, presented by Shi *et al.* (2020), aimed to identify the best and fastest algorithm for industrial real-time classification. The selected algorithm was able to identify a batch of 50 images with the desired standard and a batch of 50 images of defective veneers in just 2.5 seconds, with an average accuracy of 95.31%.

Yang *et al.* (2020), in a similar study using Extreme Machine Learning (EML) during the knowledge transfer stage, obtained a significant increase in the accuracy of CNN for the extraction of defect contours, reaching 96.7% of accuracy, in only 187 ms.

The advances in methodologies, in the accuracy and speed of identification, measurement, and classification of defects are noticeable for the field of computational vision applied to wooden panels and especially to plywood panels.

Plywood is mostly produced with two principal adhesives, the colorless urea-formaldehyde for non-structural products and the red-brown Phenol-formaldehyde for structural use. And the most common species used were yellow-colored coniferous wood, such as *Pinus*, and more recently, the brown-red colored *Eucalyptus* wood became more frequent.

The visual classification of plywood bonding quality is complex activity to human operators and the determination of the exact percentage of bonding areas is difficult, due to the distinction between wood and adhesive and the lack of clear standard procedures.

Despite the difficulty of the classification of bonding quality by visual evaluation, there are still no studies that approach this issue from the use of CNNs to enable industrial use.

4.1.2. Hypothesis

The different adhesive colors, different wood textures, and their interaction could be sufficient to a CNN efficiently classify plywood bonding quality with higher accuracy than a human operator.

4.1.3. Objective

The objective of this paper was to analyze the CNNs efficiency to classify the bonding quality of different plywood compositions and verify if the presented models present significant differences between each panel composition.

4.2. Materials

The study utilized four plywood treatments based on their compositions to evaluate the classification efficiency of wood failure percentage (WF%) through CNNs.

To the experiment were used selected veneers available at Forest Sciences Department (LCF) at Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ) Campus, in Piracicaba, SP, Brazil. The five layers of plywood panels were composed considering two wood species, *Pinus* spp. and *Eucalyptus* spp., the adhesives used

were urea-formaldehyde (UF) and phenol-formaldehyde (PF), arranged in four treatments (T1, T2, T3, and T4).

Treatment T1 was produced using *Pinus* spp. species and the adhesive phenol-formaldehyde (PF). The treatment T2 used the same species and the adhesive urea-formaldehyde (UF). T3 treatment was composed of the *Eucalyptus* spp. species and phenol-formaldehyde (PF) adhesive. And the treatment T4 was produced with urea-formaldehyde (UF) adhesive and the *Eucalyptus* spp. veneers.

The experimental panels were produced at Laboratório de Laminação e Painéis de Madeira (LLAPAM) at LCF/ESALQ to ensure the process and the composition standards. Both species were used five veneers with dimensions of 500 × 500 × 2 mm and humidity of 10 to 12 % for UF panels, and 6 to 8% for PF panels.

The UF panels used the resin ARGOS 660 HT, with a solids content of 61.38% (CRIOS, 2018), and the PF panels utilized the resin CR-7015/12, with a solids content of 50.61% (CRIOS, 2018).

The adhesive composition was adjusted to each species, for PF treatments (T1 and T3) the formulation used the proportion of 100:45:40 of PF resin, flour, and water for *Pinus* spp. (T1), and the formulation of 100:30:30 of the same components to *Eucalyptus* spp. panels (T3). To UF treatments (T2 and T4) were used the components resin, flour, water, and catalyst in the proportion of 100:45:40:3 to *Pinus* spp. (T2), and the proportion of 100:30:30:3 for *Eucalyptus* spp. panels (T4).

The panels were cold-pressed (2 kgf/cm²) at room temperature for 10 to 20 minutes before the hot pressing at 110 °C for UF adhesive and 150 °C for PF adhesive. T1 and T2 used the pressure of 11 kgf/cm² for 10 minutes (1+8+1), T3 and T4 used the pressure of 13 kgf/cm² for 11 minutes (1+8+2).

Immediately after pressing the panels were vertically arranged for even cooling of the both surfaces for 24 hours at room temperature (~25 °C). Followed by 45 days of storage at acclimatized room at temperature of 22 ± 2° C and 65% ± 5 of relative humidity for moisture uniformization.

Each treatment was composed by eight panels, which were cut into the glue-line shear test samples at Laboratório de Ensaios Mecânicos de Madeira e Derivados (LEMMAD) at LCF/ESALQ, were obtained 30 samples per panel for T1 and T3 and 20 samples per panel for T2 and T4.

4.2.1. Data

The evaluation of the glue-line shear test was carried out as described at Brazilian Standard NBR 12466-1 (2012). The PF treatments (T1 and T3) used 240 samples per treatment (8 x 30), and the UF treatments (T2 and T4) used 160 samples per treatment (8 x 20).

After the test, both halves of the samples were visually evaluated by trained personnel to determine the wood failure percentage (WF%), the treatments T1 and T3 presented 480 WF% samples each, T2 and T4 presented 320 WF% samples. The evaluation followed the procedures presented in NBR 12466 (2012).

The referred standard presents 10 classes of WF%, with a 10% range each, to determine the bonding quality of the treatment, as the higher the class which the sample fits, the better is the bonding quality of the panel.

However, to reduce the effect of imbalanced distributions of classes this work suggested an alternative classification system, with five classes, each one with 20% range ($0 < C1 \leq 20\%$; $20 < C2 \leq 40\%$; $40 < C3 \leq 60\%$; $60 < C4 \leq 80\%$; and $80 < C5 \leq 100\%$ WF).

To automate the visual analysis and construct the CNN, were obtained digital images of both sides of the sample, from each half were produced three images with different capture angles, which converted into a total of 4800 images. The treatment visual aspect of the glue-line shear test samples is presented in Figure 1.



Figure 1. Plywood treatments used for automated visual classification

Legend: T1 = *Pinus* + PF; T2 = *Pinus* + UF; T3 = *Eucalyptus* +PF; T4 = *Eucalyptus* +UF

From the total amount of 4800, 404 images were discarded to the analysis (8.42%), 2424 were labeled as class C1 (52.09%), 498 were classified as C2 (11.33%), 405 as C3 (9.21%), 372 as C4 (8.46%), and 831 as C5 (18.90%).

4.2.2. Image Processing

The processing of the images in the experiment consisted of the evaluation, selection, and removal of inappropriate images for use in CNNs ($n = 404$).

To the whole image set, it was found that about half of the image's area did not present relevant information for the analysis of the bonding quality of plywood.

To optimize the learning of CNNs, a crop was applied to reduce the size of the images, which allowed the removal of unnecessary areas such as the background and the identification of the samples.

The images had an initial size of 100 x 200 pixels and were reduced to the size of 100 x 100 pixels, as presented in Figure 2.




Figure 2. Image sample resize processing

The CNNs developed in this study utilized color images (RGB), and the conversion of the images to grayscale was not necessarily due to the small sample size ($n = 4800$).

The extracted features from color images by treating each color channel (Red-Green-Blue) and transforming their shape information into pixel surfaces. In the second step, a matrix is created with the numeric values of color intensity corresponding to each pixel (between 0 and 255).

Later, was performed normalization into the numerical matrix, where it is assigned a unit value for pixel maximum intensity and zero to minimal intensity, these features will be the input for the CNN algorithm.

4.2.3. Classification Technique

The classification techniques employed in this paper was written in Python with the use of NumPy and Pandas packages to machine learning algorithms for data mining task.

The CNN was performed using a Keras library, as the predictive performance of each algorithm is assessed by the Accuracy, Precision, Sensitivity, Specificity, and ROC curves.

4.2.4. Active Learning

Active Learning uses supervised learning iterations to label instances that are close to the class separation margins. This is because these samples are often more prone to misclassification, and their inclusion in the training set provides important information for improving the model's accuracy.

Then the CNN's are retrained using the labeled dataset. Due to the dispersion of examples in the sample space, this process involves the assumption of uniformity, so if two points are close together in the entry layer, they must also be close together on the exit layer.

During the machine learning phase, were selected 25% of the data-set labeled according to the percentage of wood failure (WF%), measured manually according to NBR 14.466-2 (ABNT, 2012).

The samples considered all five classes, approximately 1200 images, to proceed the first classification based on wood boards classification algorithm presented by Affonso et al. (2017) and the classification results were used in the CNNs transfer learning step.

The purpose of using active learning is to reduce the number of images necessary for training the model, by using labeled and unlabeled images in the construction of the model. And the human expert can focus on the structures in the data, rather than a one-to-one classification.

4.2.5. Convolutional neural networks - CNNs

The CNNs were built with 75% of the original set of images, and from this, a set of 66% of the images was selected for training and 33% for model validation.

Besides that, some computational experiments were carried out to optimize the CNN topology as shown in Table 2., for the Class data set. The number of maximum training iterations (epochs) was set to 30.

For each class, the CNN algorithm was performed 30 epochs, due to the tuning of the learning rate process and cost parameters.

Table 2. Convolutional neural network parameters

Layer (Type)	Output Shape	Parameter
Input - 2 (Input Layer)	None, 100, 100, 3	0
Zero padding 2d-2 (Zero Padding)	None, 106, 106, 3	0
Conv-0 (Convolution 2D)	None, 104, 104, 40	1120
Bn-0 (Batch Normalization)	None, 104, 104, 40	160
Activation-5 (Activation)	None, 104, 104, 40	0
Max pool (Max Pooling 2D)	None, 52, 52, 40	0
Conv-1 (Convolution 2D)	None, 50, 50, 24	8664
Bn-1 (Batch Normalization)	None, 50, 50, 24	96
Activation-6 (Activation)	None, 50, 50, 24	0
Max pool-1 (Max Pooling 2D)	None, 25, 25, 24	0
Conv-2 (Convolution 2D)	None, 23, 23, 16	3472
Bn-2 (Batch Normalization)	None, 23, 23, 16	64
Activation-7 (Activation)	None, 23, 23, 16	0
Max pool-2 (Max Pooling 2D)	None, 11, 11, 16	0
Conv-3 (Convolution 2D)	None, 9, 9, 8	1160
Bn-3 (Batch Normalization)	None, 9, 9, 8	32
Activation-8 (Activation)	None, 9, 9, 8	0
Max pool-3 (Max Pooling 2D)	None, 4, 4, 8	0
Flatten-2 (Flatten)	None, 128	0
Fc (Dense)	None, 12	1548

4.2.6. Confusion Matrix and evaluation

The constructed CNN models produced a confusion matrix composed of True-positive (TP), False-positive (FP), True-negative (TN), and False-negative (FN) metrics to measure the model generalization.

Was considered True-positive (TP), the model which classifies the example as positive and the actual label is also positive. False-positive (FP) was a model that classifies the example as positive, but the actual label is negative. The True-negative (TN), when the model classifies the example as negative and the actual label is also

negative. And False-negative (FN), when the model classifies the example as negative, but the label is positive.

Based on the confusion matrix, four different metrics to evaluate the CNN model were calculated: Accuracy (Eq. 1), Precision (Eq. 2), Sensitivity (Eq. 3) and Specificity (Eq. 4) by the following equations:

Equation 1. $Accuracy = (TP + TN)/(TP + TN + FP + FN)$

Equation 2. $Precision = TP/(TP + FP)$

Equation 3. $Sensitivity = TP/(TP + FN)$

Equation 4. $Specificity = TN/(TN + FP)$

These metrics were the base to build the Receiver Operating Characteristic curve (ROC curve), which was used to evaluate the five CNNs model's efficiency to plywood classification.

4.2.7. Receiver Operating Characteristic – ROC Curve

The ROC Curve is a way to improve the CNNs analysis through the plotting of the True-positive rate (TP) against the False-positive rate (FP) in various threshold settings, and it is more informative than just a numerical value of accuracy, sensitivity, or specificity.

The ideal point of the ROC curve is the upper left corner, with a true positive rate of 1 and a false positive rate of 0. The various points on the curve were generated by the gradual change of the threshold.

4.3. Results and discussion

The active learning-based CNNs implemented to the classification of plywood bonding quality results and the evaluation metrics are presented in Table 3.

Table 3. CNN bonding quality models and evaluation metrics

Model	Accuracy (%)	Precision (%)	Sensitivity (%)	Specificity (%)
Generalist	94.36	84.99	92.88	94.83
<i>Pinus</i>	92.46	90.21	93.45	91.64
<i>Eucalyptus</i>	91,84	94.18	90.68	93.24
PF	94.96	93.52	91.77	96.64
UF	60,90	70.03	62.74	56.06

The models presented similar behavior to the evaluation metrics, Accuracy, Precision, Sensitivity, and Specificity, except the UF model, which presented the worst results among all models.

The species models presented similar results to accuracy and specificity, which demonstrated the model's effectiveness to allocate the samples to their respective classes.

The *Eucalyptus* model presented the higher accuracy to the C1 class and the higher precision rate of the models.

The *Pinus* model expressed the best sensitivity results, that behavior may be associated with a good sampling size which was enough to guarantee good class classification and avoided overfitting.

A different behavior was observed to adhesives models. The FF model presented the best overall result of all models and the opposite was observed to the UF model with the worst results to the evaluation metrics.

The FF model presented higher accuracy to four of the five classes (C2, C3, C4, and C5). The UF model presented the lowest accuracy values to all five classes and wasn't able to classify samples to the C1 class.

The results may be influenced by the color contrast of the adhesives. The FF model presented a dark-brown color and facilitated the recognition of wood and adhesive features. Besides the light-white color of UF adhesive, the smaller sample size and the high-class imbalance of the UF model was key factor to its result. However, the UF model may be improved with the use of augmentation techniques or the expansion of the samples in further studies.

The Generalist model was able to correctly identify the bonding quality classes independently of the production factors. The model presented high accuracy, sensitivity, and specificity, only precision presented minor results.

The effect of high FP occurrence could be associated with the use of a large amount of very similar information and the imbalance of the distribution of the sample of the classes. Furthermore, when evaluating the accuracy of the Generalist model, it was possible to identify that the model presented an accuracy above 89% for all classes.

It is noteworthy that some ratings obtained accuracy above 70%, and this is an excellent result for the ratings of laminates using CNNs as the resolution model.

The proposed models proved to be able to classify the bonding quality of plywood according to the panel composition. To improve the classification results, it is necessary to reduce the unbalance of the number of images between classes.

To improve the classification results, it is necessary the reduce the unbalance of the number of images between classes.

The use of ROC curves allows the graphical evaluation of the model's classification performance based on the sensitivity and specificity of each of the five classes. An ideal model with a good classification performance aims to present a ROC curve located at the left upper corner of the ROC area.

An unwanted model presents the ROC curve next to the central line, which represents a low capacity of correct classification, with results very similar to a random guess.

To all models was possible to verify a trend of better classification to classes C1 and C5, except for the UF model. The intermediate class C3 presented the highest difficulty of classification for all models, regardless of the species or adhesive.

However, this result was already expected because of the intermediate classes with greater difficulty in human classification, the imbalance between the sample number of classes is also one of the influencing factors of this trend. Future studies should consider the use of data sets with more homogeneous distribution or the use of augmentation techniques to reduce these constraints.

The ROC curves of the adhesive models are presented in figure 1.

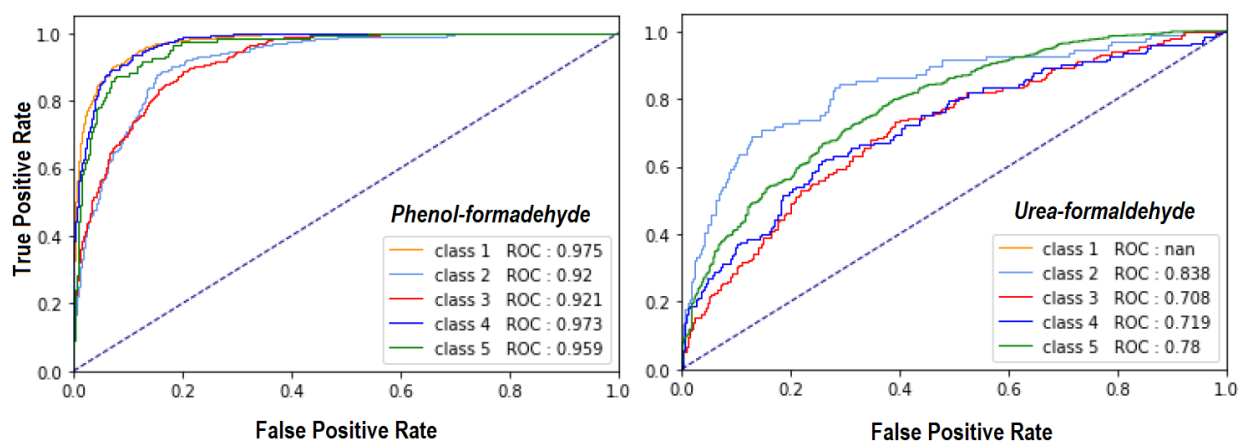


Figure 3. ROC curves for adhesive models

The use of different wood species did not negatively influence the classification efficiency of the models presented, in which both presented mean classification accuracy above 90% and the learning samples were sufficient for the correct generalization independent of the wood species used.

