

EMMANUEL ZULLO GODINHO

USO DE IA (*NEURO-FUZZY*) NA RESISTÊNCIA E COMPORTAMENTO DA MADEIRA "*in natura*" E TERMICAMENTE MODIFICADA DE CLONES HÍBRIDOS DE EUCALIPTO

Relatório de Pós-doutorado realizado na
Universidade Estadual Paulista (UNESP),
Faculdade de Ciências Agrônômicas,
Instituto, Ciência Florestal, Botucatu.

Supervisor: Prof. Dr. Ricardo Marques
Barreiros

Cossupervisor: Prof. Dr. Cantídio Fernando
Gouvêa

Botucatu

2026

EMMANUEL ZULLO GODINHO

**USO DE IA (*NEURO-FUZZY*) NA RESISTÊNCIA E COMPORTAMENTO DA
MADEIRA "*in natura*" E TERMICAMENTE MODIFICADA DE CLONES HÍBRIDOS
DE EUCALIPTO**

Botucatu

2026

EMMANUEL ZULLO GODINHO

**USO DE IA (*NEURO-FUZZY*) NA RESISTÊNCIA E COMPORTAMENTO DA
MADEIRA "*in natura*" E TERMICAMENTE MODIFICADA DE CLONES HÍBRIDOS
DE EUCALIPTO**

Relatório apresentado à Faculdade de
Ciências Agronômicas da Unesp Câmpus
de Botucatu, para **finalização** do Pós-
doutorado em Ciência Florestal.

Supervisor: Prof. Dr. Ricardo Marques Barreiros

Co-supervisor: Prof. Dr. Cantídio Fernando Gouvêa

Botucatu

2026

Impacto potencial desta pesquisa

A termorretrificação da madeira é um processo que submete peças de madeira a altas temperaturas (120–200°C) para melhorar suas propriedades, como estabilidade dimensional, resistência a fungos e aparência similar à de madeiras tropicais de maior valor econômico. O método pode ser realizado em diferentes condições, como em estufa ou em autoclave, e impacta variavelmente as propriedades mecânicas conforme a espécie de madeira e os parâmetros utilizados.

O tratamento térmico reduz higroscopicidade e aumenta a durabilidade, porém frequentemente causa perda de massa e reduções em propriedades mecânicas como resistência à flexão e compressão, variando mais significativamente em eucalipto do que em pinus. As temperaturas e durações do processo devem ser otimizadas para maximizar benefícios e minimizar perdas mecânicas, reconhecendo que temperaturas muito altas tendem a degradar hemiceluloses e celulose, causando fragilidade.

Além disso, o desenvolvimento de ferramentas de modelagem, como sistemas *Neuro-Fuzzy* (combinação de redes neurais e *lógica Fuzzy*), pode ser estratégico para prever e otimizar os resultados da termorretrificação, integrando múltiplos fatores operacionais e auxiliando no controle de qualidade e tomada de decisão técnica e comercial.

Potential Impact of this research

Wood thermo-treatment is a process that subjects wood pieces to high temperatures (120–200°C) to enhance their properties, such as dimensional stability, fungal resistance, and appearance similar to that of high-value tropical woods. This method can be conducted under different conditions, such as in a kiln or autoclave, and its effects on mechanical properties vary depending on the wood species and the parameters used.

Thermal treatment reduces hygroscopicity and increases durability, but it often causes mass loss and reductions in mechanical properties such as flexural and compressive strength effects generally more pronounced in eucalyptus than in pine. The temperatures and durations of the process must be optimized to maximize benefits and minimize mechanical losses, recognizing that excessively high temperatures tend to degrade hemicelluloses and cellulose, leading to fragility.

Moreover, the development of modeling tools, such as *Neuro-Fuzzy* systems (which combine neural networks and *Fuzzy* logic), can be strategic for predicting and optimizing the results of thermo-treatment. These tools integrate multiple operational factors and support quality control and technical and commercial decision-making.

Primeiramente a DEUS.

A minha amada esposa Maisa Liene dos
Santos Godinho,

Co meu filho Gabriel Mees Godinho

Co meu pai, minha mãe (*in memoriam*), meus
irmãos Alexandre e Anna Luíza (*in memoriam*),

dedico.

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão ao meu orientador, Professor Doutor Ricardo Marques Barreiros, pela orientação incansável, apoio intelectual e dedicação ao longo de todo este trabalho. Sua confiança em meu potencial e seus ensinamentos foram fundamentais para a realização desta tese e para minha formação acadêmica e pessoal.

Agradeço também ao meu coorientador, Professor Doutor Cantídio Fernando Gouvêa, pelo valioso suporte, contribuições técnicas e incentivo durante todo o processo de pesquisa. Sua parceria foi essencial para o aprimoramento desta trajetória.

Estendo meus sinceros agradecimentos à Faculdade de Ciências Agrônômicas da UNESP (FCA/UNESP), pela infraestrutura, oportunidades e ambiente acadêmico estimulante. O acolhimento e o suporte de toda a equipe foram imprescindíveis para o desenvolvimento deste trabalho.

A todos, meu muito obrigado!

A frase mais conhecida do Mestre Oogway no filme *Kung Fu Panda* é: **"O ontem é história, o amanhã é um mistério, mas o hoje é uma dádiva, é por isso que se chama presente"**. Essa frase encapsula a filosofia do mestre sobre viver o momento presente e apreciar cada dia.

LISTA DE ILUSTRAÇÕES

Capítulo 1 – Modelagem inteligente de processos térmicos em madeiras: uma revisão sistemática

| | |
|---|----|
| Figura 1 – Número de documentos científicos por palavra-chave..... | 25 |
| Figura 2 – Número de documentos científicos publicados por ano..... | 29 |
| Figura 3 – Nuvem de palavras..... | 30 |

Capítulo 2 – Análise das superfícies de resposta e desempenho dos modelos para previsão de propriedades

| | |
|---|----|
| Figura 1 – Fluxograma de metrologia experimental..... | 39 |
| Figura 2 – Superfície de Resposta 3D dos Clones LW e H77 para a Densidade aparente..... | 43 |
| Figura 3 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior - Densidade aparente..... | 43 |
| Figura 4 – Superfície de Resposta 3D dos Clones LW e H77 para a Densidade básica..... | 45 |
| Figura 5 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior - Densidade básica..... | 45 |
| Figura 6 – Superfície de Resposta 3D dos Clones LW e H77 para a Perda de massa..... | 47 |
| Figura 7 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Perda de massa..... | 47 |
| Figura 8 – Superfície de Resposta 3D dos Clones LW e H77 para o Inchamento volumétrico total..... | 49 |
| Figura 9 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Inchamento volumétrico total..... | 49 |
| Figura 10 – Superfície de Resposta 3D dos Clones LW e H77 para o Módulo de ruptura..... | 51 |
| Figura 11 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Módulo de ruptura..... | 51 |
| Figura 12 – Superfície de Resposta 3D dos Clones LW e H77 para o Módulo de elasticidade... | 53 |
| Figura 13 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Módulo de elasticidade..... | 53 |

LISTA DE TABELAS

Capítulo 1 – Modelagem inteligente de processos térmicos em madeiras: uma revisão sistemática

| | |
|--|----|
| Tabela 1 – Teste de definição de busca de Strings..... | 22 |
| Tabela 2 – Teste de definição de busca de Strings com a aplicação dos filtros..... | 24 |
| Tabela 3 – Teste de definição de busca de Strings com a aplicação dos filtros..... | 25 |
| Tabela 4 – Resumo dos Artigos Analisados..... | 26 |

SUMÁRIO

| | | |
|----------|--|-----------|
| | RESUMO | 13 |
| 1 | CAPÍTULO 1 - MODELAGEM INTELIGENTE DE PROCESSOS TÉRMICOS EM MADEIRAS: UMA REVISÃO SISTEMÁTICA | 16 |
| 1.1 | INTRODUÇÃO..... | 16 |
| 1.2 | REVISÃO DE LITERATURA..... | 18 |
| 1.2.1 | Bases Conceituais da Termorreificação de Madeira e Seus efeitos nas Propriedades Físico-Mecânicas..... | 18 |
| 1.2.2 | Modelagem Matemática em Processos de Modificação da Madeira: Métodos Tradicionais versus inteligentes..... | 19 |
| 1.3 | MATERIAL E MÉTODOS..... | 20 |
| 1.3.1 | Entrada..... | 21 |
| 1.4 | RESULTADOS E DISCUSSÃO..... | 25 |
| 1.4.1 | Processamento..... | 25 |
| 1.4.2 | Saída..... | 26 |
| 1.5 | CONCLUSÃO..... | 31 |
| | REFERÊNCIAS..... | 32 |
| 2 | CAPÍTULO 2 – ANÁLISE DAS SUPERFÍCIES DE RESPOSTA E DESEMPENHO DOS MODELOS PARA PREVISÃO DE PROPRIEDADES | 37 |
| 2.1 | INTRODUÇÃO..... | 37 |
| 2.2 | MATERIAL E MÉTODOS..... | 39 |
| 2.2.1 | Interpolação polinomial pelo método de Lagrange..... | 40 |
| 2.2.2 | Modelagem Matemática <i>Neuro-Fuzzy</i> | 41 |
| 2.2.3 | Análise Estatística..... | 42 |
| 2.3 | RESULTADOS..... | 42 |
| 2.3.1 | Densidade Aparente..... | 42 |
| 2.3.2 | Densidade Básica..... | 44 |
| 2.3.3 | Perda de Massa..... | 46 |
| 2.3.4 | Inchamento Volumétrico Total..... | 48 |
| 2.3.5 | Módulo de Ruptura..... | 50 |
| 2.3.6 | Módulo de Elasticidade..... | 52 |
| 2.4 | DISCUSSÃO..... | 54 |
| 2.5 | CONCLUSÃO..... | 55 |
| | REFERÊNCIAS..... | 55 |
| | APÊNDICE A..... | 57 |
| | APÊNDICE B..... | 59 |

RESUMO

A silvicultura é um setor estratégico para que a economia brasileira impulsione a produção, exportação e geração de empregos, com destaque nacional e internacional no setor madeireiro. Em São Paulo, a atividade é fundamental para o agronegócio e a economia regional, sendo baseada principalmente no cultivo de eucalipto e pinus. A indústria madeireira do país possui alto grau de tecnologia, permitindo agregar valor à matéria-prima e ampliar a competitividade global. Dentre as tecnologias empregadas, a termorreificação modifica as propriedades da madeira, aumentando sua estabilidade e resistência, atendendo a demandas de sustentabilidade. Nesse contexto, sistemas *Neuro-Fuzzy* se destacam como ferramentas avançadas para modelagem de processos complexos e tomada de decisão. Este projeto foi desenvolvido em duas partes, sendo uma parte chamado capítulo 1 – Modelagem inteligente de processos térmicos em madeiras: uma revisão sistemática e capítulo 2 – Análise das superfícies de resposta e desempenho dos modelos para previsão de propriedades. O objetivo do capítulo 1 foi identificar como está configurado o estado do conhecimento sobre a aplicabilidade da *Neuro-Fuzzy* na termorreificação da madeira. Para isso, foi realizada uma Revisão Bibliográfica Sistemática (RBS) nas principais bases de dados, resultando em 26 artigos científicos focados em aplicações de Inteligência Artificial, especialmente *Neuro-Fuzzy*, em processos industriais, mas nenhum tratando especificamente da termorreificação da madeira. Isso evidencia a originalidade e a existência de uma lacuna relevante, apontando potencial para pesquisas futuras, especialmente utilizando *softwares* como *Python* para modelagem e integração de dados de propriedades da madeira termorreificada com sistemas *Neuro-Fuzzy* para otimização e inovação no setor florestal. No capítulo 2, o objetivo foi desenvolver uma modelagem matemática aplicando o método *Fuzzy* e a Inteligência Artificial da Lógica *Fuzzy* (*Neuro-Fuzzy*), otimizando o processo de termorreificação da madeira em dois clones híbridos de eucalipto, buscando-se prever a melhor temperatura (°C) e o melhor tempo de termorreificação. O artigo analisa a influência dos parâmetros de tempo e temperatura no processo de termorreificação sobre as propriedades físicas e mecânicas de dois clones de madeira (LW e H77), utilizando métodos matemáticos avançados, destacando especialmente a modelagem *Neuro-Fuzzy*. Foram avaliadas propriedades como densidade aparente, densidade básica, perda de massa, inchamento volumétrico total, módulo de ruptura e módulo de elasticidade, com resultados indicando que cada clone responde de maneira distinta aos tratamentos térmicos, exigindo estratégias personalizadas para otimizar o desempenho da madeira. Os métodos aplicados incluíram interpolação polinomial pelo método de Lagrange e sistemas *Neuro-Fuzzy*, validados por análise estatística via Raiz do Erro Quadrático Médio - RMSE, que mostraram elevado grau de precisão para propriedades como densidade aparente (RMSE 0,10) e básica (RMSE 0,087), mas maiores diferenças para perda de massa (RMSE 1,469) e módulo de elasticidade (RMSE 3,796). O clone LW apresentou melhores resultados em faixas restritas de tempo e temperatura, enquanto o H77 mostrou maior flexibilidade em diferentes cenários. O estudo demonstra que a personalização dos parâmetros de tratamento térmico, aliada à aplicação de ferramentas inteligentes como a *Neuro-Fuzzy*, é fundamental para maximizar as qualidades físico-mecânicas e proporcionar avanços sustentáveis e eficientes no uso industrial da madeira modificada termicamente.

Palavras-chave: termorreificação; inteligência artificial; propriedades da madeira; modelagem matemática; personalização dos tratamentos

ABSTRACT

Silviculture is a strategic sector for the Brazilian economy, driving production, exports, and job creation, with both national and international prominence in the timber industry. In the state of São Paulo, this activity is fundamental to agribusiness and the regional economy, being primarily based on the cultivation of eucalyptus and pine. The country's timber industry boasts a high level of technology, enabling the addition of value to raw materials and increasing global competitiveness. Among the technologies employed, thermal modification (thermoretification) alters wood properties, enhancing its stability and resistance while meeting sustainability demands. In this context, *Neuro-Fuzzy* systems stand out as advanced tools for modeling complex processes and supporting decision-making. This project was developed in two parts: Chapter 1, "Intelligent Modeling of Thermal Processes in Wood: A Systematic Review", and Chapter 2, "Analysis of Response Surfaces and Model Performance for Property Prediction". The objective of Chapter 1 was to assess the current state of knowledge regarding the application of *Neuro-Fuzzy* systems to wood thermal modification. To this end, a Systematic Literature Review (SLR) was conducted in major databases and identified 26 scientific articles focused on artificial intelligence applications particularly *Neuro-Fuzzy* in industrial processes, though none specifically addressed wood thermoretification. This gap highlights the originality and relevance of the present work, and points to potential for future research, especially using *software* like Python to model and integrate data on properties of thermally modified wood with *Neuro-Fuzzy* systems for optimization and innovation in the forestry sector. Chapter 2 involved the development of mathematical models using *Fuzzy Logic* and *Neuro-Fuzzy Artificial Intelligence*, aiming to optimize the thermoretification process in two hybrid eucalyptus clones by identifying the optimal temperature (°C) and processing time. The article analyzes the influence of time and temperature parameters in the thermoretification process on the physical and mechanical properties of two wood clones (LW and H77), using advanced mathematical methods, with particular emphasis on the *Neuro-Fuzzy* approach. Properties evaluated included apparent density, basic density, mass loss, total volumetric swelling, modulus of rupture, and modulus of elasticity. Results indicated that each clone responded differently to thermal treatments, requiring tailored strategies to optimize wood performance. The methods employed included polynomial interpolation by the Lagrange method and *Neuro-Fuzzy* systems validated by statistical analysis using Root Mean Square Error RMSE, which demonstrated a high degree of accuracy for properties such as apparent density (RMSE 0.10) and basic density (RMSE 0.087), but greater differences for mass loss (RMSE 1,469) and modulus of elasticity (RMSE 3,796). Clone LW showed the best results in narrower ranges of time and temperature, while H77 exhibited greater flexibility under different scenarios. The study demonstrates that tailoring thermal treatment parameters, combined with the application of intelligent tools such as *Neuro-Fuzzy* systems, is essential to maximize the physical and mechanical qualities of wood, promoting sustainable and efficient advances in the industrial use of thermally modified wood.

Keywords: thermoretification; artificial intelligence; wood properties; mathematical modeling; treatment customization.

CAPÍTULO 1

MODELAGEM INTELIGENTE DE PROCESSOS TÉRMICOS EM MADEIRAS: UMA REVISÃO SISTEMÁTICA

1.1 INTRODUÇÃO

A silvicultura desempenha um papel fundamental na economia brasileira, sendo responsável por impulsionar a produção de madeira e derivados, além de gerar emprego e renda em diversas regiões do país (IBA, 2024). Em 2023, a produção brasileira de madeira em tora de florestas plantadas superou 200 milhões de metros cúbicos, enquanto o valor das exportações do setor atingiu cerca de 12 bilhões de dólares americanos, com destaque para celulose, papel e painéis de madeira (IBGE, 2024). Esses números colocam o Brasil entre os principais exportadores mundiais de produtos florestais, evidenciando a importância estratégica da silvicultura para o desenvolvimento econômico nacional.

No Estado de São Paulo, a silvicultura também se destaca como uma das principais atividades do agronegócio, de acordo com dados do (IBA, 2024), a produção paulista de madeira em tora proveniente de florestas plantadas alcançou aproximadamente 22,4 milhões de metros cúbicos em 2022, contribuindo significativamente para o valor bruto da produção agropecuária estadual (FLORESTAR, 2024). Segundo os mesmos autores, além disso, o setor tem expressiva participação na geração de empregos diretos e indiretos, dinamizando a economia regional e fomentando cadeias produtivas ligadas à madeira, à produção de celulose e ao setor moveleiro.

A silvicultura é definida como o ramo da ciência que estuda e aplica técnicas voltadas ao cultivo, manejo e restauração de florestas, com objetivos econômicos, ambientais e sociais (BLOIS et al., 2017). Essa área abrange desde a seleção das espécies mais adequadas para determinado clima e solo, passando pelo plantio, condução, colheita e monitoramento do crescimento florestal, até a recuperação de áreas degradadas e a promoção da sustentabilidade dos ecossistemas (FARIA, 2012).

No contexto brasileiro, as principais espécies utilizadas na silvicultura são o eucalipto e o pinus, sendo que o eucalipto é frequentemente escolhido para produção de celulose, carvão vegetal e energia, enquanto o pinus é amplamente utilizado para madeira serrada, móveis e painéis (SILVA & ROCHA, 2010). Outras espécies nativas

também vêm ganhando espaço em projetos de restauração e manejo sustentável, ampliando a diversidade e o potencial econômico do setor.