The ROC curves of the species models are presented in the Figure 2.

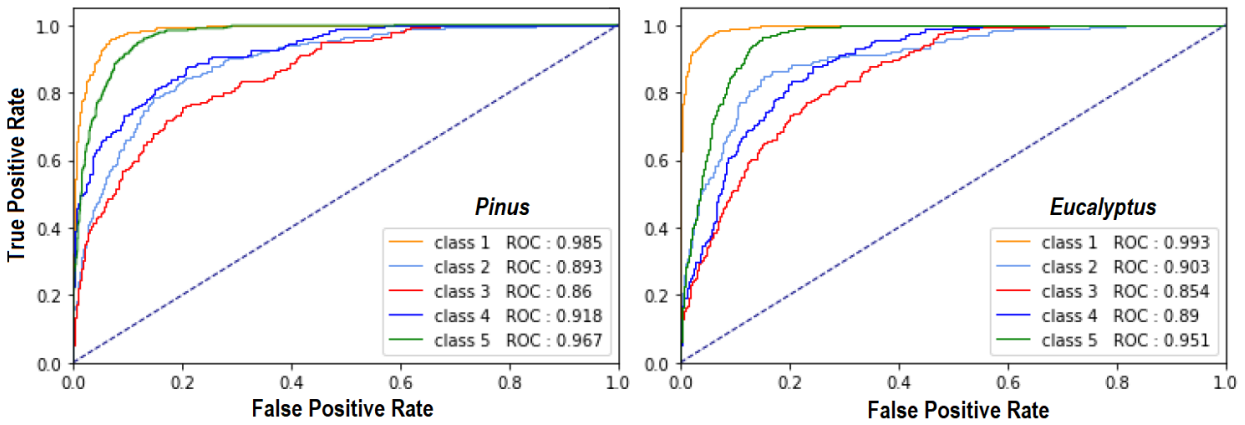


Figure 4. ROC curves for specie models

The Generalist model was efficient to address the samples to its classes, independently of the wood species and adhesive utilized, demonstrating an important advance in the development of the automated visual classification systems for plywood bonding quality.

The high accuracy and the good performance of the model, allow the use of automated visual classification systems with direct application to the plywood industry, helping the quick assessment of the wood failure percentile (WF%) with minimum human interference. The Generalist ROC curve is presented in Figure 3.

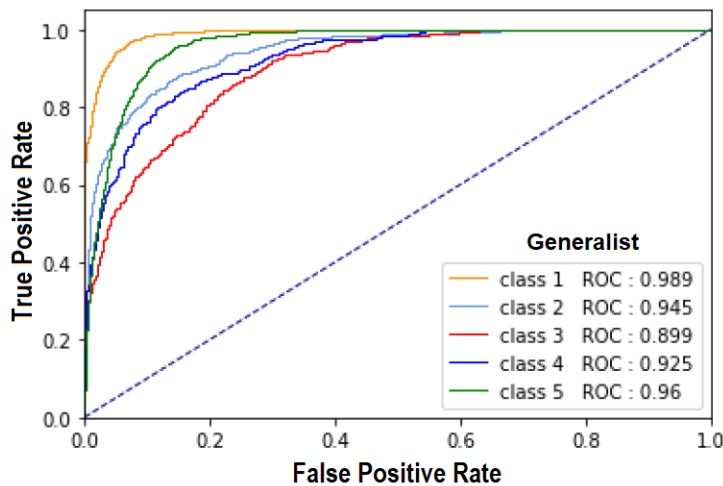


Figure 5. ROC curve for Generalist Model

4.4. Conclusions

The active learning CNN implemented to classify the bonding quality of four different plywood panels was efficient, reaching a mean accuracy of 94.4% to the Generalist model.

The Phenol-formaldehyde (PF) model presented the higher mean accuracy, while Urea-formaldehyde (UF) presented the worst result.

The species models presented intermediate and similar results independent of the species characteristics.

The lack of balance in the amount of data caused a difference in class accuracy on the models, and in further experiments, they must be adjusted to a more homogeneous distribution to provide more reliable results.

The proposed models presented good results and could be used as a starting point for the development of plywood bonding classification systems for industrial use.

Acknowledgement

This work was carried out with the support of the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) by the PROEX - DR Scholarship.

References

- AFFONSO, C. O.; ROSSI, A. L. D.; VIEIRA, F. H. A.; CARVALHO, A. C. P. L. F. Deep learning for biological image classification. **Expert systems with applications**, 85 (2017) 114–122. <http://dx.doi.org/10.1016/j.eswa.2017.05.039>
- ALAPURANEN, P., WESTMAN, T. Automatic visual inspection of wood surfaces. **Proceedings. 11th IAPR International Conference on Pattern Recognition**. 1992. doi:10.1109/icpr.1992.201578

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12466 - 1 Madeira compensada – Qualidade de colagem Parte 1: Métodos de ensaio**, Brasil 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT; **NBR ISO 12466 - 2 Madeira compensada – Qualidade de colagem Parte 2: Requisitos**, Brasil 2012.
- BARELLI, F. **Introdução à visão computacional**. Casa do Código, São Paulo, Brasil, 2019.
- CHO, T.; CONNERS, R. W.; ARAMAN, P. A.; A Comparison of Rule-Based, K-Nearest Neighbor, and Neural Net Classifiers for Automated Industrial Inspection **Annals of IEEE/ACM International Conference on Developing and Managing Expert System Programs**, September 30 - October 2, 1991 Washington, D.C.
- CONNERS, R. W.; CHO, T.; NG, C. T.; DRAYER, T. T.; ARAMAN, P. A.; BRISBON, R. L.; A multisensory machine vision system for hardwood defect detection. **Annals of Process Control/Production Management of Wood Products: Technology for the '90s**. Athens, Georgia, October 31- November 1, 1990.
- DRAKE, P. R.; PACKIANATHER, M. S. A Decision Tree of Neural Networks for Classifying Images of Wood Veneer. **Int. J. Adv. Manuf. Technol.** 14:280-285, 1998.
- FUNCK, J. W.; ZHONG, Y.; BUTLER, D.A.; BRUNNER, C.C.; FORRER, J.B. Image segmentation algorithms applied to wood defect detection. **Computers and Electronics in Agriculture**, 41 (2003) 157/179
- GOGUL, I.; KUMAR, V. Flower species recognition system using convolution neural networks and transfer learning. **4th International Conference on Signal Processing, Communications and Networking (ICSCN -2017)**, March 16 – 18, 2017, Chennai, India, 2017 DOI: 10.1109/ICSCN.2017.8085675.
- GUO, F.; ALTANER, C. M. Properties of rotary peeled veneer and laminated veneer lumber (LVL) from New Zealand grown *Eucalyptus globoides*. **New Zealand Journal of Forestry Science** (2018) 48:3
- HAFEMANN, L. G.; OLIVEIRA, L. S.; CAVALIN, P. Forest species recognition using deep convolutional neural networks. **22nd International Conference on Pattern Recognition**, 1103 – 1107 p. 2014.

- HU, K.; WANG, B.; SHEN, Y.; GUAN, J.; CAI, Y. Defect identification method for poplar veneer based on progressive growing generated adversarial network and MASK R-CNN model. **BioResources** 15(2), 3041-3052, 2020.
- HUANG, F. J.; LECUN, Y. Large-scale Learning with SVM and Convolutional Nets for Generic Object Categorization. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)**, 2006, pp. 284-291, doi: 10.1109/CVPR.2006.164.
- HUBER, H. A.; MCMILLIN, C. W.; MCKINNEY, J. P. Lumber defect detection abilities of furniture rough mill employees. **FOREST PRODUCTS JOURNAL** Vol. 35, 79-82 p. No Nov/Dez, 1985.
- KWON, O.; LEE, H. G.; LEE, M.; JANG, S.; YANG, S.; PARK, S.; CHOI, I.; YEO, H. Automatic Wood Species Identification of Korean Softwood Based on Convolutional Neural Networks. **J. Korean Wood Sci. Technol.** 2017, 45(6): 797~808.
- LECUN, Y.; BENGIO, Y. Convolutional networks for images, Speech, and time-series. **The handbook of brain theory and neural networks** 3361.10 (1995): 1995.
- 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** 1989;1(4):541–551.
- RAVINDRAN, P.; COSTA, A.; SOARES, R.; WIEDENHOEFT, A. C. Classification of CITES-listed and other neotropical Meliaceae wood images using convolutional neural networks. **Plant Methods** (2018) 14:25 <https://doi.org/10.1186/s13007-018-0292-9>.
- SHI, J.; LI, Z.; ZHU, T.; WANG, D.; NI, C. Defect detection of industry wood veneer based on NAS and multi-channel mask R-CNN. **Sensors** 2020, 20, 4398; doi:10.3390/s20164398.
- TODOROKIA, C. L.; LOWELL, E.C.; DYKSTRA, D. Automated knot detection with visual post-processing of Douglas-fir veneer images. **Computers and Electronics in Agriculture** 70 (2010) 163–171
- URBONAS, A.; RAUDONIS, V.; MASKELIUNAS, R.; DAMAŠEVICIUS, R. Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning. **Appl. Sci.** 2019, 9, 4898; <https://doi.org/10.3390/app9224898>

YANG, F.; WANG, Y.; WANG, S.; CHENG, Y. Wood Veneer Defect Detection System Based on Machine Vision at International Symposium on Communication Engineering & Computer Science (CECS 2018) **Advances in Computer Science Research**, v. 86, 2018.

YANG, Y.; ZHOU, X.; LIU, Y.; HU, Z.; DING, F. Wood defect detection based on depth extreme learning machine. *Appl. Sci.* 2020, 10, 7488; doi:10.3390/app10217488

ZAMRI, M. I. P.; CORDOVA, F.; KHAIRUDDIN, A. S. M.; MOKHTAR, N.; YUSOF, R. Tree species classification based on image analysis using Improved-Basic Gray Level Aura Matrix. **Computers and Electronics in Agriculture**, 124 (2016) 227–233.

5. CONCLUSÕES GERAIS

Com base nos resultados do experimento apresentado no Artigo 1 podemos afirmar que os tratamentos P400, P350 e E350 atenderam aos requisitos de qualidade de colagem sendo considerados aprovados pela norma NBR 12.466 (2012) para uso em ambiente externo, apenas E400 não atingiu parâmetros mínimos sendo considerado reprovado.

A espécie foi o principal fator causador de diferença estatística e a gramatura não apresentou efeito verificável em MOR, MOE, Tmax ou WF%. Pode-se recomendar a gramatura 350 g/m² para os painéis compensados destinados ao uso em ambiente externo para ambas as espécies avaliadas.

No artigo 2, os painéis compensados produzidos com lâminas de *Pinus kesiya* e de *Eucalyptus grandis* x *Eucalyptus urophylla* e adesivo ureia-formaldeído, verificou-se que todos os tratamentos foram aprovados para a utilização em ambientes protegidos da umidade, segundo os requisitos da norma NBR 12.466 (2012).

O fator espécie foi significativo em todas as análises e os painéis de *Eucalyptus grandis* x *Eucalyptus urophylla* apresentaram melhor desempenho do que os tratamentos que utilizaram lâminas de *Pinus kesiya* para a maioria dos ensaios e condição de umidade.

Apenas nos tratamentos com lâminas de *Pinus kesiya* foi verificado efeito significativo do fator Gramatura, com redução significativa de Tmax e WF% na condição de ensaio úmido. Desta forma, todos os tratamentos podem ser recomendados para a produção industrial de compensados ureicos com lâminas das espécies *Pinus kesiya* e do clone de *Eucalyptus grandis* x *Eucalyptus urophylla*.

O artigo 3 demonstrou que a utilização de sistemas de visão computacional é uma alternativa viável para automatizar a avaliação visual da qualidade de colagem de compensados.

A utilização das Redes Neurais Convolucionais (CNNs) demonstrou um grande potencial para o desenvolvimento de sistemas mais acurados que a classificação realizada por humanos.

Em quatro dos cinco modelos de CNN desenvolvidos, a classificação do WF% obteve acurácia média acima de 90%, sendo que o melhor resultado foi observado para o modelo Fenol (94,96%) seguido por Generalista (94,36%), *Pinus*

(92,46), *Eucalyptus* (91,84) e o pior resultado foi observado para o modelo Ureia (60,90%). No entanto, este experimento necessitou reduzir o número de classes de WF% de 10 para apenas 5, para otimizar o aprendizado do algoritmo e reduzir a ocorrência de falsos positivos durante a classificação.

A redução do número de classes ainda não atende a necessidade de classificação de 10 classes como solicitado pela norma NBR 12.466 (2012).

Para melhorar a acurácia das CNNs é necessário expandir o conjunto de amostras e imagens além de recorrer às técnicas de Augmentation para refinar os algoritmos sem a redução da capacidade de generalização.

Os resultados do artigo 3 são promissores e servem como embasamento para os próximos estudos e pesquisas que desejem desenvolver sistemas de visão computacional mais precisos e eficientes para a determinação da qualidade de colagem de compensados de forma automatizada.

ANEXOS

Anexo A – Artigo 1

Flexão Estática

Tabela A-1. Dados de flexão estática para os compensados fenólicos

Tratamento	Espécie	Gramatura	Painel	Perpendicular			Paralela		
				ME (g/cm ³)	MOR (MPa)	MOE (MPa)	ME (g/cm ³)	MOR (MPa)	MOE (MPa)
Pf400	<i>Pinus</i>	400	1	0,677	47,078	3105,491	0,704	80,081	9600,418
Pf400	<i>Pinus</i>	400	1	0,728	49,606	3800,941	0,694	68,847	8749,894
Pf400	<i>Pinus</i>	400	2	0,672	41,527	2731,882	0,630	83,094	10387,799
Pf400	<i>Pinus</i>	400	2	0,658	39,334	2902,894	0,667	80,084	10797,340
Pf400	<i>Pinus</i>	400	3	0,657	41,870	3805,793	0,689	74,263	9456,993
Pf400	<i>Pinus</i>	400	3	0,648	37,721	3016,056	0,696	79,158	12048,252
Pf400	<i>Pinus</i>	400	4	0,663	43,396	3687,010	0,682	85,362	10136,216
Pf400	<i>Pinus</i>	400	4	0,654	44,252	2886,109	0,699	105,68	14027,459
Pf350	<i>Pinus</i>	350	1	0,656	32,673	3031,591	0,649	77,175	8328,515
Pf350	<i>Pinus</i>	350	1	0,690	34,217	2380,981	0,682	101,57	12534,910
Pf350	<i>Pinus</i>	350	2	0,659	42,666	3113,060	0,691	93,608	11345,704
Pf350	<i>Pinus</i>	350	2	0,684	46,059	3581,481	0,708	69,299	6281,127
Pf350	<i>Pinus</i>	350	3	0,682	40,274	3511,895	0,669	79,352	11112,661
Pf350	<i>Pinus</i>	350	3	0,647	34,760	2752,728	0,705	74,760	9539,450
Pf350	<i>Pinus</i>	350	4	0,719	54,597	3477,966	0,687	93,615	12072,371
Pf350	<i>Pinus</i>	350	4	0,692	40,752	3114,834	0,677	75,793	10563,707
Ef400	<i>Eucalyptus</i>	400	1	0,750	37,484	3531,019	0,714	68,266	12919,583
Ef400	<i>Eucalyptus</i>	400	1	0,681	34,584	3339,948	0,706	89,403	12327,746
Ef400	<i>Eucalyptus</i>	400	2	0,716	41,423	3695,134	0,700	84,737	11341,346
Ef400	<i>Eucalyptus</i>	400	2	0,707	44,174	3698,653	0,707	88,079	12742,454
Ef400	<i>Eucalyptus</i>	400	3	0,664	39,253	3410,930	0,660	77,341	11672,856
Ef400	<i>Eucalyptus</i>	400	3	0,703	40,929	3674,096	0,666	79,964	10901,769
Ef400	<i>Eucalyptus</i>	400	4	0,720	47,232	3694,914	0,730	85,649	12873,285
Ef400	<i>Eucalyptus</i>	400	4	0,732	46,419	3487,479	0,689	79,602	12625,295
Ef350	<i>Eucalyptus</i>	350	1	0,697	27,460	2635,977	0,702	89,251	11855,271
Ef350	<i>Eucalyptus</i>	350	1	0,709	38,501	3201,965	0,726	94,083	13119,609
Ef350	<i>Eucalyptus</i>	350	2	0,715	40,190	3739,621	0,720	96,983	12875,256
Ef350	<i>Eucalyptus</i>	350	2	0,723	40,838	3729,022	0,679	88,979	12149,893
Ef350	<i>Eucalyptus</i>	350	3	0,704	43,230	3843,778	0,725	99,870	12533,981
Ef350	<i>Eucalyptus</i>	350	3	0,726	46,289	3716,043	0,733	103,023	13047,795
Ef350	<i>Eucalyptus</i>	350	4	0,699	37,085	3303,826	0,714	96,508	12573,018
Ef350	<i>Eucalyptus</i>	350	4	0,682	34,779	3174,620	0,701	91,202	11474,940