O parque industrial madeireiro brasileiro é robusto e tecnologicamente avançado, permitindo a transformação da matéria-prima florestal em itens que suprem tanto o mercado interno quanto as exportações, com essa eficiência e eficácia industrial, muitos são os benefícios que contribuem para esse setor, como: geração de renda, inovação tecnológica e consolidação do país como um setor de grande relevância no mercado internacional de produtos florestais (FLORESTAR, 2024; IBA, 2024).

Entre as tecnologias aplicadas à madeira, destaca-se a termorreificação, processo no qual a madeira é submetida a temperaturas elevadas em atmosfera controlada, alterando suas propriedades físico-químicas (FERREIRA et al., 2019a). A termorreificação proporciona maior estabilidade dimensional, resistência a fungos, redução da higroscopicidade e melhora no isolamento térmico, ampliando o leque de usos comerciais da madeira tratada (FERREIRA; RANGEL & CAMPOS, 2018). Essas alterações elevam o valor agregado do produto, tornando-o mais competitivo frente a materiais convencionais e ampliando seu mercado potencial.

A busca por maior eficiência e sustentabilidade tem levado à otimização dos processos produtivos na indústria madeireira. Estratégias baseadas em automação, controle estatístico, simulações computacionais e integração inteligente de dados promovem a redução de custos, melhoria da qualidade, minimização de resíduos e aproveitamento racional dos recursos (NUNES et al., 2018).

Nesse contexto, técnicas modernas como os sistemas *Neuro-Fuzzy* vêm sendo aplicadas com sucesso nos processos produtivos industriais, inclusive na área madeireira (GODINHO et al., 2024). Esses sistemas combinam a capacidade de aprendizado das redes neurais com a flexibilidade e a interpretabilidade dos sistemas *Fuzzy*, permitindo a modelagem de processos complexos, previsão de resultados e tomada de decisão em ambientes de alta incerteza (ALAHMED & AL-MUHAINI, 2020).

O modelo *Neuro-Fuzzy* integra conceitos de inteligência artificial para aproximar o conhecimento humano (por meio de regras *Fuzzy*) e a aprendizagem automática baseada em dados (BATISTELA; SABBATINO & SIMÕES, 2020). Ao aplicar *Neuro-Fuzzy* em processos industriais, é possível otimizar parâmetros de produção, identificar padrões, prever comportamentos e adaptar sistemas em tempo

real, contribuindo para processos produtivos mais eficientes, inteligentes e sustentáveis (EHTERAM et al., 2019).

Diante desse contexto, o objetivo desse capítulo é identificar como está configurado o estado do conhecimento sobre a aplicabilidade da *Neuro-Fuzzy* na termorreificação da madeira.

1.2 REVISÃO DE LITERATURA

1.2.1 Bases Conceituais da Termorreificação de Madeira e Seus efeitos nas Propriedades Físico-Mecânicas

A termorreificação da madeira é um processo termoquímico no qual a madeira é submetida a temperaturas elevadas, geralmente entre 160°C e 260°C, em ambiente com presença controlada ou ausência de oxigênio (FERREIRA et al., 2019b). O aquecimento provoca modificações nas estruturas moleculares dos principais constituintes da madeira, especialmente da hemicelulose, celulose e lignina (FERREIRA; RANGEL & CAMPOS, 2018).

Quimicamente, o processo de termorreificação promove hidrólise, despolimerização e reações de condensação entre os constituintes da madeira (PERTUZZATTI et al., 2016). A hemicelulose é particularmente sensível ao calor, sendo degradada em subprodutos como ácidos e açúcares simples, que por sua vez catalisam novas reações e promovem a autocatálise do processo (GODINHO; CANEPPELE & GASPAROTTO, 2021). Segundo o mesmo autor a celulose sofre leve degradação, perdendo algumas unidades de glicose das cadeias laterais, já a lignina é menos afetada, mas apresenta reestruturação e condensação, tornando-se mais complexa e contribuindo para a maior resistência química e biológica do material tratado.

O tratamento térmico tende a reduzir a densidade da madeira devido à degradação e perda de massa de hemiceluloses, liberação de compostos voláteis (como água, ácidos orgânicos e gases leves) e redução do teor de umidade de equilíbrio (FERREIRA et al., 2019a). Embora o volume do material permaneça relativamente constante, a massa diminui, levando a uma densidade aparente menor. Essa redução pode variar de acordo com a intensidade do tratamento e a espécie da madeira, mas em geral é considerada moderada.

A maior vantagem da termorretificação está na notável melhora da estabilidade dimensional da madeira, esse processo reduz significativamente a quantidade de grupos hidrofílicos (especialmente na hemicelulose), tornando a madeira menos propensa a absorver água e sofrer inchamentos ou retrações em resposta a variações de umidade ambiental (BARREIROS et al., 2022). Como resultado, a madeira termorretificada apresenta alteração na higroscopicidade, maior durabilidade biológica e resistência ao apodrecimento, o que amplia seu potencial de uso em condições externas e ambientes úmidos, segundo os mesmos autores.

Além disso, a quebra das cadeias poliméricas, associada à queda da densidade e à menor higroscopicidade, também afeta a condutividade térmica da madeira, sendo que em geral, a madeira termorretificada apresenta condutividade térmica ligeiramente inferior à da madeira natural, proporcionando melhor desempenho em aplicações que exigem isolamento térmico (BARREIROS et al., 2022).

1.2.2 Modelagem Matemática em Processos de Modificação da Madeira: Métodos Tradicionais x Inteligentes

A modelagem matemática é fundamental nos processos de modificação de matéria-prima, principalmente a madeira, seja para descrever transformações térmicas, químicas ou mecânicas, permitindo prever e otimizar as propriedades finais do material (IMAI et al., 2020).

Métodos tradicionais apoiam-se em modelos lineares e estatísticos, como regressão linear, análise de variância e equações diferenciais para simular fenômenos de transferência de calor, variação de densidade e propriedades mecânicas após tratamentos como termorretificação ou carbonização (PEIXOTO, 1996).

No entanto, muitas etapas do processamento da madeira apresentam alta complexidade, variabilidade natural e comportamentos não lineares difíceis de captar com técnicas clássicas (HORST, 2013). Segundo o mesmo autor, as propriedades finais do material são frequentemente influenciadas por múltiplos fatores interativos, como espécie, teor de umidade, tempo, temperatura do processo e características anatômicas, o que desafia os modelos estatísticos convencionais.

A modelagem *Fuzzy* e os sistemas híbridos *Neuro-Fuzzy* destacam-se, em particular, por sua habilidade de lidar com incertezas, imputar regras linguísticas a partir do conhecimento de especialistas e adaptar-se a informações incompletas ou

imprecisas (GODINHO et al., 2023). Isso se traduz em vantagens práticas: esses sistemas conseguem modelar fenômenos onde não existe conhecimento matemático explícito ou quando há grande variabilidade dos dados (GODINHO; CANEPPELE & GASPAROTTO, 2022).

Na prática, enquanto os modelos tradicionais são recomendados para situações controladas e sistemas bem compreendidos, abordagens baseadas em inteligência artificial e especialmente a modelagem *Fuzzy* oferecem maior flexibilidade, precisão e adaptabilidade em ambientes industriais e de pesquisa marcados por incertezas e não linearidades (MARRO et al., 2010). Os sistemas *Fuzzy* podem ser ajustados com rapidez a diferentes condições e suas regras são facilmente interpretáveis, favorecendo tomadas de decisão mais assertivas na modificação e valorização da madeira (ASGHAR; TALHA & KIM, 2017).

1.3 MATERIAL E MÉTODOS

Considerando o problema da pesquisa apresentada, que trata do uso da abordagem *Neuro-Fuzzy* na termorreificação da madeira, observa-se que, conforme destacado por Godinho; Caneppele, (2022), a discussão central gira em torno da relevância de métodos avançados para otimizar processos de conversão de biomassa visando a produção de energias renováveis. Seguindo as orientações desses autores, formulou-se a hipótese de que a aplicação de sistemas *Neuro-Fuzzy* pode ser otimizada por meio da análise de dados disponíveis na literatura, utilizando-se de uma revisão bibliográfica sistemática para fundamentar e aprimorar a eficiência do processo de termorreificação da madeira.

A abordagem metodológica adotada neste estudo, conforme descrito por Godinho; Gasparotto; Caneppele, (2022), baseou-se na busca e análise de documentos provenientes de repositórios de publicações científicas. Tal estratégia pressupõe que o pesquisador exerça uma avaliação criteriosa, selecionando informações e aspectos pertinentes, realizando registros sistematizados e aplicando procedimentos rigorosos para assegurar a confiabilidade de suas interpretações, conforme recomendado por (CUNHA; ALVES & CUNHA, 2011). Assim, devido a estas considerações dos autores adotou-se a Revisão Bibliográfica Sistemática (RBS) como base metodológica para a realização deste estudo.

A Revisão Bibliográfica Sistemática (RBS) é um método estruturado que tem como objetivo localizar e reunir publicações acadêmicas disponíveis em fontes especializadas, todas pertinentes a um tema de pesquisa previamente definido (FERNANDES et al., 2016).

Esse método envolve a definição de protocolos, a execução de etapas estruturadas e o emprego de instrumentos metodológicos específicos, com o objetivo de elaborar uma análise consolidada sobre o assunto em foco (CONFORTO; AMARAL & SILVA, 2011)

Devido à sua natureza sistematizada, a Revisão Bibliográfica Sistemática (RBS) exige a formulação de uma questão de pesquisa bem definida, a partir da qual são elaboradas estratégias de busca, além de critérios rigorosos para a seleção, exclusão e análise dos documentos consultados, assegurando a qualidade e relevância das informações consideradas (ANTONIAZZI & GODINHO, 2023).

Para fundamentar o propósito deste estudo, optou-se pela aplicação da RBS, seguindo um procedimento estruturado em três etapas principais: Entrada, Processamento e Saída, conforme descrito também por (FERNANDES et al., 2016).

A etapa de entrada consiste na definição clara do problema de pesquisa que a Revisão Bibliográfica Sistemática pretende abordar, incluindo a delimitação dos objetivos, a estipulação dos critérios para inclusão e exclusão dos documentos e, especialmente, a formulação das *Strings* de busca.

Em seguida, durante a fase de processamento, são realizadas as buscas propriamente ditas, seguidas pela triagem inicial dos materiais por meio de leitura e avaliação criteriosa. Finalmente, na fase de saída, os documentos selecionados são organizados e armazenados, facilitando as análises subsequentes e o tratamento dos dados necessários para a elaboração da síntese dos resultados obtidos.

1.3.1 Entrada

O problema que esta pesquisa busca investigar foi “*Qual é o estado atual do conhecimento sobre a aplicabilidade da modelagem Neuro-Fuzzy na termorreificação da madeira?*” Assim, o objetivo desta Revisão Bibliográfica Sistemática (RBS) foi identificar o estado atual do conhecimento sobre a aplicação da modelagem *Neuro-Fuzzy* no processo de termorreificação da madeira.

A seleção das bases de dados foi realizada com base em sua relevância para a área de estudo, utilizando-se o acesso disponibilizado pelo Portal de Periódicos CAPES do Governo Federal, por meio do *login* institucional da UNESP, que permite acesso direto e liberado às plataformas *ScienceDirect*[®], *Scopus*[®], *Web of Science*[®], *Scielo*[®] e *SpringerLink*[®]. Essa conexão institucional, realizada através do e-mail da universidade, garantindo o acesso completo aos conteúdos científicos necessários para a pesquisa.

Após um levantamento inicial de palavras-chave e, criação das *Strings* de busca, limitou-se a um total de 5 *Strings* para a primeira busca exploratória, apresentados na Tabela 1, pesquisa foi realizada no dia 07 julho de 2025.

Tabela 1 – Teste de definição de busca de *Strings*

| id | <i>Strings</i> | CAPES[®] |
|-----------|-----------------------------------|--------------------------|
| 1 | “Termorretificação” | 30 |
| 2 | “ <i>Neuro-Fuzzy</i> ” | 14.598 |
| 3 | “Propriedades Físicas da madeira” | 44 |
| 4 | “ <i>Eucalyptus urograndis</i> ” | 371 |
| 5 | “Resistência da madeira” | 43 |
| Total | | 15.086 |

Fonte: Própria autoria

Durante a etapa de busca documental, as *Strings* de pesquisa foram combinadas progressivamente, inicialmente unindo-se dois termos por vez (“Termorretificação” AND “*Neuro-Fuzzy*”. “Termorretificação” AND “Propriedades Físicas da madeira”. “Termorretificação” AND “*Eucalyptus urograndis*”. “Termorretificação” AND “Resistência da madeira”. “*Neuro-Fuzzy*” AND “Propriedades Físicas da madeira”. “*Neuro-Fuzzy*” AND “*Eucalyptus urograndis*”. “*Neuro-Fuzzy*” AND “Resistência da madeira”. “Propriedades Físicas da madeira” AND “*Eucalyptus urograndis*”. “Propriedades Físicas da madeira” AND “Resistência da madeira”. “*Eucalyptus urograndis*” AND “Resistência da madeira”), depois três a três (“Termorretificação” AND “*Neuro-Fuzzy*” AND “Propriedades Físicas da madeira”. “Termorretificação” AND “*Neuro-Fuzzy*” AND “*Eucalyptus urograndis*”. “Termorretificação” AND “*Neuro-Fuzzy*” AND “Resistência da madeira”. “Termorretificação” AND “Propriedades Físicas da madeira” AND “*Eucalyptus urograndis*”. “Termorretificação” AND “Propriedades Físicas da madeira” AND

“Resistência da madeira”. “Termorretificação” AND “*Eucalyptus urograndis*” AND “Resistência da madeira”. “*Neuro-Fuzzy*” AND “Propriedades Físicas da madeira” AND “*Eucalyptus urograndis*”. “*Neuro-Fuzzy*” AND “Propriedades Físicas da madeira” AND “Resistência da madeira”. “*Neuro-Fuzzy*” AND “*Eucalyptus urograndis*” AND “Resistência da madeira”. “Propriedades Físicas da madeira” AND “*Eucalyptus urograndis*” AND “Resistência da madeira”), e assim sucessivamente, utilizando o conectivo booleano recomendado AND para conectar as palavras-chave.

O uso do operador AND é fundamental para garantir que os resultados retornem somente documentos que contenham simultaneamente todos os termos pesquisados, aumentando a precisão e relevância dos artigos encontrados, conforme aplicado por (CUNHA; ALVES & CUNHA, 2011). No entanto, após essas combinações mais específicas e complexas, observou-se que não houve retorno de resultados relevantes nas bases de dados consultadas, indicando uma escassez ou ausência de publicações científicas que abordassem diretamente o tema sob essa configuração específica.

Essa falta de documentos sugere que a aplicação da modelagem *Neuro-Fuzzy* na termorretificação da madeira ainda é um campo pouco explorado na literatura científica, reforçando a importância e a originalidade da presente pesquisa.

Após a realização da busca inicial utilizando os termos-chave definidos, constatou-se a existência de 15.086 artigos científicos relacionados ao tema. Diante desse volume expressivo de resultados, optou-se por delimitar a pesquisa por meio de seis filtros específicos: acesso aberto; tipo de recurso restrito a artigos; ano de publicação entre 2010 e 2025; abrangência tanto produções nacionais quanto internacionais; revisão por pares; e idioma limitado ao português e ao inglês. Esses critérios foram estabelecidos com o objetivo de assegurar a qualidade, a atualidade e a relevância dos documentos selecionados para a análise, tornando o estudo mais focado e consistente.

A Tabela 2 apresenta a quantidade de artigos com a inclusão dos filtros citados.

Tabela 2 – Teste de definição de busca de *Strings* com a aplicação dos filtros

| id | <i>Strings</i> | CAPES® |
|-----------|-----------------------------------|---------------|
| 1 | “Termorretificação” | 13 |
| 2 | “ <i>Neuro-Fuzzy</i> ” | 56 |
| 3 | “Propriedades Físicas da madeira” | 21 |
| 4 | “ <i>Eucalyptus urograndis</i> ” | 147 |
| 5 | “Resistência da madeira” | 23 |
| Total | | 260 |

Fonte: Própria autoria

Após a aplicação dos seis filtros de inclusão estabelecidos (acesso aberto, tipo de recurso restrito a artigos, ano de publicação entre 2010 e 2025, abrangência nacional e internacional, revisão por pares e idioma em português e inglês), assim o número de documentos científicos disponíveis foi reduzido para 260 artigos. Essa filtragem permitiu concentrar a análise em um conjunto mais qualificado e alinhado aos objetivos da pesquisa, facilitando a seleção de materiais relevantes para o estudo.

A partir dos 260 artigos encontrados após a aplicação dos filtros iniciais, foi realizada uma nova etapa de exclusão para refinar ainda mais o material a ser analisado. Inicialmente, foram descartados 150 artigos que não estavam disponíveis para *download* em PDF, seguidos da exclusão de 35 documentos duplicados. Em seguida, aplicou-se um filtro baseado nas palavras-chave e na análise dos resumos, eliminando mais 40 artigos que não apresentavam proximidade suficiente com o tema central da pesquisa. Por fim, uma leitura mais aprofundada resultou na exclusão de outros 10 artigos, culminando em um total de 26 artigos selecionados para análise detalhada, conforme Tabela 3. Essa triagem rigorosa garantiu que apenas os estudos mais relevantes e alinhados ao objetivo da pesquisa fossem considerados.

Tabela 3 – Teste de definição de busca de *Strings* com a aplicação dos filtros

| id | <i>Strings</i> | CAPES® |
|-------|-----------------------------------|--------|
| 1 | "Termorreificação" | 3 |
| 2 | " <i>Neuro-Fuzzy</i> " | 10 |
| 3 | "Propriedades Físicas da madeira" | 4 |
| 4 | " <i>Eucalyptus urograndis</i> " | 5 |
| 5 | "Resistência da madeira" | 4 |
| Total | | 26 |


Fonte: Própria autoria

1.4 RESULTADOS E DISCUSSÃO

1.4.1 Processamento

Com os documentos selecionados, utilizando os critérios aplicados na etapa de Entrada, iniciou-se o Processamento, no qual foram exportados 26 documentos da base de dados e importados para o *software* de gerenciamento Mendeley®. A distribuição dos documentos por tema foi a seguinte: "Termorreificação" (3), "*Neuro-Fuzzy*" (10), "Propriedades Físicas da madeira" (4), "*Eucalyptus urograndis*" (5) e "Resistência da madeira" (4), conforme ilustrado na Figura 1.