Tabela A-2. Teste de Levene para verificar a homogeneidade de variâncias de MOR e MOE para flexão estática nas direções perpendicular e paralela

Direção	Levene Estatísticas	GL1	GL2	Sig.	
Perpendicular	MOR (MPa)	0,707	3	28	0,556 ns
	MOE (MPa)	3,302	3	28	0,035 *
	ME (g/cm ³)	0,603	3	28	0,619 ns
Paralela	MOR (MPa)	1,886	3	28	0,155 ns
	MOE (MPa)	3,450	3	28	0,030 *
	ME (g/cm ³)	0,253	3	28	0,859 ns

* = Variâncias não homogêneas pelo teste de Levene a 5% de probabilidade; ns = Variâncias homogêneas pelo teste de Levene a 5% de probabilidade

Tabela A-3. Testes de normalidade para MOR e MOE dos compensados fenólicos

Direção de ensaio	de Tratamento		Kolmogorov-Smirnov			Shapiro-Wilk		
			Estatísticas	GL	Sig.	Estatísticas	GL	Sig.
Perpendicular	MOR	Pf400	0,134	8	0,200 ns	0,976	8	0,941 ns
		Pf350	0,171	8	0,200 ns	0,923	8	0,456 ns
		Ef400	0,126	8	0,200 ns	0,968	8	0,882 ns
		Ef350	0,149	8	0,200 ns	0,959	8	0,796 ns
	MOE	Pf400	0,246	8	0,167 ns	0,838	8	0,072 ns
		Pf350	0,182	8	0,200 ns	0,923	8	0,451 ns
		Ef400	0,276	8	0,072 ns	0,861	8	0,123 ns
		Ef350	0,256	8	0,133 ns	0,880	8	0,190 ns
	ME	Pf400	0,256	8	0,131 ns	0,764	8	0,012 *
		Pf350	0,181	8	0,200 ns	0,946	8	0,671 ns
		Ef400	0,159	8	0,200 ns	0,983	8	0,978 ns
		Ef350	0,127	8	0,200 ns	0,972	8	0,913 ns
Paralela	MOR	Pf400	0,256	8	0,132 ns	0,854	8	0,104 ns
		Pf350	0,254	8	0,136 ns	0,893	8	0,248 ns
		Ef400	0,174	8	0,200 ns	0,925	8	0,470 ns
		Ef350	0,148	8	0,200 ns	0,946	8	0,668 ns
	MOE	Pf400	0,219	8	0,200 ns	0,903	8	0,310 ns
		Pf350	0,189	8	0,200 ns	0,928	8	0,495 ns
		Ef400	0,222	8	0,200 ns	0,875	8	0,169 ns
		Ef350	0,187	8	0,200 ns	0,948	8	0,690 ns
	ME	Pf400	0,240	8	0,196 ns	0,816	8	0,042 *
		Pf350	0,120	8	0,200 ns	0,965	8	0,855 ns
		Ef400	0,181	8	0,200 ns	0,943	8	0,646 ns
		Ef350	0,166	8	0,200 ns	0,924	8	0,466 ns

* = Rejeita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade; ns = Aceita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade

Tabela A-4. Análise de variância para ME (g/cm³) na direção perpendicular

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	0,010 ^a	3	,003	5,907	0,003
Intercept	15,279	1	15,279	28392,581	0,000
Gramatura	9,964E-05	1	9,964E-05	0,185	0,670 ns
Espécie	0,009	1	0,009	17,049	0,000 *
Gramatura * Espécie	0,000	1	0,000	0,488	0,491 ns
Error	0,015	28	0,001		
Total	15,303	32			
Corrected Total	0,025	31			

a. R Squared = ,388 (Adjusted R Squared = ,322); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-5. Desdobramento do fator espécie para ME (g/cm³) na direção perpendicular

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference		
				Lower Bound	Upper Bound	
<i>Eucalyptus</i>	<i>Pinus</i>	0,034*	0,008	0,000 *	0,017	0,051
<i>Pinus</i>	<i>Eucalyptus</i>	-0,034*	0,008	0,000 *	-0,051	-0,017

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-6. Análise de variância para ME (g/cm³) na direção paralela

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	0,005 ^a	3	0,002	3,432	0,030
Intercept	15,404	1	15,404	33700,884	0,000
Gramatura	0,001	1	0,001	1,262	0,271 ns
Espécie	0,004	1	0,004	8,013	0,009 *
Gramatura * Espécie	0,000	1	0,000	1,021	0,321 ns
Error	0,013	28	0,000		
Total	15,422	32			
Corrected Total	0,018	31			

a. R Squared = ,269 (Adjusted R Squared = ,191); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-7. Desdobramento do fator Espécie para ME (g/cm³) na direção paralela

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	0,021*	0,008	0,009 *	0,006	0,037
<i>Pinus</i> <i>Eucalyptus</i>	-0,021*	0,008	0,009 *	-0,037	-0,006

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-8. Análise de variância de MOR para flexão estática na direção perpendicular

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	85,346 ^a	3	28,449	0,952	0,429
Intercept	53681,472	1	53681,472	1796,005	0,000
Espécie	29,860	1	29,860	0,999	0,326 ns
Gramatura	54,897	1	54,897	1,837	0,186 ns
Espécie * Gramatura	0,589	1	0,589	0,020	0,889 ns
Error	836,903	28	29,889		
Total	54603,720	32			
Corrected Total	922,249	31			

a. R Squared = ,093 (Adjusted R Squared = -,005); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-9. Análise de Variância de MOE para flexão estática na direção Perpendicular

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	920979,503a	3	306993,168	2,188	0,112
Intercept	356296397,978	1	356296397,978	2538,898	0,000
Espécie	773865,907	1	773865,907	5,514	0,026*
Gram	145659,858	1	145659,858	1,038	0,317 ns
Espécie * Gramatura	1453,738	1	1453,738	0,010	0,920 ns
Error	3929381,948	28	140335,070		
Total	361146759,430	32			
Corrected Total	4850361,452	31			

a. R Squared = ,190 (Adjusted R Squared = ,103); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-10. Desdobramento do fator espécie para MOE na direção perpendicular

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	311,020*	132,446	0,026*	39,717	582,323
<i>Pinus</i> <i>Eucalyptus</i>	-311,020*	132,446	0,026*	-582,323	-39,717

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-11. Análise de variância de MOR para flexão estática na direção paralela

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	978,207 ^a	3	326,069	4,046	0,017
Intercept	233702,352	1	233702,352	2899,524	0,000
Espécie	259,919	1	259,919	3,225	0,083 ns
Gramatura	416,552	1	416,552	5,168	0,031 *
Espécie * Gramatura	301,736	1	301,736	3,744	0,063 ns
Error	2256,807	28	80,600		
Total	236937,366	32			
Corrected Total	3235,014	31			

a. R Squared = ,302 (Adjusted R Squared = ,228); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-12. Desdobramento para o fator gramatura em MOR na direção paralela

Gramatura		Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
					Lower Bound	Upper Bound
350	<i>Eucalyptus</i> <i>Pinus</i>	11,841*	4,489	0,013*	2,646	21,036
	<i>Pinus</i> <i>Eucalyptus</i>	-11,841*	4,489	0,013*	-21,036	-2,646
400	<i>Eucalyptus</i> <i>Pinus</i>	-0,441	4,489	0,922 ns	-9,636	8,754
	<i>Pinus</i> <i>Eucalyptus</i>	0,441	4,489	0,922 ns	-8,754	9,636
Espécie		Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
					Lower Bound	Upper Bound
<i>Eucalyptus</i>	350 400	13,357*	4,489	0,006*	4,162	22,552
	400 350	-13,357*	4,489	0,006*	-22,552	-4,162
<i>Pinus</i>	350 400	1,074	4,489	0,813 ns	-8,121	10,270
	400 350	-1,074	4,489	0,813 ns	-10,270	8,121

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-13. Análise de Variância de MOE para flexão estática na direção paralela

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	29264340,455 ^a	3	9754780,152	4,797	0,008
Intercept	4140884568,104	1	4140884568,104	2036,211	0,000
Espécie	28221244,009	1	28221244,009	13,877	0,001*
Gramatura	45037,695	1	45037,695	0,022	0,883 ns
Espécie * Gramatura	998058,751	1	998058,751	0,491	0,489 ns
Error	56941435,299	28	2033622,689		
Total	4227090343,858	32			
Corrected Total	86205775,754	31			

a. R Squared = ,339 (Adjusted R Squared = ,269); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-14. Desdobramento do fator espécie para MOE de flexão estática na direção paralela

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	1878,205*	504,185	0,001*	845,429	2910,982
<i>Pinus</i> <i>Eucalyptus</i>	-1878,205*	504,185	0,001*	-2910,982	-845,429

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Cisalhamento na linha de cola

Tensão de Ruptura (Tmax)

Tabela A-15. Tensão de ruptura para o ensaio de cisalhamento na linha de cola para compensados fenólicos

Tratamento	Espécie	Gramatura	Tmax (MPa) D	Tmax (MPa) CW	Tmax (MPa) BDB
1	<i>Pinus</i>	400	2,32	2,79	1,48
1	<i>Pinus</i>	400	2,88	2,60	1,66
1	<i>Pinus</i>	400	2,99	1,84	1,71
1	<i>Pinus</i>	400	3,33	2,39	1,62
1	<i>Pinus</i>	400	2,93	2,15	1,90
1	<i>Pinus</i>	400	2,78	2,01	1,86
1	<i>Pinus</i>	400	3,10	2,58	1,78
1	<i>Pinus</i>	400	3,37	2,77	1,32
1	<i>Pinus</i>	400	2,95	1,83	1,39
1	<i>Pinus</i>	400	2,46	2,25	1,39
1	<i>Pinus</i>	400	2,25	2,26	1,47
1	<i>Pinus</i>	400	3,11	1,93	1,39
1	<i>Pinus</i>	400	2,55	2,06	1,37
1	<i>Pinus</i>	400	3,21	1,95	1,27
1	<i>Pinus</i>	400	3,30	2,19	1,27
1	<i>Pinus</i>	400	2,59	2,15	1,65
1	<i>Pinus</i>	400	3,01	2,45	1,12
1	<i>Pinus</i>	400	2,98	2,09	1,42
1	<i>Pinus</i>	400	3,23	2,32	1,17
1	<i>Pinus</i>	400	3,04	2,10	1,52
1	<i>Pinus</i>	400	2,98	2,24	1,58
1	<i>Pinus</i>	400	3,22	1,83	1,27
1	<i>Pinus</i>	400	2,92	2,49	1,41
1	<i>Pinus</i>	400	3,05	2,60	1,17
1	<i>Pinus</i>	400	3,42	1,99	0,81
1	<i>Pinus</i>	400	3,93	2,07	1,52
1	<i>Pinus</i>	400	2,86	2,07	1,34
1	<i>Pinus</i>	400	2,98	2,12	1,65
1	<i>Pinus</i>	400	3,19	2,20	1,13
1	<i>Pinus</i>	400	3,02	2,12	1,40
1	<i>Pinus</i>	400	3,14	2,33	1,43
1	<i>Pinus</i>	400	2,75	1,94	1,47
1	<i>Pinus</i>	400	2,47	2,30	1,55
1	<i>Pinus</i>	400	3,81	2,23	1,59
1	<i>Pinus</i>	400	3,18	1,77	1,29
1	<i>Pinus</i>	400	3,14	2,56	1,56
1	<i>Pinus</i>	400	3,24	2,20	1,56
1	<i>Pinus</i>	400	3,32	2,46	1,70
1	<i>Pinus</i>	400	2,63	2,54	1,37
1	<i>Pinus</i>	400	3,23	2,91	1,62
2	<i>Pinus</i>	350	3,37	2,36	1,32
2	<i>Pinus</i>	350	2,95	1,88	1,56
2	<i>Pinus</i>	350	2,55	2,47	1,50
2	<i>Pinus</i>	350	2,89	2,32	1,17
2	<i>Pinus</i>	350	3,18	2,13	1,87
2	<i>Pinus</i>	350	2,75	2,85	1,36
2	<i>Pinus</i>	350	2,83	1,93	1,66
2	<i>Pinus</i>	350	1,98	2,20	1,22
2	<i>Pinus</i>	350	3,73	2,31	1,43
2	<i>Pinus</i>	350	2,63	2,20	1,55
2	<i>Pinus</i>	350	3,31	2,05	1,85
2	<i>Pinus</i>	350	2,93	2,77	0,91
2	<i>Pinus</i>	350	2,61	2,42	1,72
2	<i>Pinus</i>	350	2,78	1,93	1,43
2	<i>Pinus</i>	350	2,64	2,58	1,58
2	<i>Pinus</i>	350	3,12	2,40	1,88
2	<i>Pinus</i>	350	3,60	1,95	1,52
2	<i>Pinus</i>	350	3,24	2,85	1,36
2	<i>Pinus</i>	350	3,17	2,77	1,97