Figura 1 – Número de documentos científicos por palavra-chave



Legenda: (1) Termorreificação; (2) *Neuro-Fuzzy*; (3) Propriedades Físicas da madeira; (4) *Eucalyptus urograndis*; (5) Resistência da madeira.

Fonte: Próprio autor.

Após a análise criteriosa e a aplicação de filtros específicos, foram selecionados os artigos que fundamentaram esta pesquisa, garantindo a relevância e a qualidade do material examinado.

1.4.2 Saída

Após baixar e ler os 26 artigos na íntegra, foi elaborada uma tabela que apresenta o(s) autor(es), o título do artigo e sua principal contribuição para a comunidade acadêmica. Essa organização facilitou a análise comparativa dos estudos, permitindo identificar tendências, lacunas e avanços relevantes na área de pesquisa. Dessa forma, foi possível sistematizar o conhecimento disponível e direcionar os próximos passos do trabalho com maior embasamento, como listado na Tabela 4.

Tabela 4 – Resumo dos Artigos Analisados

| Id | Autor | Título | Contribuição |
|----|-------------------------|--|--|
| 1 | (Beltrame et al., 2010) | Propriedades Físico-Mecânicas da Madeira de <i>Araucaria angustifolia</i> (Bertol.) em Três Estratos Fitossociológicos | O artigo contribuiu ao demonstrar que as propriedades físico-mecânicas da madeira de <i>Araucaria angustifolia</i> variam conforme o estrato fitossociológico, sendo superiores nos estratos médio e superior. |
| 2 | (Cardoso et al., 2010) | Efeito da Combustão dos Gases da Carbonização no Rendimento Gravimétrico da Madeira de <i>Eucalyptus</i> sp. | O trabalho demonstrou que a combustão dos gases da carbonização não alterou o rendimento em carvão vegetal, mas reduziu a quantidade de madeira parcialmente carbonizada e aumentou a produção de finos. Esses achados auxiliam na otimização do processo de carbonização. |
| 3 | (Araújo et al., 2010) | Constituintes químicos e efeito ecotoxicológico do óleo volátil de folhas de <i>Eucalyptus urograndis</i> (MIRTACEAE) | O estudo identificou os principais constituintes do óleo volátil das folhas de <i>Eucalyptus urograndis</i> , destacando orto-cimeno e 1,8-cineol. Demonstrou que o óleo lixiviado pode causar efeitos tóxicos em organismos aquáticos, como <i>Daphnia laevis</i> e <i>D. similis</i> . |
| 4 | (Gonçalves; Leta, 2010) | Macroscopic Rock Texture Image Classification Using a Hierarchical <i>Neuro-Fuzzy</i> Class Method Laercio | O estudo apresentou um método hierárquico <i>Neuro-Fuzzy</i> baseado em partição binária do espaço (NFHB-Class) capaz de classificar texturas macroscópicas de rochas com acurácia superior a 73%. A abordagem automatiza a extração de regras <i>Fuzzy</i> interpretáveis, facilitando o diagnóstico e planejamento em exploração de reservatórios de petróleo. |
| 5 | (Vivian et al., 2010a) | Resistência da Madeira de <i>Canafístula</i> (<i>Peltophorum dubium</i> (Spreng.) Taub.) | A principal contribuição está na demonstração de como os diferentes níveis de umidade afetam |

| | | | |
|----|--|--|---|
| | | ao PSF e a Umidade de Equilíbrio | significativamente as propriedades de resistência ao impacto e à flexão estática da madeira. |
| 6 | (Stangerlin et al., 2010) | Propriedades de Flexão Estática da Madeira de <i>Carya illinoensis</i> em Duas Condições de Umidade | A principal contribuição deste artigo está na demonstração de que a presença de água na madeira de <i>Carya illinoensis</i> reduz significativamente suas propriedades de elasticidade e resistência à flexão estática. |
| 7 | (Vivian et al., 2010b) | Efeito de pré-tratamentos na taxa de secagem da madeira de <i>Hovenia dulcis</i> Thunb. | A principal contribuição deste artigo consiste em demonstrar como diferentes pré-tratamentos influenciam de maneira significativa a taxa de secagem da madeira de uva-do-japão (<i>Hovenia dulcis</i> Thunb.). |
| 8 | (Andrade et al., 2011) | Site evaluation and productivity of a 3-year old stand of <i>Eucalyptus urograndis</i> in São Paulo, Brazil | A principal contribuição deste artigo está na avaliação integrada de aspectos silviculturais, químicos e físicos de uma plantação de <i>Eucalyptus urograndis</i> no Brasil, fornecendo subsídios importantes para o manejo sustentável de florestas plantadas. |
| 9 | (Viera; Schumacher; Liberalesso, 2011) | Crescimento e produtividade de povoamentos monoespecíficos e mistos de Eucalipto e Acácia-negra | A principal contribuição deste artigo está em demonstrar que o interplântio de <i>Eucalyptus urograndis</i> com <i>Acacia mearnsii</i> , uma leguminosa arbórea fixadora de nitrogênio, não afetou negativamente o crescimento nem a produtividade total de madeira dos povoamentos em comparação aos monocultivos dessas espécies. |
| 10 | (Balbinot; Favieiro, 2013) | A <i>Neuro-Fuzzy</i> system for characterization of arm movements | O artigo apresenta como principal contribuição o desenvolvimento e validação de um sistema baseado na análise de sinais mioelétricos adquiridos por eletrodos de superfície para caracterização de movimentos do braço humano. |
| 11 | (Furlong et al., 2013) | Estimating microalgae <i>Synechococcus nidulans</i> daily biomass concentration using <i>Neuro-Fuzzy</i> network | O artigo apresentou como principal contribuição o desenvolvimento de um estimador <i>Neuro-Fuzzy</i> capaz de prever a concentração de biomassa da microalga <i>Synechococcus nidulans</i> a partir das concentrações iniciais em batelada, visando estimar a produtividade diária. |
| 12 | (Almeida et al., 2014) | Comparação entre valores de ensaios experimentais e calculados da resistência ao embutimento da madeira de <i>Pinus taeda</i> L. | O artigo contribuiu significativamente para o entendimento sobre o dimensionamento de ligações em estruturas de madeira com pinos metálicos, analisando a adequação das recomendações da norma brasileira ABNT NBR 7190:1997. |
| 13 | (Silva et al., 2014) | Estimativa da produtividade de trigo em função da adubação nitrogenada utilizando modelagem <i>Neuro Fuzzy</i> | O artigo contribuiu de maneira relevante ao demonstrar a viabilidade do uso de sistemas de inferência adaptativos <i>Neuro-Fuzzy</i> para previsão da produtividade de trigo sob diferentes regimes de adubação nitrogenada. |
| 14 | (Freitas et al., 2015) | Caracterizações anatômica e físico-mecânica da madeira de <i>Liquidambar</i> sp. | Este artigo contribuiu significativamente ao fornecer uma caracterização abrangente das propriedades anatômicas e físico-mecânicas da madeira de <i>Liquidambar</i> sp. proveniente de árvores com oito anos de idade. |
| 15 | (Leonardi et al., 2015) | <i>Eucalyptus urograndis</i> stem proteome is responsive to short-term cold stress | Este artigo apresenta como principal contribuição a caracterização inicial das respostas moleculares do <i>Eucalyptus urograndis</i> ao estresse térmico, especialmente ao frio, por meio da análise proteômica do caule. |
| 16 | (Chiarello et al., 2016) | Production of cellulosic ethanol from steam-exploded <i>Eucalyptus</i> | O artigo traz uma contribuição expressiva ao demonstrar avanços no processo de produção de etanol celulósico a partir de biomassa |