2	<i>Pinus</i>	350	2,98	2,16	1,91
2	<i>Pinus</i>	350	3,21	1,90	1,30
2	<i>Pinus</i>	350	2,71	1,94	0,89
2	<i>Pinus</i>	350	2,79	2,22	1,36
2	<i>Pinus</i>	350	3,49	1,89	1,46
2	<i>Pinus</i>	350	2,96	1,84	1,64
2	<i>Pinus</i>	350	2,45	2,01	1,53
2	<i>Pinus</i>	350	2,81	1,84	1,37
2	<i>Pinus</i>	350	2,24	2,13	0,79
2	<i>Pinus</i>	350	2,76	2,32	1,20
2	<i>Pinus</i>	350	3,12	1,60	1,56
2	<i>Pinus</i>	350	3,03	2,39	1,52
2	<i>Pinus</i>	350	3,31	2,38	1,08
2	<i>Pinus</i>	350	3,21	2,63	1,89
2	<i>Pinus</i>	350	2,90	1,94	1,42
2	<i>Pinus</i>	350	3,99	2,08	1,04
2	<i>Pinus</i>	350	3,14	2,35	1,88
2	<i>Pinus</i>	350	3,04	2,64	2,10
2	<i>Pinus</i>	350	3,61	2,14	2,38
2	<i>Pinus</i>	350	3,56	2,45	1,81
2	<i>Pinus</i>	350	2,87	2,22	1,49
<hr/>					
3	<i>Eucalyptus</i>	400	2,04	1,74	1,62
3	<i>Eucalyptus</i>	400	1,63	1,47	1,50
3	<i>Eucalyptus</i>	400	2,14	1,33	1,45
3	<i>Eucalyptus</i>	400	1,85	1,31	0,00
3	<i>Eucalyptus</i>	400	1,72	1,67	0,47
3	<i>Eucalyptus</i>	400	2,21	1,44	0,55
3	<i>Eucalyptus</i>	400	1,85	1,69	0,54
3	<i>Eucalyptus</i>	400	1,68	1,16	0,40
3	<i>Eucalyptus</i>	400	1,85	1,72	0,35
3	<i>Eucalyptus</i>	400	1,77	1,18	0,40
3	<i>Eucalyptus</i>	400	2,36	1,39	0,95
3	<i>Eucalyptus</i>	400	2,29	1,98	1,09
3	<i>Eucalyptus</i>	400	1,93	2,05	1,35
3	<i>Eucalyptus</i>	400	2,54	2,08	1,22
3	<i>Eucalyptus</i>	400	2,11	1,64	1,08
3	<i>Eucalyptus</i>	400	2,45	1,32	0,82
3	<i>Eucalyptus</i>	400	2,23	1,44	2,03
3	<i>Eucalyptus</i>	400	2,49	1,36	0,97
3	<i>Eucalyptus</i>	400	2,39	1,57	1,11
3	<i>Eucalyptus</i>	400	1,84	1,83	1,55
3	<i>Eucalyptus</i>	400	1,72	1,46	0,89
3	<i>Eucalyptus</i>	400	1,70	2,49	0,95
3	<i>Eucalyptus</i>	400	1,74	1,75	1,07
3	<i>Eucalyptus</i>	400	1,94	2,11	0,40
3	<i>Eucalyptus</i>	400	1,96	1,61	1,19
3	<i>Eucalyptus</i>	400	2,06	1,67	0,82
3	<i>Eucalyptus</i>	400	2,51	1,70	0,78
3	<i>Eucalyptus</i>	400	2,23	1,36	0,80
3	<i>Eucalyptus</i>	400	2,33	1,62	0,90
3	<i>Eucalyptus</i>	400	2,27	1,42	0,82
3	<i>Eucalyptus</i>	400	2,20	2,10	0,50
3	<i>Eucalyptus</i>	400	2,24	1,78	1,02
3	<i>Eucalyptus</i>	400	1,83	2,33	0,97
3	<i>Eucalyptus</i>	400	1,97	1,48	1,01
3	<i>Eucalyptus</i>	400	1,94	1,57	1,04
3	<i>Eucalyptus</i>	400	2,01	2,26	0,65
3	<i>Eucalyptus</i>	400	2,27	1,76	1,16
3	<i>Eucalyptus</i>	400	2,16	1,78	1,00
3	<i>Eucalyptus</i>	400	2,24	1,89	0,85
3	<i>Eucalyptus</i>	400	0,00	1,84	0,02
<hr/>					
4	<i>Eucalyptus</i>	350	2,47	1,58	0,84
4	<i>Eucalyptus</i>	350	2,37	1,79	0,78
4	<i>Eucalyptus</i>	350	0,87	1,91	0,39
4	<i>Eucalyptus</i>	350	1,62	1,86	0,86
4	<i>Eucalyptus</i>	350	2,12	1,61	0,47
4	<i>Eucalyptus</i>	350	1,70	1,46	1,09

4	<i>Eucalyptus</i>	350	2,15	1,47	0,71
4	<i>Eucalyptus</i>	350	2,14	1,36	0,34
4	<i>Eucalyptus</i>	350	2,04	1,22	0,77
4	<i>Eucalyptus</i>	350	1,90	1,59	0,64
4	<i>Eucalyptus</i>	350	1,81	1,60	1,60
4	<i>Eucalyptus</i>	350	2,58	1,91	1,32
4	<i>Eucalyptus</i>	350	2,56	1,59	1,14
4	<i>Eucalyptus</i>	350	1,75	1,88	1,00
4	<i>Eucalyptus</i>	350	2,39	1,71	1,70
4	<i>Eucalyptus</i>	350	2,17	1,14	1,09
4	<i>Eucalyptus</i>	350	2,46	1,97	0,97
4	<i>Eucalyptus</i>	350	1,84	2,26	1,06
4	<i>Eucalyptus</i>	350	2,16	1,99	0,93
4	<i>Eucalyptus</i>	350	2,32	2,18	0,96
4	<i>Eucalyptus</i>	350	2,22	2,19	1,27
4	<i>Eucalyptus</i>	350	2,48	2,14	1,37
4	<i>Eucalyptus</i>	350	2,56	2,27	1,54
4	<i>Eucalyptus</i>	350	2,51	1,47	1,60
4	<i>Eucalyptus</i>	350	2,17	1,45	1,11
4	<i>Eucalyptus</i>	350	1,93	2,34	1,26
4	<i>Eucalyptus</i>	350	3,24	1,76	1,31
4	<i>Eucalyptus</i>	350	2,28	1,84	1,54
4	<i>Eucalyptus</i>	350	2,24	2,10	0,89
4	<i>Eucalyptus</i>	350	3,17	2,35	0,97
4	<i>Eucalyptus</i>	350	1,90	1,51	1,10
4	<i>Eucalyptus</i>	350	2,17	1,66	1,45
4	<i>Eucalyptus</i>	350	2,09	1,53	0,75
4	<i>Eucalyptus</i>	350	1,83	2,44	1,17
4	<i>Eucalyptus</i>	350	2,08	1,59	0,98
4	<i>Eucalyptus</i>	350	1,85	2,56	1,15
4	<i>Eucalyptus</i>	350	2,36	1,63	0,90
4	<i>Eucalyptus</i>	350	2,12	1,72	1,11
4	<i>Eucalyptus</i>	350	1,68	1,55	1,14
4	<i>Eucalyptus</i>	350	1,85	1,51	1,08

Tabela A-16. Teste de Levene para verificar a homogeneidade de variâncias da Tmax na condição de ensaio - Seco

Condição	F	df1	df2	Sig.
Seca – D	0,306	3	156	0,821 ns
Água Fria – CW	0,813	3	156	0,488 ns
Ciclo – BDB	4,136	3	156	0,007*

* = Variâncias não homogêneas pelo teste de Levene a 5% de probabilidade; ns = Variâncias homogêneas pelo teste de Levene a 5% de probabilidade

Tabela A-17. Testes de normalidade para Tmax (MPa) para três condições de ensaio

Condição	Tratamento	Kolmogorov-Smirnov			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
WF (%) - D	Pf400	0,112	40	0,200 ns	0,963	40	0,211 ns
	Pf350	0,060	40	0,200 ns	0,990	40	0,975 ns
	Ef400	0,107	39	0,200 ns	0,961	39	0,194 ns
	Ef350	0,102	40	0,200 ns	0,939	40	0,032 *
WF (%) - CW	Pf400	0,106	40	0,200 ns	0,969	40	0,336 ns
	Pf350	0,097	40	0,200 ns	0,969	40	0,341 ns
	Ef400	0,103	40	0,200 ns	0,964	40	0,231 ns
	Ef350	0,132	40	0,076 ns	0,960	40	0,172 ns
WF (%) - BDB	Pf400	0,071	40	0,200 ns	0,980	40	0,683 ns
	Pf350	0,099	40	0,200 ns	0,984	40	0,840 ns
	Ef400	0,109	40	0,200 ns	0,976	40	0,558 ns
	Ef350	0,086	40	0,200 ns	0,979	40	0,665 ns

* = Rejeita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade; ns = Aceita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade

Tabela A-18. Análise de variância para Tmax (MPa) na condição – Seco (D)

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	35,027 ^a	3	11,676	74,623	0,000
Intercept	1041,114	1	1041,114	6654,175	0,000
Gramatura	0,159	1	0,159	1,015	0,315 ns
Espécie	34,652	1	34,652	221,474	0,000*
Gramatura * Espécie	0,216	1	0,216	1,381	0,242 ns
Error	24,408	156	0,156		
Total	1100,549	160			
Corrected Total	59,434	159			

a. R Squared = ,589 (Adjusted R Squared = ,581); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-19. Desdobramento do fator Espécie para Tmax (MPa) na condição Seco (D)

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	-0,931*	0,063	0,000 *	-1,054	-0,807
<i>Pinus</i> <i>Eucalyptus</i>	0,931*	0,063	0,000 *	0,807	1,054

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-20. Análise de variância para a tensão de resistência ao cisalhamento na linha de cola (Tmax) na condição Água Fria - CW

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	10,276 ^a	3	3,425	34,996	0,000 ns
Intercept	632,661	1	632,661	6463,660	0,000 ns
Gramatura	0,105	1	0,105	1,073	0,302 ns
Espécie	10,040	1	10,040	102,575	0,000 *
Gramatura * Espécie	0,131	1	0,131	1,339	0,249 ns
Error	15,269	156	0,098		
Total	658,207	160			
Corrected Total	25,545	159			

a. R Squared = ,402 (Adjusted R Squared = ,391); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-21. Desdobramento do fator Espécie para Tmax na condição Água Fria - CW

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	-0,501*	0,049	0,000 *	-0,599	-0,403
<i>Pinus</i> <i>Eucalyptus</i>	0,501*	0,049	0,000 *	0,403	0,599

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-22. Análise de variância para Tmax (MPa) para o ensaio de cisalhamento na linha de cola na condição BDB

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	10,535 ^a	3	3,512	31,797	0,000
Intercept	243,296	1	243,296	2202,937	0,000
Gramatura	0,437	1	0,437	3,955	0,048 *
Espécie	10,010	1	10,010	90,636	0,000 *
Gramatura * Espécie	0,088	1	0,088	0,800	0,372 ns
Error	17,229	156	0,110		
Total	271,060	160			
Corrected Total	27,764	159			

a. R Squared = ,379 (Adjusted R Squared = ,368); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela A-23. Desdobramento para o fator espécie para Tmax (MPa) na condição BDB

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	-0,500*	0,053	0,000 *	-0,604	-0,396
<i>Pinus</i> <i>Eucalyptus</i>	0,500*	0,053	0,000 *	0,396	0,604

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-24. Desdobramento para o fator Gramatura para Tmax (MPa) na condição BDB

(I) Gramatura	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
350 400	0,105*	0,053	0,048 *	0,001	0,208
400 350	0,105*	0,053	0,048 *	-0,208	-0,001

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela A-25. Dados de percentual de falha na madeira (WF%) para o ensaio de cisalhamento na linha de cola nas diferentes condições de ensaio

Tratamento	Espécie	Gramatura	Classe de WF% D	Classe de WF% CW	Classe de WF% BDB
Pf400	<i>Pinus</i>	400	na	3	2
Pf400	<i>Pinus</i>	400	na	3	2
Pf400	<i>Pinus</i>	400	8	4	3
Pf400	<i>Pinus</i>	400	8	4	3
Pf400	<i>Pinus</i>	400	7	4	2
Pf400	<i>Pinus</i>	400	7	4	2
Pf400	<i>Pinus</i>	400	9	6	2
Pf400	<i>Pinus</i>	400	9	6	2
Pf400	<i>Pinus</i>	400	8	1	3
Pf400	<i>Pinus</i>	400	9	1	3
Pf400	<i>Pinus</i>	400	8	3	3
Pf400	<i>Pinus</i>	400	8	3	3
Pf400	<i>Pinus</i>	400	na	3	4
Pf400	<i>Pinus</i>	400	na	3	4
Pf400	<i>Pinus</i>	400	10	4	3
Pf400	<i>Pinus</i>	400	10	4	3
Pf400	<i>Pinus</i>	400	7	4	1
Pf400	<i>Pinus</i>	400	6	4	1
Pf400	<i>Pinus</i>	400	na	2	2
Pf400	<i>Pinus</i>	400	na	2	2
Pf400	<i>Pinus</i>	400	na	3	1
Pf400	<i>Pinus</i>	400	na	3	1
Pf400	<i>Pinus</i>	400	na	2	1
Pf400	<i>Pinus</i>	400	na	2	1
Pf400	<i>Pinus</i>	400	4	4	1
Pf400	<i>Pinus</i>	400	5	4	1
Pf400	<i>Pinus</i>	400	na	5	1
Pf400	<i>Pinus</i>	400	na	5	1
Pf400	<i>Pinus</i>	400	na	6	1
Pf400	<i>Pinus</i>	400	na	6	1
Pf400	<i>Pinus</i>	400	na	1	2
Pf400	<i>Pinus</i>	400	na	1	2
Pf400	<i>Pinus</i>	400	8	3	1
Pf400	<i>Pinus</i>	400	8	3	1
Pf400	<i>Pinus</i>	400	7	7	3
Pf400	<i>Pinus</i>	400	9	7	3
Pf400	<i>Pinus</i>	400	5	3	2
Pf400	<i>Pinus</i>	400	7	3	2
Pf400	<i>Pinus</i>	400	7	8	2
Pf400	<i>Pinus</i>	400	9	8	2
Pf400	<i>Pinus</i>	400	8	1	1
Pf400	<i>Pinus</i>	400	8	1	1
Pf400	<i>Pinus</i>	400	2	5	1

Pf400	<i>Pinus</i>	400	2	5	1
Pf400	<i>Pinus</i>	400	5	7	2
Pf400	<i>Pinus</i>	400	6	7	2
Pf400	<i>Pinus</i>	400	7	5	2
Pf400	<i>Pinus</i>	400	7	5	2
Pf400	<i>Pinus</i>	400	8	1	1
Pf400	<i>Pinus</i>	400	8	1	1
Pf400	<i>Pinus</i>	400	9	3	2
Pf400	<i>Pinus</i>	400	8	3	2
Pf400	<i>Pinus</i>	400	9	1	1
Pf400	<i>Pinus</i>	400	8	1	1
Pf400	<i>Pinus</i>	400	6	1	3
Pf400	<i>Pinus</i>	400	6	1	3
Pf400	<i>Pinus</i>	400	5	1	1
Pf400	<i>Pinus</i>	400	5	1	1
Pf400	<i>Pinus</i>	400	5	1	1
Pf400	<i>Pinus</i>	400	5	1	1
Pf400	<i>Pinus</i>	400	9	4	1
Pf400	<i>Pinus</i>	400	10	4	1
Pf400	<i>Pinus</i>	400	2	10	1
Pf400	<i>Pinus</i>	400	2	10	1
Pf400	<i>Pinus</i>	400	na	10	2
Pf400	<i>Pinus</i>	400	na	10	2
Pf400	<i>Pinus</i>	400	6	4	2
Pf400	<i>Pinus</i>	400	8	4	2
Pf400	<i>Pinus</i>	400	10	1	1
Pf400	<i>Pinus</i>	400	8	1	1
Pf400	<i>Pinus</i>	400	2	7	10
Pf400	<i>Pinus</i>	400	3	7	10
Pf400	<i>Pinus</i>	400	na	5	3
Pf400	<i>Pinus</i>	400	na	5	3
Pf400	<i>Pinus</i>	400	8	8	1
Pf400	<i>Pinus</i>	400	8	8	1
Pf400	<i>Pinus</i>	400	10	1	1
Pf400	<i>Pinus</i>	400	9	1	1
Pf400	<i>Pinus</i>	400	10	5	5
Pf400	<i>Pinus</i>	400	10	5	5
<hr/>					
Pf350	<i>Pinus</i>	350	1	7	3
Pf350	<i>Pinus</i>	350	1	7	3
Pf350	<i>Pinus</i>	350	9	1	0
Pf350	<i>Pinus</i>	350	8	1	0
Pf350	<i>Pinus</i>	350	na	6	1
Pf350	<i>Pinus</i>	350	na	6	1
Pf350	<i>Pinus</i>	350	9	2	2
Pf350	<i>Pinus</i>	350	8	2	2
Pf350	<i>Pinus</i>	350	7	2	3
Pf350	<i>Pinus</i>	350	8	2	3
Pf350	<i>Pinus</i>	350	2	4	1
Pf350	<i>Pinus</i>	350	2	4	1
Pf350	<i>Pinus</i>	350	3	3	6
Pf350	<i>Pinus</i>	350	2	3	6
Pf350	<i>Pinus</i>	350	na	3	1
Pf350	<i>Pinus</i>	350	na	3	1
Pf350	<i>Pinus</i>	350	10	3	3
Pf350	<i>Pinus</i>	350	10	3	3
Pf350	<i>Pinus</i>	350	10	1	3
Pf350	<i>Pinus</i>	350	10	1	3
Pf350	<i>Pinus</i>	350	3	10	2
Pf350	<i>Pinus</i>	350	4	10	2
Pf350	<i>Pinus</i>	350	2	7	1
Pf350	<i>Pinus</i>	350	2	7	1
Pf350	<i>Pinus</i>	350	4	7	1
Pf350	<i>Pinus</i>	350	5	7	1
Pf350	<i>Pinus</i>	350	2	1	2
Pf350	<i>Pinus</i>	350	4	1	2
Pf350	<i>Pinus</i>	350	5	2	1
Pf350	<i>Pinus</i>	350	4	2	1

Pf350	<i>Pinus</i>	350	2	4	1
Pf350	<i>Pinus</i>	350	2	4	1
Pf350	<i>Pinus</i>	350	4	3	1
Pf350	<i>Pinus</i>	350	4	3	1
Pf350	<i>Pinus</i>	350	10	5	1
Pf350	<i>Pinus</i>	350	10	5	1
Pf350	<i>Pinus</i>	350	5	8	6
Pf350	<i>Pinus</i>	350	7	8	6
Pf350	<i>Pinus</i>	350	10	3	1
Pf350	<i>Pinus</i>	350	10	3	1
Pf350	<i>Pinus</i>	350	9	1	2
Pf350	<i>Pinus</i>	350	9	1	2
Pf350	<i>Pinus</i>	350	na	2	1
Pf350	<i>Pinus</i>	350	na	2	1
Pf350	<i>Pinus</i>	350	na	2	1
Pf350	<i>Pinus</i>	350	na	2	1
Pf350	<i>Pinus</i>	350	4	4	3
Pf350	<i>Pinus</i>	350	5	4	3
Pf350	<i>Pinus</i>	350	2	3	1
Pf350	<i>Pinus</i>	350	1	3	1
Pf350	<i>Pinus</i>	350	na	5	5
Pf350	<i>Pinus</i>	350	na	5	5
Pf350	<i>Pinus</i>	350	10	1	1
Pf350	<i>Pinus</i>	350	10	1	1
Pf350	<i>Pinus</i>	350	10	3	1
Pf350	<i>Pinus</i>	350	10	3	1
Pf350	<i>Pinus</i>	350	na	9	1
Pf350	<i>Pinus</i>	350	na	9	1
Pf350	<i>Pinus</i>	350	9	1	1
Pf350	<i>Pinus</i>	350	8	1	1
Pf350	<i>Pinus</i>	350	6	1	1
Pf350	<i>Pinus</i>	350	6	1	1
Pf350	<i>Pinus</i>	350	na	1	1
Pf350	<i>Pinus</i>	350	na	1	1
Pf350	<i>Pinus</i>	350	4	6	8
Pf350	<i>Pinus</i>	350	3	6	8
Pf350	<i>Pinus</i>	350	8	1	1
Pf350	<i>Pinus</i>	350	7	1	1
Pf350	<i>Pinus</i>	350	2	2	1
Pf350	<i>Pinus</i>	350	2	2	1
Pf350	<i>Pinus</i>	350	8	1	4
Pf350	<i>Pinus</i>	350	9	1	4
Pf350	<i>Pinus</i>	350	4	2	2
Pf350	<i>Pinus</i>	350	4	2	2
Pf350	<i>Pinus</i>	350	8	6	4
Pf350	<i>Pinus</i>	350	7	6	4
Pf350	<i>Pinus</i>	350	na	2	5
Pf350	<i>Pinus</i>	350	na	2	5
Pf350	<i>Pinus</i>	350	na	2	1
Pf350	<i>Pinus</i>	350	na	2	1
Ef400	<i>Eucalyptus</i>	400	na	1	8
Ef400	<i>Eucalyptus</i>	400	na	1	8
Ef400	<i>Eucalyptus</i>	400	1	2	9
Ef400	<i>Eucalyptus</i>	400	1	2	9
Ef400	<i>Eucalyptus</i>	400	1	1	5
Ef400	<i>Eucalyptus</i>	400	1	1	5
Ef400	<i>Eucalyptus</i>	400	na	1	1
Ef400	<i>Eucalyptus</i>	400	na	1	1
Ef400	<i>Eucalyptus</i>	400	3	10	1
Ef400	<i>Eucalyptus</i>	400	4	10	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	8	1	1
Ef400	<i>Eucalyptus</i>	400	9	1	1
Ef400	<i>Eucalyptus</i>	400	4	1	1
Ef400	<i>Eucalyptus</i>	400	4	1	1
Ef400	<i>Eucalyptus</i>	400	1	3	1

Ef400	<i>Eucalyptus</i>	400	1	3	1
Ef400	<i>Eucalyptus</i>	400	1	10	1
Ef400	<i>Eucalyptus</i>	400	1	10	1
Ef400	<i>Eucalyptus</i>	400	6	5	1
Ef400	<i>Eucalyptus</i>	400	5	5	1
Ef400	<i>Eucalyptus</i>	400	5	2	1
Ef400	<i>Eucalyptus</i>	400	4	2	1
Ef400	<i>Eucalyptus</i>	400	10	1	1
Ef400	<i>Eucalyptus</i>	400	9	1	1
Ef400	<i>Eucalyptus</i>	400	6	4	1
Ef400	<i>Eucalyptus</i>	400	5	4	1
Ef400	<i>Eucalyptus</i>	400	2	2	2
Ef400	<i>Eucalyptus</i>	400	2	2	2
Ef400	<i>Eucalyptus</i>	400	10	6	1
Ef400	<i>Eucalyptus</i>	400	10	6	1
Ef400	<i>Eucalyptus</i>	400	4	3	2
Ef400	<i>Eucalyptus</i>	400	3	3	2
Ef400	<i>Eucalyptus</i>	400	8	2	1
Ef400	<i>Eucalyptus</i>	400	8	2	1
Ef400	<i>Eucalyptus</i>	400	1	2	1
Ef400	<i>Eucalyptus</i>	400	1	2	1
Ef400	<i>Eucalyptus</i>	400	4	1	1
Ef400	<i>Eucalyptus</i>	400	3	1	1
Ef400	<i>Eucalyptus</i>	400	1	2	1
Ef400	<i>Eucalyptus</i>	400	1	2	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	2	1	1
Ef400	<i>Eucalyptus</i>	400	2	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	4	1	1
Ef400	<i>Eucalyptus</i>	400	3	1	1
Ef400	<i>Eucalyptus</i>	400	5	2	2
Ef400	<i>Eucalyptus</i>	400	6	2	2
Ef400	<i>Eucalyptus</i>	400	2	3	1
Ef400	<i>Eucalyptus</i>	400	2	3	1
Ef400	<i>Eucalyptus</i>	400	7	4	3
Ef400	<i>Eucalyptus</i>	400	7	4	3
Ef400	<i>Eucalyptus</i>	400	1	1	1
Ef400	<i>Eucalyptus</i>	400	2	1	1
Ef400	<i>Eucalyptus</i>	400	2	2	2
Ef400	<i>Eucalyptus</i>	400	2	2	2
Ef400	<i>Eucalyptus</i>	400	5	2	1
Ef400	<i>Eucalyptus</i>	400	4	2	1
Ef400	<i>Eucalyptus</i>	400	2	1	1
Ef400	<i>Eucalyptus</i>	400	2	1	1
Ef400	<i>Eucalyptus</i>	400	1	2	1
Ef400	<i>Eucalyptus</i>	400	1	2	1
Ef350	<i>Eucalyptus</i>	350	2	2	1
Ef350	<i>Eucalyptus</i>	350	1	2	1
Ef350	<i>Eucalyptus</i>	350	2	2	1
Ef350	<i>Eucalyptus</i>	350	1	2	1

Ef350	<i>Eucalyptus</i>	350	na	2	2
Ef350	<i>Eucalyptus</i>	350	na	2	2
Ef350	<i>Eucalyptus</i>	350	1	3	1
Ef350	<i>Eucalyptus</i>	350	1	3	1
Ef350	<i>Eucalyptus</i>	350	3	2	1
Ef350	<i>Eucalyptus</i>	350	2	2	1
Ef350	<i>Eucalyptus</i>	350	2	3	1
Ef350	<i>Eucalyptus</i>	350	2	3	1
Ef350	<i>Eucalyptus</i>	350	2	1	1
Ef350	<i>Eucalyptus</i>	350	2	1	1
Ef350	<i>Eucalyptus</i>	350	2	1	1
Ef350	<i>Eucalyptus</i>	350	2	1	1
Ef350	<i>Eucalyptus</i>	350	6	3	1
Ef350	<i>Eucalyptus</i>	350	6	3	1
Ef350	<i>Eucalyptus</i>	350	2	2	1
Ef350	<i>Eucalyptus</i>	350	2	2	1
Ef350	<i>Eucalyptus</i>	350	6	2	1
Ef350	<i>Eucalyptus</i>	350	6	2	1
Ef350	<i>Eucalyptus</i>	350	6	1	1
Ef350	<i>Eucalyptus</i>	350	5	1	1
Ef350	<i>Eucalyptus</i>	350	3	1	2
Ef350	<i>Eucalyptus</i>	350	3	1	2
Ef350	<i>Eucalyptus</i>	350	5	1	1
Ef350	<i>Eucalyptus</i>	350	6	1	1
Ef350	<i>Eucalyptus</i>	350	2	2	2
Ef350	<i>Eucalyptus</i>	350	4	2	2
Ef350	<i>Eucalyptus</i>	350	6	4	1
Ef350	<i>Eucalyptus</i>	350	6	4	1
Ef350	<i>Eucalyptus</i>	350	4	1	1
Ef350	<i>Eucalyptus</i>	350	4	1	1
Ef350	<i>Eucalyptus</i>	350	10	1	1
Ef350	<i>Eucalyptus</i>	350	9	1	1
Ef350	<i>Eucalyptus</i>	350	6	1	2
Ef350	<i>Eucalyptus</i>	350	4	1	2
Ef350	<i>Eucalyptus</i>	350	8	2	1
Ef350	<i>Eucalyptus</i>	350	7	2	1
Ef350	<i>Eucalyptus</i>	350	4	1	6
Ef350	<i>Eucalyptus</i>	350	4	1	6
Ef350	<i>Eucalyptus</i>	350	9	1	1
Ef350	<i>Eucalyptus</i>	350	9	1	1
Ef350	<i>Eucalyptus</i>	350	4	2	1
Ef350	<i>Eucalyptus</i>	350	4	2	1
Ef350	<i>Eucalyptus</i>	350	8	2	1
Ef350	<i>Eucalyptus</i>	350	8	2	1
Ef350	<i>Eucalyptus</i>	350	10	2	1
Ef350	<i>Eucalyptus</i>	350	9	2	1
Ef350	<i>Eucalyptus</i>	350	8	3	2
Ef350	<i>Eucalyptus</i>	350	8	3	2
Ef350	<i>Eucalyptus</i>	350	7	1	1
Ef350	<i>Eucalyptus</i>	350	8	1	1
Ef350	<i>Eucalyptus</i>	350	6	1	1
Ef350	<i>Eucalyptus</i>	350	6	1	1
Ef350	<i>Eucalyptus</i>	350	8	1	1
Ef350	<i>Eucalyptus</i>	350	8	1	1
Ef350	<i>Eucalyptus</i>	350	7	10	1
Ef350	<i>Eucalyptus</i>	350	7	10	1
Ef350	<i>Eucalyptus</i>	350	1	1	1
Ef350	<i>Eucalyptus</i>	350	1	1	1
Ef350	<i>Eucalyptus</i>	350	7	1	1
Ef350	<i>Eucalyptus</i>	350	8	1	1
Ef350	<i>Eucalyptus</i>	350	4	1	1
Ef350	<i>Eucalyptus</i>	350	4	1	1
Ef350	<i>Eucalyptus</i>	350	5	3	1
Ef350	<i>Eucalyptus</i>	350	5	3	1
Ef350	<i>Eucalyptus</i>	350	7	1	1
Ef350	<i>Eucalyptus</i>	350	7	1	1
Ef350	<i>Eucalyptus</i>	350	2	4	1

Ef350	<i>Eucalyptus</i>	350	2	4	1
Ef350	<i>Eucalyptus</i>	350	4	1	1
Ef350	<i>Eucalyptus</i>	350	3	1	1
Ef350	<i>Eucalyptus</i>	350	5	1	1
Ef350	<i>Eucalyptus</i>	350	5	1	1
Ef350	<i>Eucalyptus</i>	350	4	1	1
Ef350	<i>Eucalyptus</i>	350	6	1	1
Ef350	<i>Eucalyptus</i>	350	7	1	1
Ef350	<i>Eucalyptus</i>	350	5	1	1

Anexo B – Artigo 2

Flexão estática

Tabela B-1. Dados de Flexão estática para compensados colados com adesivo ureia-formaldeído

Tratamento	Espécie	Gramatura	Perpendicular			Paralela		
			ME (g/cm ³)	MOR (MPa)	MOE (MPa)	ME (g/cm ³)	MOR (MPa)	MOE (MPa)
P400	<i>Pinus</i>	400	0,682	18,26	2077,39	0,670	86,60	9429,88
P400	<i>Pinus</i>	400	0,610	37,32	3299,47	0,674	75,92	8906,60
P400	<i>Pinus</i>	400	0,642	54,41	3743,61	0,671	80,95	11308,18
P400	<i>Pinus</i>	400	0,665	32,36	2644,48	0,650	73,74	6331,02
P400	<i>Pinus</i>	400	0,711	38,32	2918,66	0,646	63,17	7345,02
P400	<i>Pinus</i>	400	0,654	33,59	3045,92	0,639	75,76	9544,41
P400	<i>Pinus</i>	400	0,663	44,48	3658,92	0,623	74,81	11162,96
P400	<i>Pinus</i>	400	0,620	32,54	2265,88	0,625	71,60	6701,57
P350	<i>Pinus</i>	350	0,664	37,91	3137,67	0,667	72,74	9056,84
P350	<i>Pinus</i>	350	0,667	46,44	3243,96	0,647	64,18	8939,42
P350	<i>Pinus</i>	350	0,626	36,53	2828,07	0,699	103,24	12119,76
P350	<i>Pinus</i>	350	0,694	50,30	3721,60	0,665	86,04	10790,30
P350	<i>Pinus</i>	350	0,645	35,04	2671,72	0,645	68,66	7060,46
P350	<i>Pinus</i>	350	0,687	40,30	3184,61	0,622	72,56	9254,58
P350	<i>Pinus</i>	350	0,662	32,01	1802,71	0,669	83,61	11874,70
P350	<i>Pinus</i>	350	0,644	39,14	2594,36	0,704	88,52	9650,76
E400	<i>Eucalyptus</i>	400	0,644	36,38	3574,01	0,652	81,01	11668,00
E400	<i>Eucalyptus</i>	400	0,657	34,59	2868,46	0,682	89,88	13002,26
E400	<i>Eucalyptus</i>	400	0,730	49,73	3766,62	0,724	93,72	11465,34
E400	<i>Eucalyptus</i>	400	0,720	48,40	3518,70	0,749	102,58	12665,70
E400	<i>Eucalyptus</i>	400	0,730	45,33	3740,10	0,688	92,34	12226,51
E400	<i>Eucalyptus</i>	400	0,700	43,36	3757,58	0,703	92,71	13474,95
E400	<i>Eucalyptus</i>	400	0,711	44,35	3359,48	0,694	91,32	10964,74
E400	<i>Eucalyptus</i>	400	0,723	44,26	3429,54	0,708	90,07	11557,95
E350	<i>Eucalyptus</i>	350	0,712	39,84	3561,21	0,697	94,84	11855,39
E350	<i>Eucalyptus</i>	350	0,729	44,92	3511,99	0,722	107,95	12509,07
E350	<i>Eucalyptus</i>	350	0,742	43,71	3477,26	0,712	85,28	11562,15
E350	<i>Eucalyptus</i>	350	0,726	41,12	3380,58	0,711	91,92	11501,68
E350	<i>Eucalyptus</i>	350	0,705	42,56	3650,31	0,666	86,55	11760,63
E350	<i>Eucalyptus</i>	350	0,693	42,37	3291,07	0,696	89,61	11945,86
E350	<i>Eucalyptus</i>	350	0,700	40,58	3435,03	0,659	84,25	11140,03
E350	<i>Eucalyptus</i>	350	0,696	42,17	3100,19	0,678	76,02	10287,99

Tabela B-2. Teste de Levene para verificar a homogeneidade de variâncias.