| | | | |
|----|---|---|--|
| | | urograndis and sugarcane bagasse at high total solids and low enzyme loadings | lignocelulósica, utilizando materiais de <i>Eucalyptus urograndis</i> e bagaço de cana-de-açúcar submetidos à explosão a vapor. |
| 17 | (Medeiros Neto; Paes; Segundinho, 2016) | Determinações dos módulos de elasticidade e ruptura de madeiras por técnicas não destrutivas e destrutiva | O artigo trouxe uma contribuição importante ao demonstrar a viabilidade do uso de técnicas não destrutivas, baseadas em frequências de vibração (longitudinal e transversal) e <i>stress wave</i> , para avaliar a rigidez e resistência da madeira de quatro espécies florestais: eucalipto (<i>Corymbia citriodora</i>), louro preto (<i>Cordia alliodora</i>), massaranduba (<i>Manilkara</i> sp.) e pau-brasil (<i>Caesalpinia echinata</i>). |
| 18 | (Xavier et al., 2016) | Efeito do teor de umidade e da direção de carregamento na resistência de ligações pregadas em madeiras de reflorestamento | O artigo trouxe uma contribuição significativa ao avaliar, de forma detalhada, como a direção de carregamento (paralela ou perpendicular às fibras) e o teor de umidade afetam a resistência de ligações pregadas em madeiras de <i>Corymbia citriodora</i> , <i>Eucalyptus pellita</i> e <i>Eucalyptus paniculata</i> . |
| 19 | (Jadidi et al., 2019) | Short-Term Electric Power Demand Forecasting Using NSGA II-ANFIS Model | Este artigo contribui significativamente para o aprimoramento da previsão de carga (<i>load forecasting</i>) em redes inteligentes de energia elétrica ao propor um algoritmo híbrido que combina técnicas de inteligência artificial e métodos de otimização evolutiva. |
| 20 | (Silva; Silva, 2020) | Modelagem <i>Fuzzy</i> com Técnicas de Agrupamento <i>Fuzzy</i> e Estruturas <i>Neuro-Fuzzy</i> | O artigo apresenta como principal contribuição o desenvolvimento e avaliação de um processo de modelagem <i>Fuzzy</i> para sistemas complexos, utilizando técnicas de agrupamento <i>Fuzzy</i> (FC-Means e Subtractive Cluster) seguidas da otimização dos resultados em um sistema <i>Neuro-Fuzzy</i> . |
| 21 | (Stefenon et al., 2021) | Hybrid Wavelet Stacking Ensemble Model for Insulators Contamination Forecasting | Este artigo apresenta uma contribuição relevante para a identificação preditiva de falhas em isoladores de porcelana de 13,8 kV, perfil pino, em sistemas elétricos, por meio do uso de equipamentos de ultrassom aliados a técnicas modernas de aprendizado de máquina. |
| 22 | (Nogueira et al., 2023) | Experimental study on Full-Scale glulam beams manufactured with <i>Eucalyptus urograndis</i> | O artigo contribuiu significativamente ao demonstrar a viabilidade do uso do híbrido <i>Eucalyptus urograndis</i> na produção de madeira laminada colada (glulam), destacando-o como uma alternativa promissora de matéria-prima para produtos de madeira. |
| 23 | (Godinho; Frigo; Caneppele, 2023) | Modelagem <i>Neuro-Fuzzy</i> na fermentação alcoólica | O artigo apresenta uma contribuição relevante ao aplicar modelagens matemáticas baseadas em Lógica <i>Fuzzy</i> e Inteligência Artificial <i>Neuro-Fuzzy</i> para otimizar o processo produtivo da fermentação alcoólica do mosto de cana-de-açúcar. |
| 24 | (Godinho et al., 2024) | Modeling the evaluation of methods for determining the basic density of wood in forest species based on data from a <i>Neuro-Fuzzy</i> inference system | O artigo apresenta uma importante contribuição ao aplicar sistemas <i>Neuro-Fuzzy</i> , em particular o ANFIS (<i>Adaptive Neuro-Fuzzy Inference System</i>), para prever a densidade básica de diferentes espécies arbóreas sob influência de múltiplos fatores. |
| 25 | (Godinho; Caneppele; Floriano, 2024) | Application of <i>Neuro-Fuzzy</i> to the elephant grass production process: | Por meio de uma Revisão Bibliográfica Sistemática, o estudo mapeou oportunidades e identificou que a integração de sistemas <i>Neuro-Fuzzy</i> em processos laboratoriais e industriais |

| | | | |
|----|-------------------------------------|---|---|
| | | A systematic bibliographic review | permite obter modelos preditivos e de controle mais precisos e eficientes para o setor bioenergético. |
| 26 | (Godinho; Fermino; Barreiros, 2025) | Kinetic modeling and <i>Neuro-Fuzzy</i> application in ethanol production | O artigo apresenta como principal contribuição a utilização integrada de modelagem cinética e técnicas <i>Neuro-Fuzzy</i> , especificamente o sistema ANFIS (Adaptive <i>Neuro-Fuzzy</i> Inference System), para otimizar o processo de produção de etanol a partir de caldo de cana-de-açúcar. |


Fonte: Própria autoria

A Tabela 4 apresenta a relação completa dos 26 artigos selecionados para esta pesquisa, destacando a contribuição específica de cada um para o avanço da comunidade acadêmica.

Com base nos critérios adotados nesta revisão sistemática, foi possível identificar um avanço significativo nas produções científicas relacionadas à aplicação da *Neuro-Fuzzy* como modelo eficiente para otimizar a produção, buscando reduzir custos no processo de termorretificação da madeira. Ressalta-se que esta pesquisa apresenta um caráter inédito ao aplicar a *Neuro-Fuzzy* na otimização da termorretificação da madeira de eucalipto, o que evidencia a relevância e a contribuição inovadora deste trabalho.

A Figura 2, apresenta o número de publicações por ano, foram encontrados 26 documentos. Destes, 26 foram publicados nos últimos quinze anos (2010 a 2025), o que demonstra o avanço e relevância da temática abordada.

Figura 2 – Número de documentos científicos publicados por ano



Fonte: Próprio autor.

Os dados referentes (Figura 2) à quantidade de publicações por ano indicam uma variação significativa ao longo do período analisado, totalizando 26 artigos entre 2010 e 2025. Observa-se um pico inicial em 2010, com 7 publicações, seguido por uma redução e estabilização em níveis mais baixos nos anos seguintes, com pequenas oscilações entre 1 e 3 publicações anuais. Alguns anos, como 2012, 2017, 2018 e 2022, não registraram publicações. A partir de 2019, há uma leve retomada na produção, mantendo-se em torno de 1 a 2 artigos por ano. Essa distribuição sugere que o tema tem recebido atenção constante, embora com variações, refletindo possíveis mudanças no interesse da comunidade acadêmica ou na disponibilidade de pesquisas específicas. O total acumulado de 26 artigos demonstra um corpo razoável de literatura que fundamenta a pesquisa, permitindo uma análise consistente e atualizada do tema.

A Figura 3 apresenta uma nuvem de palavras desenvolvida a partir das palavras-chave extraídas dos artigos selecionados na pesquisa. Essa visualização destaca os termos mais frequentes e relevantes, facilitando a identificação dos principais temas abordados na literatura analisada e contribuindo para uma compreensão mais clara das tendências e focos de estudo dentro do campo investigado.

Figura 3 – Nuvem de palavras



Fonte: Próprio autor.

Para a produção da nuvem de palavras (Figura 3) foi realizada uma análise quantitativa das palavras-chave extraídas dos artigos selecionados na pesquisa. Cada termo foi contabilizado conforme sua frequência estimada de ocorrência, destacando-se aqueles mais recorrentes, como "Sistema *Neuro-Fuzzy*" (12 ocorrências), "Termorretificação" e "Propriedades físicas" (9 ocorrências cada), além de outros termos relevantes relacionados à madeira, ao tratamento térmico e à inteligência artificial.

Essa abordagem permitiu representar visualmente, por meio da nuvem de palavras, a importância relativa de cada conceito, facilitando a identificação dos principais focos temáticos da literatura analisada. A nuvem foi gerada utilizando ferramentas que atribuem maior destaque (tamanho e cor) às palavras com maior frequência, proporcionando uma visão clara e intuitiva das tendências e áreas de maior interesse na pesquisa.

Segundo (GODINHO; CANEPPELE & FLORIANO, 2024), que realizou uma revisão bibliográfica sistemática, apresentou a importância da metodologia *Neuro-Fuzzy*, que combina redes neurais e lógica *Fuzzy*, é uma ferramenta promissora para melhorar a quantificação química da celulose do capim-elefante, otimizando processos laboratoriais e produtivos na produção de bioetanol a partir da biomassa.

Segundo (GODINHO et al., 2024), a aplicação do modelo *Neuro-Fuzzy* (ANFIS) demonstrou alta precisão na predição da densidade básica de espécies florestais, combinando redes neurais e lógica *Fuzzy* para otimizar processos produtivos. A pesquisa, baseada em dados experimentais e validação rigorosa, evidenciou que o sistema *Neuro-Fuzzy* é uma ferramenta eficiente, rápida e de baixo custo para modelagem em bioenergia e produção de bioetanol.

1.5 CONCLUSÕES

A partir da pesquisa realizada por meio da RBS, foi possível identificar uma variedade de aplicações e metodologias relacionadas ao uso de sistemas *Neuro-Fuzzy* em diferentes áreas do conhecimento. No entanto, os resultados também evidenciam o caráter inédito desta investigação no que se refere à aplicação da abordagem *Neuro-Fuzzy* no processo de termorretificação da madeira, com o objetivo de modelar dados associados às propriedades envolvidas nesse tratamento.

Dos 26 documentos analisados nesta pesquisa, 100% correspondem a artigos científicos, o que evidencia a relevância acadêmica das investigações voltadas à modelagem matemática com o uso de Inteligência Artificial, em especial por meio da abordagem *Neuro-Fuzzy*. Da mesma forma, observa-se um crescente interesse da comunidade científica pelas pesquisas relacionadas à termorreificação da madeira, que vêm ganhando destaque e sendo cada vez mais exploradas e desenvolvidas por especialistas da área nos últimos anos.

Embora não tenham sido encontrados artigos que tratem especificamente da aplicabilidade da modelagem *Neuro-Fuzzy* no contexto da termorreificação da madeira, essa lacuna evidencia a existência de oportunidades para futuras investigações na área. Dessa forma, abre-se espaço para o desenvolvimento de pesquisas que explorem a utilização de sistemas *Neuro-Fuzzy* como ferramenta de otimização das variáveis independentes envolvidas nos processos de termorreificação da madeira, aproveitando as metodologias já consolidadas em outras áreas para impulsionar avanços nesse campo de estudo.