Direção	Propriedade	F	df1	df2	Sig.
Perpendicular	MOR (MPa)	1,034	3	28	0,393 ns
	MOE (MPa)	3,292	3	28	0,035 *
	ME (g/cm ³)	0,975	3	28	0,418 ns
Paralela	MOR (MPa)	2,391	3	28	0,090 ns
	MOE (MPa)	3,845	3	28	0,020 *
	ME (g/cm ³)	0,155	3	28	0,926 ns

* = Variâncias não homogêneas pelo teste de Levene a 5% de probabilidade; ns = Variâncias homogêneas pelo teste de Levene a 5% de probabilidade

Tabela B-3. Testes de normalidade para flexão estática de compensados uréicos

Tratamento		Kolmogorov-Smirnov			Shapiro-Wilk			
		Statistic	df	Sig.	Statistic	df	Sig.	
Perpendicular	MOR (MPa)	P400	0,224	8	0,200 ns	0,951	8	0,724 ns
		P350	0,211	8	0,200 ns	0,939	8	0,604 ns
		E400	0,254	8	0,136 ns	0,898	8	0,279 ns
		E350	0,154	8	0,200 ns	0,976	8	0,941 ns
	MOE (MPa)	P400	0,128	8	0,200 ns	0,952	8	0,736 ns
		P350	0,174	8	0,200 ns	0,948	8	0,695 ns
		E400	0,225	8	0,200 ns	0,836	8	0,068 ns
		E350	0,155	8	0,200 ns	0,952	8	0,735 ns
	ME (g/cm ³)	P400	0,172	8	0,200 ns	0,927	8	0,485 ns
		P350	0,233	8	0,200 ns	0,813	8	0,039 *
		E400	0,148	8	0,200 ns	0,963	8	0,834 ns
		E350	0,140	8	0,200 ns	0,977	8	0,944 ns
Paralela	MOR (MPa)	P400	0,215	8	0,200 ns	0,954	8	0,748 ns
		P350	0,213	8	0,200 ns	0,941	8	0,624 ns
		E400	0,253	8	0,139 ns	0,895	8	0,260 ns
		E350	0,161	8	0,200 ns	0,944	8	0,649 ns
	MOE (MPa)	P400	0,161	8	0,200 ns	0,920	8	0,429 ns
		P350	0,174	8	0,200 ns	0,941	8	0,621 ns
		E400	0,209	8	0,200 ns	0,954	8	0,756 ns
		E350	0,214	8	0,200 ns	0,937	8	0,585 ns
	ME (g/cm ³)	P400	0,184	8	0,200 ns	0,935	8	0,565 ns
		P350	0,142	8	0,200 ns	0,986	8	0,985 ns
		E400	0,188	8	0,200 ns	0,948	8	0,686 ns
		E350	0,215	8	0,200 ns	0,897	8	0,270 ns

* = Rejeita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade; ns = Aceita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade.

Tabela B-4. Análise de variância para ME (g/cm³) na direção perpendicular

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	,020 ^a	3	0,007	8,786	0,000 *
Intercept	14,919	1	14,919	20145,433	0,000
Gramatura	0,001	1	0,001	0,753	0,393 ns
Espécie	0,019	1	0,019	25,480	0,000 *
Gramatura * Espécie	9,247E-05	1	9,247E-05	0,125	0,726 ns
Error	0,021	28	0,001		
Total	14,959	32			
Corrected Total	0,040	31			

a. R Squared = ,485 (Adjusted R Squared = ,430); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B-5. Desdobramento do fator Espécie para ME (g/cm³) na direção perpendicular

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	0,049*	0,010	0,000 *	0,029	0,068
<i>Pinus</i> <i>Eucalyptus</i>	-0,049*	0,010	0,000 *	-0,068	-0,029

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela B- 6. Análise de variância para ME (g/cm³) na direção paralela

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	0,013 ^a	3	0,004	7,048	0,001 *
Intercept	14,656	1	14,656	23139,234	0,000
Gramatura	0,000	1	0,000	,181	0,674 ns
Espécie	0,012	1	0,012	19,407	0,000 *
Gramatura * Espécie	0,001	1	0,001	1,556	0,223 ns
Error	0,018	28	0,001		
Total	14,687	32			
Corrected Total	0,031	31			

a. R Squared = ,430 (Adjusted R Squared = ,369); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade.

Tabela B- 7. Desdobramento do fator Espécie para ME (g/cm³) na direção paralela

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	0,039 [*]	0,009	0,000 *	0,021	0,057
<i>Pinus</i> <i>Eucalyptus</i>	-0,039 [*]	0,009	0,000 *	-0,057	-0,021

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak

Tabela B-8. Análise de variância para MOR no ensaio de flexão estática na direção perpendicular

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	223,149 ^a	3	74,383	1,692	0,191 ns
Intercept	52214,230	1	52214,230	1187,706	0,000
Espécie	174,410	1	174,410	3,967	0,056 ns
Gramatura	9,333	1	9,333	0,212	0,649 ns
Espécie * Gramatura	39,406	1	39,406	0,896	0,352 ns
Error	1230,943	28	43,962		
Total	53668,322	32			
Corrected Total	1454,092	31			

a. R Squared = ,153 (Adjusted R Squared = ,063); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B-9. Análise de variância para MOE no ensaio de flexão estática na direção perpendicular

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	2338992,014 ^a	3	779664,005	3,828	0,020 *
Intercept	326792102,449	1	326792102,449	1604,659	0,000
Espécie	2302189,606	1	2302189,606	11,305	0,002 *
Gramatura	36213,763	1	36213,763	0,178	0,676 ns
Espécie * Gramatura	588,646	1	588,646	0,003	0,958 ns
Error	5702259,038	28	203652,109		
Total	334833353,501	32			
Corrected Total	8041251,052	31			

a. R Squared = ,291 (Adjusted R Squared = ,215); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B-10. Desdobramento para o fator Espécie para MOR na direção perpendicular

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	536,445 [*]	159,551	0,002 *	209,620	863,271
<i>Pinus</i> <i>Eucalyptus</i>	-536,445 [*]	159,551	0,002 *	-863,271	-209,620

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela B-11. Análise de variância para MOR no ensaio de flexão estática na direção paralela

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	1455,429 ^a	3	485,143	5,837	0,003 *
Intercept	226491,353	1	226491,353	2724,881	0,000
Espécie	1351,379	1	1351,379	16,258	0,000 *
Gramatura	12,235	1	12,235	0,147	0,704 ns
Espécie * Gramatura	91,815	1	91,815	1,105	0,302 ns
Error	2327,352	28	83,120		
Total	230274,134	32			
Corrected Total	3782,781	31			

a. R Squared = ,385 (Adjusted R Squared = ,319); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B-12. Desdobramento para o fator Espécie para MOR na direção paralela

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	12,997 [*]	3,223	0,000 *	6,394	19,600
<i>Pinus</i> <i>Eucalyptus</i>	-12,997 [*]	3,223	0,000 *	-19,600	-6,394

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela B-13. Análise de variância para MOE no ensaio de flexão estática na direção paralela.

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	55541687,640 ^a	3	18513895,880	9,710	0,000 *
Intercept	3592652409,147	1	3592652409,147	1884,182	0,000
Espécie	50279805,113	1	50279805,113	26,369	0,000 *
Gramatura	394827,840	1	394827,840	0,207	0,653 ns
Espécie * Gramatura	4867054,687	1	4867054,687	2,553	0,121 ns
Error	53388830,178	28	1906743,935		
Total	3701582926,964	32			
Corrected Total	108930517,817	31			

a. R Squared = ,510 (Adjusted R Squared = ,457); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B-14. Desdobramento para o fator Espécie para MOE na direção paralela

(I) Espécie	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval for Difference	
				Lower Bound	Upper Bound
<i>Eucalyptus</i> <i>Pinus</i>	2506,985 [*]	488,204	0,000 *	1506,945	3507,026
<i>Pinus</i> <i>Eucalyptus</i>	-2506,985 [*]	488,204	0,000 *	-3507,026	-1506,945

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Cisalhamento na linha de cola

Tensão de Ruptura

Tabela B-15. Tensão de ruptura (Tmax) e do percentual de falha na madeira (WF%) pelo ensaio de cisalhamento na linha de cola em diferentes condições de ensaio

Tratamento	Espécie	Gramatura	Tmax Seco	WF seco	Tmax Água fria	WF Água fria
P400	<i>Pinus</i>	400	2,55	18	2,24	60
P400	<i>Pinus</i>	400	2,67	62	2,28	84
P400	<i>Pinus</i>	400	3,10	80	1,65	56
P400	<i>Pinus</i>	400	2,93	72	3,16	42
P400	<i>Pinus</i>	400	2,28	70	2,86	54
P400	<i>Pinus</i>	400	2,11	6	1,76	14
P400	<i>Pinus</i>	400	2,48	26	2,27	4
P400	<i>Pinus</i>	400	2,36	0	2,09	8
P400	<i>Pinus</i>	400	2,76	na	2,82	88
P400	<i>Pinus</i>	400	2,70	50	1,90	62
P400	<i>Pinus</i>	400	1,77	na	2,18	50
P400	<i>Pinus</i>	400	1,97	20	1,97	36
P400	<i>Pinus</i>	400	1,79	na	2,12	82
P400	<i>Pinus</i>	400	2,16	84	1,85	na
P400	<i>Pinus</i>	400	2,38	74	1,40	76
P400	<i>Pinus</i>	400	2,52	24	1,71	66
P400	<i>Pinus</i>	400	2,12	50	2,42	36
P400	<i>Pinus</i>	400	2,17	88	2,14	100
P400	<i>Pinus</i>	400	2,97	100	1,37	46
P400	<i>Pinus</i>	400	2,50	82	1,97	74
P400	<i>Pinus</i>	400	1,93	2	2,05	36
P400	<i>Pinus</i>	400	1,61	0	2,22	96
P400	<i>Pinus</i>	400	2,45	2	1,48	0
P400	<i>Pinus</i>	400	1,54	na	2,07	20
P400	<i>Pinus</i>	400	2,36	8	1,70	10
P400	<i>Pinus</i>	400	1,99	na	2,24	na
P400	<i>Pinus</i>	400	2,50	20	1,78	14
P400	<i>Pinus</i>	400	2,44	28	2,09	48
P400	<i>Pinus</i>	400	2,52	100	1,92	74
P400	<i>Pinus</i>	400	2,22	100	2,18	28
P400	<i>Pinus</i>	400	2,17	na	2,21	44
P400	<i>Pinus</i>	400	2,49	14	2,18	90
P400	<i>Pinus</i>	400	2,04	na	1,69	20
P400	<i>Pinus</i>	400	2,73	98	2,57	66
P400	<i>Pinus</i>	400	2,18	na	1,86	12
P400	<i>Pinus</i>	400	2,12	na	2,38	100
P400	<i>Pinus</i>	400	1,60	16	1,92	52
P400	<i>Pinus</i>	400	2,57	na	2,39	88
P400	<i>Pinus</i>	400	1,99	na	1,87	40
P400	<i>Pinus</i>	400	2,14	64	2,96	60
P350	<i>Pinus</i>	350	1,90	0	1,25	0
P350	<i>Pinus</i>	350	2,14	18	1,58	0
P350	<i>Pinus</i>	350	2,37	4	1,00	0
P350	<i>Pinus</i>	350	1,92	12	0,99	0
P350	<i>Pinus</i>	350	1,76	2	1,15	0
P350	<i>Pinus</i>	350	2,03	0	1,10	0
P350	<i>Pinus</i>	350	2,02	0	1,07	0
P350	<i>Pinus</i>	350	2,41	0	0,07	0
P350	<i>Pinus</i>	350	1,91	0	1,23	0
P350	<i>Pinus</i>	350	2,03	74	1,04	0
P350	<i>Pinus</i>	350	2,60	16	1,82	6
P350	<i>Pinus</i>	350	2,33	40	1,47	12
P350	<i>Pinus</i>	350	2,16	0	1,43	4
P350	<i>Pinus</i>	350	2,28	10	1,88	2
P350	<i>Pinus</i>	350	2,70	34	1,70	4
P350	<i>Pinus</i>	350	2,35	0	1,51	10
P350	<i>Pinus</i>	350	2,61	30	1,69	0
P350	<i>Pinus</i>	350	2,03	48	1,79	12

P350	<i>Pinus</i>	350	2,47	46	1,30	0
P350	<i>Pinus</i>	350	2,81	52	1,18	0
P350	<i>Pinus</i>	350	2,27	6	2,39	34
P350	<i>Pinus</i>	350	2,31	40	2,58	24
P350	<i>Pinus</i>	350	2,58	10	1,65	0
P350	<i>Pinus</i>	350	2,81	2	1,31	0
P350	<i>Pinus</i>	350	1,97	0	1,35	0
P350	<i>Pinus</i>	350	3,01	26	1,42	0
P350	<i>Pinus</i>	350	2,16	80	1,44	0
P350	<i>Pinus</i>	350	2,28	6	2,07	10
P350	<i>Pinus</i>	350	2,15	2	2,52	0
P350	<i>Pinus</i>	350	2,71	16	1,53	12
P350	<i>Pinus</i>	350	2,67	0	1,14	0
P350	<i>Pinus</i>	350	1,96	62	1,08	0
P350	<i>Pinus</i>	350	2,38	8	0,95	0
P350	<i>Pinus</i>	350	2,77	74	1,45	0
P350	<i>Pinus</i>	350	2,27	22	1,45	4
P350	<i>Pinus</i>	350	2,23	0	1,68	0
P350	<i>Pinus</i>	350	2,22	4	1,14	0
P350	<i>Pinus</i>	350	2,65	4	1,26	12
P350	<i>Pinus</i>	350	2,26	58	1,65	20
P350	<i>Pinus</i>	350	2,25	70	1,40	0
E400	<i>Eucalyptus</i>	400	2,79	82	1,79	100
E400	<i>Eucalyptus</i>	400	2,11	72	2,03	100
E400	<i>Eucalyptus</i>	400	2,15	100	1,77	100
E400	<i>Eucalyptus</i>	400	2,20	88	2,07	90
E400	<i>Eucalyptus</i>	400	2,25	42	1,40	na
E400	<i>Eucalyptus</i>	400	2,06	90	2,88	92
E400	<i>Eucalyptus</i>	400	2,50	28	1,94	76
E400	<i>Eucalyptus</i>	400	2,34	na	2,31	100
E400	<i>Eucalyptus</i>	400	1,94	100	2,53	94
E400	<i>Eucalyptus</i>	400	1,93	70	2,19	100
E400	<i>Eucalyptus</i>	400	2,23	72	3,09	100
E400	<i>Eucalyptus</i>	400	2,35	100	3,25	100
E400	<i>Eucalyptus</i>	400	2,67	100	3,97	100
E400	<i>Eucalyptus</i>	400	2,48	100	2,00	92
E400	<i>Eucalyptus</i>	400	2,54	100	2,21	100
E400	<i>Eucalyptus</i>	400	2,73	100	3,35	100
E400	<i>Eucalyptus</i>	400	1,98	100	2,06	100
E400	<i>Eucalyptus</i>	400	2,64	100	2,74	100
E400	<i>Eucalyptus</i>	400	2,33	60	2,16	100
E400	<i>Eucalyptus</i>	400	2,32	100	3,07	100
E400	<i>Eucalyptus</i>	400	3,42	100	2,55	62
E400	<i>Eucalyptus</i>	400	2,05	66	2,25	100
E400	<i>Eucalyptus</i>	400	2,12	70	3,04	94
E400	<i>Eucalyptus</i>	400	2,52	58	2,97	100
E400	<i>Eucalyptus</i>	400	2,33	100	2,12	100
E400	<i>Eucalyptus</i>	400	2,00	400	2,94	98
E400	<i>Eucalyptus</i>	400	2,25	100	1,89	100
E400	<i>Eucalyptus</i>	400	2,17	38	3,78	100
E400	<i>Eucalyptus</i>	400	2,63	96	3,68	100
E400	<i>Eucalyptus</i>	400	2,43	100	2,60	100
E400	<i>Eucalyptus</i>	400	2,30	100	1,50	62
E400	<i>Eucalyptus</i>	400	2,23	38	1,82	80
E400	<i>Eucalyptus</i>	400	1,53	72	2,97	100
E400	<i>Eucalyptus</i>	400	2,58	66	1,86	100
E400	<i>Eucalyptus</i>	400	2,64	50	2,10	100
E400	<i>Eucalyptus</i>	400	2,25	32	2,00	100
E400	<i>Eucalyptus</i>	400	1,93	80	2,90	98
E400	<i>Eucalyptus</i>	400	1,96	100	2,89	94
E400	<i>Eucalyptus</i>	400	2,47	14	2,11	84
E400	<i>Eucalyptus</i>	400	1,40	52	2,52	74
E350	<i>Eucalyptus</i>	350	2,64	58	1,98	102
E350	<i>Eucalyptus</i>	350	2,39	100	2,26	74
E350	<i>Eucalyptus</i>	350	2,30	92	3,21	100
E350	<i>Eucalyptus</i>	350	1,98	100	2,22	100
E350	<i>Eucalyptus</i>	350	2,25	100	2,36	76