Para trabalhos futuros, recomenda-se a realização de uma análise mais aprofundada sobre cada um dos 26 documentos identificados, a fim de extrair informações detalhadas que possam subsidiar novas linhas de investigação. Entre as possibilidades, destaca-se o desenvolvimento de estudos voltados a propriedades específicas da termorreificação da madeira por meio da utilização do *software Python*, integrando e consolidando bases de dados experimentais. Além disso, sugere-se a aplicação de modelos *Neuro-Fuzzy* para a modelagem matemática das relações entre as variáveis de entrada e saída do processo, promovendo abordagens inovadoras e o avanço científico na área.

REFERÊNCIAS

ALAHMED, Ahmed S.; AL-MUHAINI, Mohammad M. An intelligent load priority list-based integrated energy management system in microgrids. **Electric Power Systems Research**, v. 185, 1 ago. 2020.

ALMEIDA, Diego Henrique de *et al.* Comparação entre valores de ensaios experimentais e calculados da resistência ao embutimento da madeira de *Pinus taeda* L. **Revista Árvore**, v. 38, n. 2, p. 347–352, abr. 2014.

ANDRADE, Guilherme de Castro *et al.* Site evaluation and productivity of a 3-year old stand of *Eucalyptus urograndis* in São Paulo, Brazil. **Pesquisa Florestal Brasileira**, v. 31, n. 68, p. 331, 2011.

ANTONIAZZI, Matheus Augusto Santos; GODINHO, Emmanuel Zullo. COMPREENSÃO E APLICAÇÃO DO NÚMERO DE EULER : Uma revisão sistemática bibliográfica. **Sodebras**, v. 18, n. 1, p. 139–148, 2023.

ARAÚJO, Fabíola Oliveira Lino de *et al.* Constituintes químicos e efeito ecotoxicológico do óleo volátil de folhas de *Eucalyptus urograndis* (Mirtaceae). **Química Nova**, v. 33, n. 7, p. 1510–1513, 2010.

ASGHAR, Furqan; TALHA, Muhammad; KIM, Sung Ho. Robust frequency and voltage stability control strategy for standalone AC/DC hybrid microgrid. **Energies**, v. 10, n. 6, 1 jun. 2017.

BALBINOT, Alexandre; FAVIEIRO, Gabriela. A *Neuro-Fuzzy* system for characterization of arm movements. **Sensors**, v. 13, n. 2, p. 2613–2630, 21 fev. 2013.

BARREIROS, Ricardo Marques *et al.* Efeitos da termorretificação da madeira em clones de eucalipto. *In: Open Science Research IX*. Científica ed. São Paulo, SP: [S.n.]. p. 1443–1455.

BATISTELA, Gislaine Cristina; SABBATINO, Leticia Ayumi; SIMÕES, Danilo. Avaliação econômica de projeto: uma abordagem da lógica *Fuzzy* para tomada de decisão. **C.Q.D.- Revista Eletrônica Paulista de Matemática**, v. 17, p. 255–266, 2020.

BELTRAME, Rafael *et al.* Propriedades físico-mecânicas da madeira de *Araucaria angustifolia* (Bertol.) em três estratos fitossociológicos. **Revista Ciência da Madeira - RCM**, v. 1, n. 2, p. 54–69, 2010.

BLOIS, Henrique Dias *et al.* Silvicultura: Cenários Prospectivos para Geração de Energia Elétrica. **Revista de Gestão Ambiental e Sustentabilidade**, v. 6, n. 1, p. 140–159, 2017.

CARDOSO, Marco Túlio *et al.* Efeito da combustão dos gases da carbonização no rendimento gravimétrico da madeira de *Eucalyptus* sp. **Revista Ciência da Madeira - RCM**, v. 1, n. 2, p. 20–31, 2010.

CHIARELLO, Luana M. *et al.* Production of cellulosic ethanol from steam-exploded *Eucalyptus urograndis* and sugarcane bagasse at high total solids and low enzyme loadings. **Sustainable Chemical Processes**, v. 4, n. 1, p. 15, 16 dez. 2016.

CONFORTO, Edivandro Carlos; AMARAL, Daniel Capaldo; SILVA, Sérgio Luis Da. Roteiro para revisão bibliográfica sistemática : aplicação no desenvolvimento de produtos e gerenciamento de projetos. *In: 2011*. Disponível em: <<http://www.ufrgs.br/cbgdp2011/downloads/9149.pdf>>

CUNHA, Cláudia Silveira da; ALVES, Patrícia Ferreira; CUNHA, Pedro Luiz Pinto da. **Manual REVISÃO BIBLIOGRÁFICA SISTEMÁTICA INTEGRATIVA: a pesquisa baseada em evidências**. GRUPO ANIM ed. Belo Horizonte: Equipe EAD, 2011.

EHTERAM, Mohammad *et al.* An improved model based on the support vector machine and cuckoo algorithm for simulating reference evapotranspiration. **PLoS ONE**, v. 14, n. 5, 1 maio 2019.

FARIA, JÚLIO CÉZAR TANNURE. **Crescimento inicial de espécies florestais em plantios mistos em Alegre-Es.** [S.l.]: Monografia (Trabalho de Conclusão de Curso em Engenharia Florestal) - Universidade Federal do Espírito Santo, 2012.

FERNANDES, Flávia Roberta *et al.* Comunidades de prática: uma revisão bibliográfica sistemática sobre casos de aplicação organizacional. **AtoZ: novas práticas em informação e conhecimento**, v. 5, n. 1, p. 44, 2016.

FERREIRA, Bruno Santos; RANGEL, Elidiane Cipriano; CAMPOS, Cristiane Inácio de. Efeito da termorreificação na qualidade de colagem de lâminas de madeira para a produção de compensado. **Ciência Florestal**, v. 28, n. 1, p. 274–282, 2018.

FERREIRA, Mayra Daniela *et al.* Propriedades Físicas E Mecânicas Da Madeira De Angelim-Pedra Submetida a Tratamento Térmico. **Tecnologia em Metalurgia Materiais e Mineração**, v. 16, n. 1, p. 3–7, 2019a.

FERREIRA, Mayra Daniela *et al.* Propriedades Físicas E Mecânicas Da Madeira De Angelim-Pedra Submetida a Tratamento Térmico. **Tecnologia em Metalurgia Materiais e Mineração**, v. 16, n. 1, p. 3–7, 2019b.

FLORESTAR. **PANORAMA DA SILVICULTURA PAULISTA 2024**. Disponível em: <https://florestar.org.br/wp-content/uploads/2024/07/Floresta-SP_2_final_2_e.pdf>. Acesso em: 15 jul. 2025.

FREITAS, Thaís Pereira *et al.* Caracterizações anatômica e físico-mecânica da madeira de Liquidambar sp. **Floresta**, v. 45, n. 4, p. 723–734, 2015.

FURLONG, Vitor Badiale *et al.* Estimating microalgae *Synechococcus nidulans* daily biomass concentration using *Neuro-Fuzzy* network. **Ciência e Tecnologia de Alimentos**, v. 33, p. 142–147, fev. 2013.

GODINHO, Emmanuel Zullo *et al.* Modelagem *Fuzzy* da produtividade da cebola sob diferentes dosagens do fertilizante de solo e fertilizante foliar. **Sodebras**, v. 18, n. 205, p. 32–40, 2023.

GODINHO, Emmanuel Zullo *et al.* Modeling the evaluation of methods for determining the basic density of wood in forest species based on data from a *Neuro-Fuzzy* inference system. **Brazilian Journal of Biosystems Engineering**, v. 18, n. December, p. 1–6, 2024.

GODINHO, Emmanuel Zullo; CANEPPELE, Fernando De Lima. Modelagem *Fuzzy* na produção de bioetanol de capim-elefante. **Scientific Journal of Environmental Sciences and Biotechnology**, v. 8, n. 1, p. 51–56, 2022.

GODINHO, Emmanuel Zullo; CANEPPELE, Fernando de Lima; FLORIANO, Camille. Application of *Neuro-Fuzzy* to the elephant grass production process: A systematic bibliographic review. **Research, Society and Development**, v. 13, n. 2, p. e6613244927, 2024.

GODINHO, Emmanuel Zullo; CANEPPELE, Fernando de Lima; GASPAROTTO, Helio Vagner. Avaliação do pré-tratamento hidrotérmico alcalino de gramíneas *Pennisetum* spp . e *Panicum* spp . **Bioenergia em revista: diálogos**, v. 11, p. 43–51, 2021.

GODINHO, Emmanuel Zullo; CANEPPELE, Fernando De Lima; GASPAROTTO, Hélio Vagner. Original Research Article Use of *Fuzzy* logic to optimize fertilizer application on radish. **Trends in Horticultures**, v. 5, n. 2, p. 55–60, 2022.

GODINHO, Emmanuel Zullo; FERMINO, Caetano Dartiere Zulian; BARREIROS, Ricardo Marques. Kinetic modeling and *Neuro-Fuzzy* application in ethanol production. **Brazilian Journal of Biosystems Engineering**, v. 19, n. February, p. 1–5, 2025.

GODINHO, Emmanuel Zullo; FRIGO, Murilo Miceno; CANEPPELE, Fernando de Lima. Modelagem *Neuro-Fuzzy* na fermentação alcoólica. **Revista Acadêmica Online**, v. IX, n. 46, p. 1–12, 2023.

GODINHO, Emmanuel Zullo; GASPAROTTO, Helio Vagner; CANEPPELE, Fernando de Lima. Lógica *Fuzzy* na Agricultura: Breve Histórico. **Cadernos de Educação Tecnologia e Sociedade**, v. 15, n. 1, p. 126–139, 2022.