E350	<i>Eucalyptus</i>	350	2,19	100	1,89	100
E350	<i>Eucalyptus</i>	350	2,50	64	2,61	80
E350	<i>Eucalyptus</i>	350	1,97	100	1,78	100
E350	<i>Eucalyptus</i>	350	2,15	100	2,42	100
E350	<i>Eucalyptus</i>	350	2,49	100	3,21	100
E350	<i>Eucalyptus</i>	350	2,36	42	2,85	96
E350	<i>Eucalyptus</i>	350	2,66	100	2,35	100
E350	<i>Eucalyptus</i>	350	2,45	76	2,62	100
E350	<i>Eucalyptus</i>	350	2,42	100	3,05	80
E350	<i>Eucalyptus</i>	350	2,33	42	2,84	100
E350	<i>Eucalyptus</i>	350	2,65	74	3,15	98
E350	<i>Eucalyptus</i>	350	2,21	70	2,80	92
E350	<i>Eucalyptus</i>	350	2,56	68	3,34	98
E350	<i>Eucalyptus</i>	350	2,81	100	2,81	100
E350	<i>Eucalyptus</i>	350	2,55	100	3,11	100
E350	<i>Eucalyptus</i>	350	2,01	80	2,23	90
E350	<i>Eucalyptus</i>	350	2,87	66	2,63	100
E350	<i>Eucalyptus</i>	350	2,08	62	2,18	100
E350	<i>Eucalyptus</i>	350	2,09	100	2,47	100
E350	<i>Eucalyptus</i>	350	2,36	100	3,58	100
E350	<i>Eucalyptus</i>	350	2,19	80	2,31	100
E350	<i>Eucalyptus</i>	350	2,18	100	1,92	86
E350	<i>Eucalyptus</i>	350	1,76	70	3,32	100
E350	<i>Eucalyptus</i>	350	2,15	94	2,38	82
E350	<i>Eucalyptus</i>	350	2,71	100	1,58	80
E350	<i>Eucalyptus</i>	350	1,62	100	2,70	100
E350	<i>Eucalyptus</i>	350	2,41	20	2,20	100
E350	<i>Eucalyptus</i>	350	1,57	na	1,88	90
E350	<i>Eucalyptus</i>	350	2,35	na	3,18	100
E350	<i>Eucalyptus</i>	350	1,66	78	3,34	na
E350	<i>Eucalyptus</i>	350	1,42	na	2,67	na
E350	<i>Eucalyptus</i>	350	2,17	98	1,76	100
E350	<i>Eucalyptus</i>	350	1,92	100	2,88	na
E350	<i>Eucalyptus</i>	350	1,88	100	1,95	92
E350	<i>Eucalyptus</i>	350	2,26	72	2,47	na

Tabela B-16. Teste de Levene para verificar a homogeneidade de variâncias de Tmax para as condições de ensaio Seco (D) e Água Fria (CW)

Condição	F	df1	df2	Sig.
Seco – D	0,612	3	156	0,608 ns
Água Fria – CW	5,110	3	156	0,002 *

* = Variâncias não homogêneas pelo teste de Levene a 5% de probabilidade; ns = Variâncias homogêneas pelo teste de Levene a 5% de probabilidade

Tabela B- 17. Testes de normalidade para Tmax (MPa) de compensados uréicos em duas condições

Tratamento	Kolmogorov-Smirnov				Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
Tensão (MPa) Seco	1,00	0,079	40	0,200 ns	0,984	40	0,830 ns
	2,00	0,096	40	0,200 ns	0,971	40	0,374 ns
	3,00	0,101	40	0,200 ns	0,956	40	0,124 ns
	4,00	0,093	40	0,200 ns	0,979	40	0,647 ns
Tensão (MPa) Água Fria	1,00	0,128	40	0,095 ns	0,959	40	0,160 ns
	2,00	0,114	40	0,200 ns	0,929	40	0,015 ns
	3,00	0,144	40	0,036 *	0,954	40	0,104 ns
	4,00	0,082	40	0,200 ns	0,972	40	0,428 ns

* = Rejeita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade; ns = Aceita a hipótese de distribuição normal dos dados ao nível de 5% de probabilidade.

Tabela B- 18. Análise de variância para Tmax (MPa) no ensaio de cisalhamento na linha de cola na condição Seco

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	0,142 ^a	3	0,047	0,402	0,751 ns
Intercept	836,722	1	836,722	7137,575	0,000
Espécie	0,070	1	0,070	0,598	0,440 ns
Gramatura	0,012	1	0,012	0,100	0,752 ns
Espécie * Gramatura	0,060	1	0,060	0,509	0,477 ns
Error	18,288	156	0,117		
Total	855,151	160			
Corrected Total	18,429	159			

a. R Squared = ,008 (Adjusted R Squared = -,011); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B- 19. Análise de variância para Tmax (MPa) no ensaio de cisalhamento na linha de cola na condição Água Fria

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	31,334 ^a	3	10,445	40,665	0,000 *
Intercept	737,108	1	737,108	2869,779	0,000
Espécie	22,620	1	22,620	88,067	0,000 *
Gramatura	3,312	1	3,312	12,895	0,000 *
Espécie * Gramatura	5,402	1	5,402	21,033	0,000 *
Error	40,069	156	0,257		
Total	808,511	160			
Corrected Total	71,403	159			

a. R Squared = ,439 (Adjusted R Squared = ,428); * = Diferença estatística é significativa ao nível de 5% de probabilidade; ns = Diferença estatística não-significativa ao nível de 5% de probabilidade

Tabela B-20. Desdobramento para a interação dos fatores Espécie * Gramatura para Tmax (MPa) na condição Água Fria - CW

Espécie			Mean Difference	Std.	Sig.	95% Confidence Interval for Difference	
	(I)	(J)	(I-J)	Error		Lower Bound	Upper Bound
<i>Eucalyptus</i>	350	400	0,080	0,113	0,483 ns	-0,144	0,304
	400	350	-0,080	0,113	0,483 ns	-0,304	0,144
<i>Pinus</i>	350	400	-0,655 [*]	0,113	0,000 *	-0,879	-0,431
	400	350	0,655 [*]	0,113	0,000 *	0,431	0,879

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Tabela B-21. Desdobramento para a interação dos fatores Gramatura * Espécie para Tmax (MPa) na condição Água Fria - CW

Gramatura (g/m ²)			Mean Difference	Std.	Sig.	95% Confidence Interval for Difference	
	(I)	(J)	(I-J)	Error		Lower Bound	Upper Bound
350	<i>Eucalyptus</i>	<i>Pinus</i>	1,120 [*]	0,113	0,000 *	0,896	1,343
	<i>Pinus</i>	<i>Eucalyptus</i>	-1,120 [*]	0,113	0,000 *	-1,343	-0,896
400	<i>Eucalyptus</i>	<i>Pinus</i>	0,385 [*]	0,113	0,001 *	0,161	0,608
	<i>Pinus</i>	<i>Eucalyptus</i>	-0,385 [*]	0,113	0,001 *	-0,608	-0,161

* = Diferença significativa ao nível de 5% pelo teste de Sidak; ns = Diferença estatística não-significativa ao nível de 5% pelo teste de Sidak.

Anexo C – artigo 3

O banco de imagens utilizado para a criação das redes neurais convolucionais (CNN) apresentadas no Artigo 3 – “Deep learning for plywood bonding quality classification”, podem ser acessadas pelo link:

<https://drive.google.com/drive/folders/1rr1NP3DRQRZnRo7yEEfHo78sq4wwlMDY?usp=sharing>

A tabela de identificação das amostras e seus respectivos valores de percentual de falha coesiva aparente da madeira (WF%) utilizados para a produção das redes neurais convolucionais do Artigo 3 – “Deep learning for plywood bonding quality classification”, estão disponíveis no link:

https://drive.google.com/file/d/1WM91fkxXWnMf3t7mry-LNaK6_gxCrDDI/view?usp=sharing

Os Scripts utilizados para a criação e avaliação das redes neurais convolucionais (CNNs) avaliadas no Artigo 3 – “Deep learning for plywood bonding quality classification”, são apresentados abaixo:

Project Laminados

Resp: Anderson / Jaymison

Aquisition

date : 31/Jul/2020

In [1]:

```
1 #Imports
2 import numpy as np
3 import matplotlib.pyplot as plt
4 from PIL import Image
5 import os
6 import glob
7 import pickle
8 import pandas as pd
```

In [2]:

```
1 # Keras Library
2 from keras.models import load_model
3 from keras import layers
4 from keras.layers import Concatenate, Input, Dense, Activation, ZeroPadding2D, BatchNo
5 from keras.layers import AveragePooling2D, MaxPooling2D, Dropout, GlobalMaxPooling2D,
6 from keras.models import Model, Sequential
7 from keras.preprocessing import image
```

c:\users\carlos\appdata\local\programs\python\python36\lib\site-packages\h5py__init__.py:36: FutureWarning: Conversion of the second argument of issubdtype from `float` to `np.floating` is deprecated. In future, it will be treated as `np.float64 == np.dtype(float).type`.

from ._conv import register_converters as _register_converters
Using TensorFlow backend.

In [3]:

```
1 ### Endereço do diretório das imagens
2 path = "D:/laminado/image/"
3 path0 = "D:/laminado/"
```

24/09/2020

Laminado

In [5]:

```

1 def corner(im,channel):
2     im0 = np.array(im)
3     rx,ry,yc,xc,edge = 100,100,100,100,30
4     my,mx,Max = 0,0,0
5     minY,minX = 0,0
6
7     for i in range(edge,rx):
8         mx = (im0[yc,i,channel]-im0[yc,i+1,channel])**2
9         if mx >= Max:
10            Max = mx
11            minX = i
12
13            my,mx,Max = 0,0,0
14            for i in range(edge,ry):
15                my = (im0[i,xc,channel]-im0[i+1,xc,channel])**2
16                if my > Max:
17                    Max = my
18                    minY = i
19            return minX,minY

```

In []:

```

1 # dimx = 325
2 # dimy = 185
3 # dx = 210
4 # dy = 100
5 # os.chdir(path)
6 # files=glob.glob("*.jpg")
7 # size = len(files)
8 # Xt = np.zeros((size,dy,dx,3))
9 # for i in range(0,size):
10 #     im = Image.open(files[i])
11 #     im = im.resize((dimx,dimy))
12 #     minX,minY = corner(im,0)
13 #     im = im.crop((minX-20,minY,minX-20+dx,minY+dy)) #Left, top, right, bottom
14 #     Xt[i] = np.array(im)/256
15 #     if (i%50)==False:
16 #         print(i)

```

Dataset

	File	lenth	image	ID	size GB	classes	Obs
	train0	2150	xtr	files	1.1	6	cropped
	train1	2150	xtr	files	1.1	6	cropped
	train	4306	xtr	files	1.1	6	cropped

Out[6]:

	wood	glue	ID	T	WF	class
0	1	1	1101a	2.318890	0	0
1	1	1	1101b	2.318890	0	0
2	1	1	1102a	2.878999	80	4
3	1	1	1102b	2.878999	80	4
4	1	1	1103a	2.990556	64	3

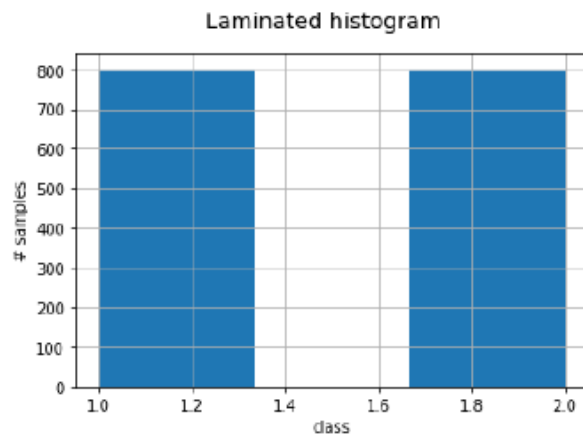
Histogramas

In [14]:

```
1 wood.hist(bins=3)
2 plt.suptitle('Laminated histogram', x=0.5, y=1.05, ha='center', fontsize='x-large')
3 plt.xlabel('class')
4 plt.ylabel('# samples')
```

Out[14]:

Text(0, 0.5, '# samples')

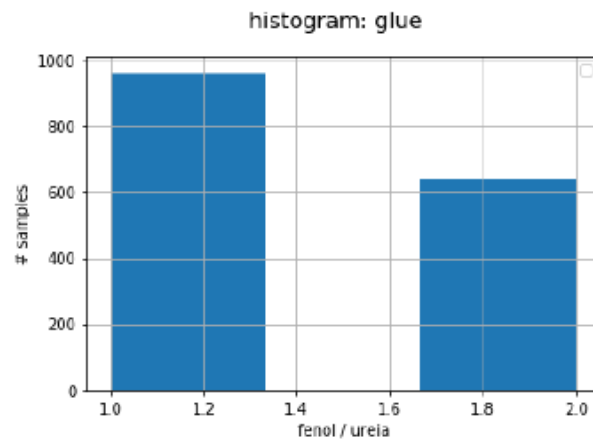


In [15]:

```
1 glue.hist(bins = 3)
2 plt.suptitle('histogram: glue', x=0.5, y=1.05, ha='center', fontsize='x-large')
3 plt.legend()
4 plt.xlabel('fenol / ureia')
5 plt.ylabel('# samples')
```

Out[15]:

Text(0, 0.5, '# samples')



In [16]:

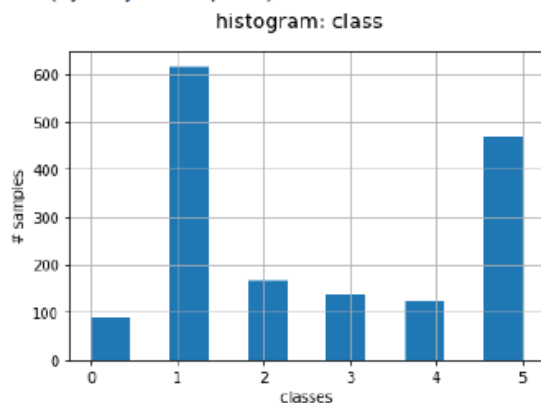
```

1 Class.hist(bins = 11)
2 plt.suptitle('histogram: class', x=0.5, y=1.05, ha='center', fontsize='x-large')
3 plt.xlabel(" classes ")
4 plt.ylabel('# samples')

```

Out[16]:

Text(0, 0.5, '# samples')



Model

In [12]:

```

1 n1 = len(ID)
2 n2 = len(Xt)
3 Ytt = np.zeros(n2)
4 tp = np.zeros((n2,2))
5 for i in range(n1):
6     for j in range(n2):
7         if ID[i] == files[j][0:5]:
8             Ytt[j] = Class[i]
9             tp[j,0] = wood[i]
10            tp[j,1] = glue[i]

```

In [16]:

```

1 j = 0
2 Xt4 = np.zeros((1519,100,210,3))
3 Yt4 = np.zeros((1519,6))
4 for i in range(n2):
5     if tp[i,1] == 2:
6         Yt4[j] = Yt[i]
7         Xt4[j] = Xt[i]
8         j +=1

```

In [14]:

```

1 def dotArray(Y):
2     num = len(Y)
3     Numclass = int(np.max(Y))
4     Ydot = np.zeros((num,Numclass+1))
5     for i in range(num):
6         for j in range(Numclass+1):
7             if Y[i] == j: Ydot[i,j]= 1
8
9     return Ydot

```

In [15]:

```

1 Yt = dotArray(Ytt)

```

Transfer learning

In [17]:

```

1 # Load model
2 ModelLamT = load_model(path0 + "ModelLam0.h5")

```


In [27]:

```

1  def KerasModel(input_shape):
2      NumClass = 6
3      X_input = Input(input_shape)
4
5      # Zero-Padding: pads the border of X_input with zeroes
6      X = ZeroPadding2D((3, 3))(X_input)
7
8      # CONV -> BN -> RELU Block applied to X
9      X = Conv2D(40, (3, 3), strides = (1, 1), name = 'conv0')(X)
10     X = BatchNormalization(axis = 3, name = 'bn0')(X)
11     X = Activation('relu')(X)
12
13     # MAXPOOL
14     X = MaxPooling2D((2, 2), name='max_pool')(X)
15
16     ##
17     X = Conv2D(24, (3, 3), strides = (1, 1), name = 'conv1')(X)
18     X = BatchNormalization(axis = 3, name = 'bn1')(X)
19     X = Activation('relu')(X)
20     X = MaxPooling2D((2, 2), name='max_pool1')(X)
21     ##
22
23     ##
24     X = Conv2D(16, (3, 3), strides = (1, 1), name = 'conv2')(X)
25     X = BatchNormalization(axis = 3, name = 'bn2')(X)
26     X = Activation('relu')(X)
27     X = MaxPooling2D((2, 2), name='max_pool2')(X)
28     ##
29
30     ## New Layer
31     X = Conv2D(8, (3, 3), strides = (1, 1), name = 'conv3')(X)
32     X = BatchNormalization(axis = 3, name = 'bn3')(X)
33     X = Activation('relu')(X)
34     X = MaxPooling2D((2, 2), name='max_pool3')(X)
35     ##
36
37
38     # FLATTEN X (means convert it to a vector) + FULLYCONNECTED
39     X = Flatten()(X)
40     X = Dense(NumClass, activation='sigmoid', name='fc')(X)
41
42     # Create model. This creates your Keras model instance, you'll use this instance
43     model = Model(inputs = X_input, outputs = X, name='KerasModel')
44
45     return model

```

In [28]:

```

1  # Construct the model
2  Modellam = KerasModel(Xt[0,:,100:200,:].shape)
3  # Run the model
4  Modellam.compile(loss='binary_crossentropy', optimizer='Adam', metrics=['accuracy'])

```

In [29]:

```

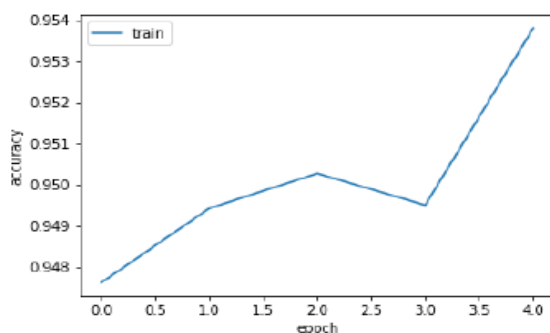
1  ### transferLearning
2  for i in range(0, len(Modellam.layers)-1):
3      Modellam.layers[i].set_weights(ModellamT.layers[i].get_weights())

```

In [93]:

```
1 history = Modellam.fit( x=Xt[0:4350,:,100:200,:], y=Yt[0:4350], batch_size=2**6, epoch
2 plt.plot(history.history['acc'])
3 plt.ylabel('accuracy')
4 plt.xlabel('epoch')
5 plt.legend(['train', 'test'], loc='upper left')
6 plt.show()
```

```
Epoch 1/5
4350/4350 [=====] - 411s 94ms/step - loss: 0.1392 -
acc: 0.9476
Epoch 2/5
4350/4350 [=====] - 413s 95ms/step - loss: 0.1338 -
acc: 0.9494
Epoch 3/5
4350/4350 [=====] - 404s 93ms/step - loss: 0.1303 -
acc: 0.9503
Epoch 4/5
4350/4350 [=====] - 404s 93ms/step - loss: 0.1303 -
acc: 0.9495
Epoch 5/5
4350/4350 [=====] - 403s 93ms/step - loss: 0.1217 -
acc: 0.9538
```



In [18]:

```
1 _, NumClass = Yt.shape
2 labels = [" " for x in range(NumClass)]
3 for i in range(0, NumClass):
4     labels[i] = "class "+str(i)
```

In [19]:

```
1 labels
```

Out[19]:

```
['class 0', 'class 1', 'class 2', 'class 3', 'class 4', 'class 5']
```

In [22]:

```
1 pred = Modellam.predict(Xt4[:, :, 100:200, :])
```

In [23]:

```
1 from sklearn.metrics import roc_auc_score, roc_curve, auc
2 fpr0, tpr0, thresholds0 = roc_curve(Yt4[:,0], pred[:,0])
3 fpr1, tpr1, thresholds1 = roc_curve(Yt4[:,1], pred[:,1])
4 fpr2, tpr2, thresholds2 = roc_curve(Yt4[:,2], pred[:,2])
5 fpr3, tpr3, thresholds3 = roc_curve(Yt4[:,3], pred[:,3])
6 fpr4, tpr4, thresholds4 = roc_curve(Yt4[:,4], pred[:,4])
7 fpr5, tpr5, thresholds5 = roc_curve(Yt4[:,5], pred[:,5])
8
9 roc_auc0 = auc(fpr0, tpr0)
10 roc_auc1 = auc(fpr1, tpr1)
11 roc_auc2 = auc(fpr2, tpr2)
12 roc_auc3 = auc(fpr3, tpr3)
13 roc_auc4 = auc(fpr4, tpr4)
14 roc_auc5 = auc(fpr5, tpr5)
```

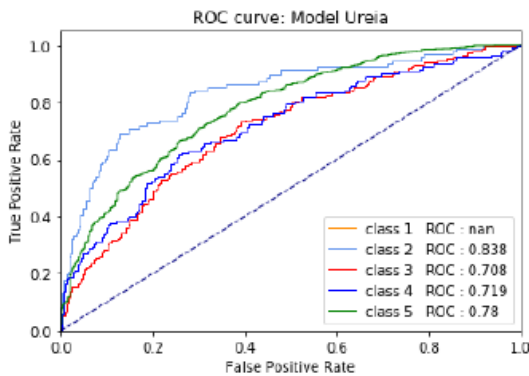
```
c:\users\carlos\appdata\local\programs\python\python36\lib\site-packages\skl
earn\metrics\ranking.py:571: UndefinedMetricWarning: No positive samples in
y_true, true positive value should be meaningless
UndefinedMetricWarning)
```

In [24]:

```

1 plt.figure()
2 lw = 1
3 colors = ['aqua', 'darkorange', 'cornflowerblue', 'red', 'blue', 'green']
4 #plt.plot(fpr0, tpr0 , color=colors[0],lw=lw, label=labels[0]+' ROC : '+str(round(r
5 plt.plot(fpr1, tpr1 , color=colors[1],lw=lw, label=labels[1]+' ROC : '+str(round(r
6 plt.plot(fpr2, tpr2 , color=colors[2],lw=lw, label=labels[2]+' ROC : '+str(round(r
7 plt.plot(fpr3, tpr3 , color=colors[3],lw=lw, label=labels[3]+' ROC : '+str(round(r
8 plt.plot(fpr4, tpr4 , color=colors[4],lw=lw, label=labels[4]+' ROC : '+str(round(r
9 plt.plot(fpr5, tpr5 , color=colors[5],lw=lw, label=labels[5]+' ROC : '+str(round(r
10
11
12 plt.plot([0, 1], [0, 1], color='navy', lw=lw, linestyle='--')
13 plt.xlim([0.0, 1.0])
14 plt.ylim([0.0, 1.05])
15 plt.xlabel('False Positive Rate')
16 plt.ylabel('True Positive Rate')
17 plt.title('ROC curve: Model Ureia')
18 plt.legend(loc="lower right")
19 plt.show()

```

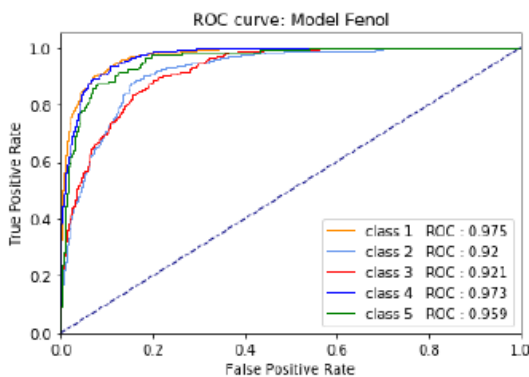


In [60]:

```

1 plt.figure()
2 lw = 1
3 colors = ['aqua', 'darkorange', 'cornflowerblue', 'red', 'blue', 'green']
4 #plt.plot(fpr0, tpr0 , color=colors[0],lw=lw, label=labels[0]+' ROC : '+str(round(r
5 plt.plot(fpr1, tpr1 , color=colors[1],lw=lw, label=labels[1]+' ROC : '+str(round(r
6 plt.plot(fpr2, tpr2 , color=colors[2],lw=lw, label=labels[2]+' ROC : '+str(round(r
7 plt.plot(fpr3, tpr3 , color=colors[3],lw=lw, label=labels[3]+' ROC : '+str(round(r
8 plt.plot(fpr4, tpr4 , color=colors[4],lw=lw, label=labels[4]+' ROC : '+str(round(r
9 plt.plot(fpr5, tpr5 , color=colors[5],lw=lw, label=labels[5]+' ROC : '+str(round(r
10
11
12 plt.plot([0, 1], [0, 1], color='navy', lw=lw, linestyle='--')
13 plt.xlim([0.0, 1.0])
14 plt.ylim([0.0, 1.05])
15 plt.xlabel('False Positive Rate')
16 plt.ylabel('True Positive Rate')
17 plt.title('ROC curve: Model Fenol')
18 plt.legend(loc="lower right")
19 plt.show()

```

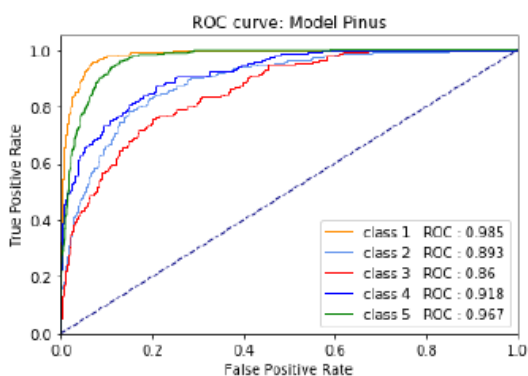


In [42]:

```

1 plt.figure()
2 lw = 1
3 colors = ['aqua', 'darkorange', 'cornflowerblue', 'red', 'blue', 'green']
4 #plt.plot(fpr0, tpr0 , color=colors[0],lw=lw, label=labels[0]+' ROC : '+str(round(
5 plt.plot(fpr1, tpr1 , color=colors[1],lw=lw, label=labels[1]+' ROC : '+str(round(r
6 plt.plot(fpr2, tpr2 , color=colors[2],lw=lw, label=labels[2]+' ROC : '+str(round(r
7 plt.plot(fpr3, tpr3 , color=colors[3],lw=lw, label=labels[3]+' ROC : '+str(round(r
8 plt.plot(fpr4, tpr4 , color=colors[4],lw=lw, label=labels[4]+' ROC : '+str(round(r
9 plt.plot(fpr5, tpr5 , color=colors[5],lw=lw, label=labels[5]+' ROC : '+str(round(r
10
11
12 plt.plot([0, 1], [0, 1], color='navy', lw=lw, linestyle='--')
13 plt.xlim([0.0, 1.0])
14 plt.ylim([0.0, 1.05])
15 plt.xlabel('False Positive Rate')
16 plt.ylabel('True Positive Rate')
17 plt.title('ROC curve: Model Pinus')
18 plt.legend(loc="lower right")
19 plt.show()

```

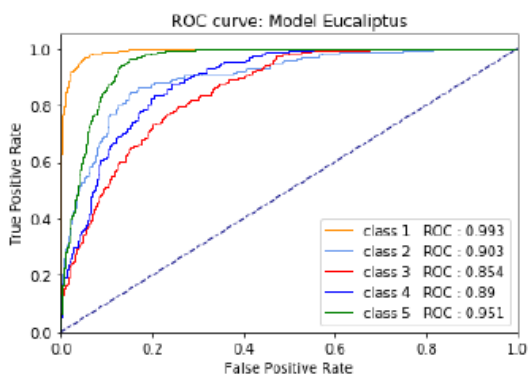


In [49]:

```

1 plt.figure()
2 lw = 1
3 colors = ['aqua', 'darkorange', 'cornflowerblue', 'red', 'blue', 'green']
4 #plt.plot(fpr0, tpr0 , color=colors[0],lw=lw, label=labels[0]+' ROC : '+str(round(
5 plt.plot(fpr1, tpr1 , color=colors[1],lw=lw, label=labels[1]+' ROC : '+str(round(r
6 plt.plot(fpr2, tpr2 , color=colors[2],lw=lw, label=labels[2]+' ROC : '+str(round(r
7 plt.plot(fpr3, tpr3 , color=colors[3],lw=lw, label=labels[3]+' ROC : '+str(round(r
8 plt.plot(fpr4, tpr4 , color=colors[4],lw=lw, label=labels[4]+' ROC : '+str(round(r
9 plt.plot(fpr5, tpr5 , color=colors[5],lw=lw, label=labels[5]+' ROC : '+str(round(r
10
11
12 plt.plot([0, 1], [0, 1], color='navy', lw=lw, linestyle='--')
13 plt.xlim([0.0, 1.0])
14 plt.ylim([0.0, 1.05])
15 plt.xlabel('False Positive Rate')
16 plt.ylabel('True Positive Rate')
17 plt.title('ROC curve: Model Eucaliptus')
18 plt.legend(loc="lower right")
19 plt.show()

```




In [96]:

```

1 plt.figure()
2 lw = 1
3 colors = ['aqua', 'darkorange', 'cornflowerblue', 'red', 'blue', 'green']
4 #plt.plot(fpr0, tpr0 , color=colors[0],lw=lw, label=labels[0]+' ROC : '+str(round(r
5 plt.plot(fpr1, tpr1 , color=colors[1],lw=lw, label=labels[1]+' ROC : '+str(round(r
6 plt.plot(fpr2, tpr2 , color=colors[2],lw=lw, label=labels[2]+' ROC : '+str(round(r
7 plt.plot(fpr3, tpr3 , color=colors[3],lw=lw, label=labels[3]+' ROC : '+str(round(r
8 plt.plot(fpr4, tpr4 , color=colors[4],lw=lw, label=labels[4]+' ROC : '+str(round(r
9 plt.plot(fpr5, tpr5 , color=colors[5],lw=lw, label=labels[5]+' ROC : '+str(round(r
10
11
12 plt.plot([0, 1], [0, 1], color='navy', lw=lw, linestyle='--')
13 plt.xlim([0.0, 1.0])
14 plt.ylim([0.0, 1.05])
15 plt.xlabel('False Positive Rate')
16 plt.ylabel('True Positive Rate')
17 plt.title('ROC curve: General model')
18 plt.legend(loc="lower right")
19 plt.show()

```



In [61]:

```

1 ## Model validation
2 preds = Modellam.evaluate(Xt3[0:50, :, 100:200, :], Yt3[0:50])
3 print ("Loss = " + str(round(preds[0],3)))
4 print ("Test Accuracy = " + str(round(preds[1],3)))

```

```

50/50 [=====] - 2s 39ms/step
Loss = 0.305
Test Accuracy = 0.85

```

In [52]:

```

1 ## Model validation
2 preds = Modellam.evaluate(Xt2[0:50, :, 100:200, :], Yt2[0:50])
3 print ("Loss = " + str(round(preds[0],3)))
4 print ("Test Accuracy = " + str(round(preds[1],3)))

```

```

50/50 [=====] - 2s 39ms/step
Loss = 0.161
Test Accuracy = 0.93

```

In [51]:

```

1 ## Model validation
2 preds = Modellam.evaluate(Xt1[0:50, :, 100:200, :], Yt1[0:50])
3 print ("Loss = " + str(round(preds[0],3)))
4 print ("Test Accuracy = " + str(round(preds[1],3)))

```

```

50/50 [=====] - 3s 59ms/step
Loss = 0.305
Test Accuracy = 0.85

```

In [97]:

```

1 ## Model validation
2 preds = Modellam.evaluate(Xt[4350:4396, :, 100:200, :], Yt[4350:4396])
3 print ("Loss = " + str(round(preds[0],3)))
4 print ("Test Accuracy = " + str(round(preds[1],3)))

```

```

46/46 [=====] - 2s 44ms/step
Loss = 0.343
Test Accuracy = 0.873

```

In [97]:

```
1 ## Model validation
2 preds = ModelLam.evaluate(Xt[4350:4396, :, 100:200, :], Yt[4350:4396])
3 print ("Loss = " + str(round(preds[0],3)))
4 print ("Test Accuracy = " + str(round(preds[1],3)))
```

46/46 [=====] - 2s 44ms/step
 Loss = 0.343
 Test Accuracy = 0.873

In [92]:

```
1 # Save model
2 # ModelLam.save(path0 + "ModelLam3.h5")
```

In [21]:

```
1 # Load model
2 ModelLam = load_model(path0 + "ModelLam3.h5")
```

Model

	name	time	sizedata	classes	size	epoch	train acc	val acc
	ModelLam3	Sep 19	4396	5	270KB	10	.917	.87
	ModelLam3	Sep 19	4396	5	270KB	20	.933	.88
	ModelLam3	Sep 19	4396	5	270KB	30	.954	.89