GONÇALVES, Laercio B.; LETA, Fabiana R. Macroscopic rock texture image classification using a hierarchical *Neuro-Fuzzy* class method. **Mathematical Problems in Engineering**, v. 2010, n. 1, 2 jan. 2010.

HORST, Diogo José. **Avaliação da produção energética a partir de ligninas contidas em biomassas**. [S.l.]: Dissertação (Mestrado em Gestão da Produção e Manutenção) - Universidade Tecnológica Federal do Paraná, 2013.

IBA. **IBA - Indústria Brasileira de Árvores**. Disponível em: <<https://iba.org/dados-estatisticos>>. Acesso em: 15 jul. 2025.

IBGE, Instituto Brasileiro de Geografia. **PEVS - Produção da Extração Vegetal e da Silvicultura**. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9105-producao-da-extracao-vegetal-e-da-silvicultura.html>>. Acesso em: 15 jul. 2025.

IMAI, Hugo Eiji *et al.* Simulação computacional como ferramenta de otimização na geração de energia solar fotovoltaica. **urbe. Revista Brasileira de Gestão Urbana**, v. 12, n. 1, p. e20190343, 2020.

JADIDI, Aydin *et al.* Short-Term Electric Power Demand Forecasting Using NSGA II-ANFIS Model. **Energies**, v. 12, n. 10, p. 1891, 17 maio 2019.

LEONARDI, Gabriela de Almeida *et al.* Eucalyptus urograndis stem proteome is responsive to short-term cold stress. **Genetics and Molecular Biology**, v. 38, n. 2, p. 191–198, jun. 2015.

MARRO, Alessandro Assi *et al.* **Lógica Fuzzy: Conceitos e aplicações. Departamento de Informática e Matemática Aplicada (DIMAp) Universidade Federal do Rio Grande do Norte (UFRN)**Natal-RN, 2010.

MEDEIROS NETO, Pedro Nicó; PAES, Juarez Benigno; SEGUNDINHO, Pedro Gutemberg de Alcântara. Determinações dos módulos de elasticidade e ruptura de madeiras por técnicas não destrutivas e destrutiva. **Scientia Forestalis**, v. 44, n. 111, 3 out. 2016.

NOGUEIRA, Rodrigo de Souza *et al.* Experimental study on Full-Scale glulam beams

manufactured with *Eucalyptus urograndis*. **Maderas: Ciencia y Tecnologia**, v. 25, n. 25, p. 1–12, 2023.

NUNES, Jéssica Letícia Thomas *et al.* MELHORIA DO PROCESSO PRODUTIVO POR MEIO DE OTIMIZAÇÃO DE PROCESSO DE ENVASE. **Engepro**, v. 2, n. 1, p. 105–122, 2018.

PEIXOTO, Maurício A. P. BIOESTATÍSTICA: PORQUE, O QUE É COMO ENSINAR. **Revista Brasileira de Educação Médica**, v. 20, n. 1, p. 7–14, abr. 1996.

PERTUZZATTI, Anderson *et al.* Propriedades Físicas da Madeira de *Pinus elliottii* var. *elliottii* Termorretrificada Sob Diferentes Atmosferas. **Revista Ciência da Madeira - RCM**, v. 7, n. 1, p. 7–15, 2016.

SANTOS, Karoline Eduarda *et al.* Geoestatística e Geoprocessamento na tomada de decisão do uso de insumos em uma pastagem. **Brazilian Journal of Biosystems Engineering v**, v. 11, n. 3, p. 294–307, 2017.

SILVA, Aldo A. V. da *et al.* Estimativa da produtividade de trigo em função da adubação nitrogenada utilizando modelagem *Neuro Fuzzy*. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 2, p. 180–187, fev. 2014.

SILVA, Evane da; ROCHA, Carlos Roberto. Eucalipto e capim elefante: características e potencial produtivo de biomassa. **Revista Agrogeoambiental**, v. 2, n. 1, p. 143–152, abr. 2010.

SILVA, Inara; SILVA, Aldo. **Modelagem Fuzzy com Técnicas de Agrupamento Fuzzy e Estruturas Neuro-Fuzzy**. , 2020.

STANGERLIN, Diego Martins *et al.* Propriedades de flexão estática da madeira de *Carya illinoensis* em duas condições de umidade. **Revista Ciência da Madeira - RCM, Pelotas**, v. 1, n. 2, p. 70–79, 30 nov. 2010.

STEFENON, Stefano Frizzo *et al.* Hybrid Wavelet Stacking Ensemble Model for Insulators Contamination Forecasting. **IEEE Access**, v. 9, p. 66387–66397, 2021.

VIERA, Márcio; SCHUMACHER, Mauro Valdir; LIBERALESSO, Edenilson. Crescimento e produtividade de povoamentos monoespecíficos e mistos de Eucalipto e Acácia-negra. **Pesquisa Agropecuária Tropical**, v. 41, n. 3, 6 jul. 2011.

VIVIAN, M. A. *et al.* Resistência da madeira de Canafístula (*Peltophorum dubium* (Spreng.) Taub.) ao PSF e a umidade de equilíbrio. **Revista Ciência da Madeira - RCM**, v. 1, n. 1, p. 11–24, 31 maio 2010a.

VIVIAN, Magno Alan *et al.* Efeito de pré-tratamentos na taxa de secagem da madeira de *Hovenia dulcis* Thunb. **Ciência da Madeira**, v. 1, n. 2, p. 32–43, 2010b.

XAVIER, C. N. *et al.* Efeito do teor de umidade e da direção de carregamento na resistência de ligações pregadas em madeiras de reflorestamento. **Revista Ciência da Madeira - RCM**, v. 7, n. 1, p. 51–60, 30 abr. 2016.

CAPÍTULO 2

ANÁLISE DAS SUPERFÍCIES DE RESPOSTA E DESEMPENHO DOS MODELOS PARA PREVISÃO DE PROPRIEDADES

2.1 INTRODUÇÃO

As propriedades da madeira desempenham um papel fundamental na sua utilização em diferentes aplicações industriais e tecnológicas, dentre as propriedades físicas mais relevantes destacam-se a densidade, a estabilidade dimensional, a porosidade e a higroscopicidade (FERREIRA et al., 2019).

A densidade influencia diretamente a resistência mecânica, o peso e o comportamento da madeira durante o processamento e o uso final, já a estabilidade dimensional está relacionada à variação de volume em função das mudanças de umidade, sendo crucial para garantir a durabilidade e o desempenho estrutural em ambientes sujeitos a variações climáticas (BARREIROS et al., 2022). Além disso, a porosidade e a capacidade de absorção de água afetam a trabalhabilidade, a impregnação com produtos químicos e a resistência ao ataque de agentes biológicos.

Nas propriedades mecânicas, destacam-se a resistência à compressão, à tração, à flexão e ao cisalhamento, que determinam a capacidade da madeira de suportar esforços em diferentes direções, sendo que essas propriedades são influenciadas por fatores como a espécie, a idade, a presença de defeitos e o teor de umidade (BELTRAME et al., 2010).

A avaliação criteriosa dessas características é essencial para a seleção adequada da madeira em projetos de engenharia civil, construção, mobiliário e outros setores, assegurando desempenho, segurança e longevidade das estruturas e produtos desenvolvidos, tendo como ponto fundamental a temperatura (FERREIRA; RANGEL & CAMPOS, 2018).

A temperatura desempenha papel fundamental nos processos industriais envolvendo madeira, influenciando diretamente tanto as propriedades físicas quanto mecânicas do material (PERTUZZATTI et al., 2016). Durante o tratamento térmico, a aplicação de calor em níveis controlados pode promover melhorias significativas na estabilidade dimensional, reduzindo o inchamento e a higroscopicidade da madeira (FERREIRA et al., 2019).

Esse processo também contribui para o aumento da vida útil do produto final, tornando-o mais resistente a variações ambientais e menos suscetível a deformações, no entanto, é importante ressaltar que temperaturas elevadas podem ocasionar a degradação de componentes químicos essenciais, como as hemiceluloses, resultando em perda de massa e diminuição da densidade aparente do material (MELO et al., 2013).

A otimização dos processos produtivos na indústria da madeira é essencial para elevar a eficiência operacional e, conseqüentemente, melhorar os resultados financeiros da empresa (NUNES et al., 2018). Portanto, a otimização do processo produtivo não é apenas uma questão técnica, mas um fator decisivo para a competitividade e a sustentabilidade econômica da indústria madeireira.

A *Neuro-Fuzzy* é uma técnica híbrida que combina a capacidade de aprendizado das redes neurais artificiais com a lógica *Fuzzy*, que trabalha com conceitos imprecisos e linguagens naturais (GODINHO; FRIGO & CANEPPELE, 2023). No contexto produtivo, a *Neuro-Fuzzy* é importante porque possibilita a otimização e o controle adaptativo de processos, promovendo maior eficiência, redução de custos e melhoria da qualidade do produto final (GODINHO et al., 2023).

Silva et al. (2014) citaram que a modelagem *Neuro-Fuzzy* pode estimar a produtividade do trigo em função da adubação nitrogenada, prevendo assim conhecer novos valores de produção de trigo para diferentes doses de nitrogênio, apresentando um erro de predição inferior ao de métodos tradicionais, como a aproximação quadrática, esse estudo demonstrou a viabilidade do sistema para apoiar decisões agrícolas, otimizando o uso de insumos e potencializando a produtividade.

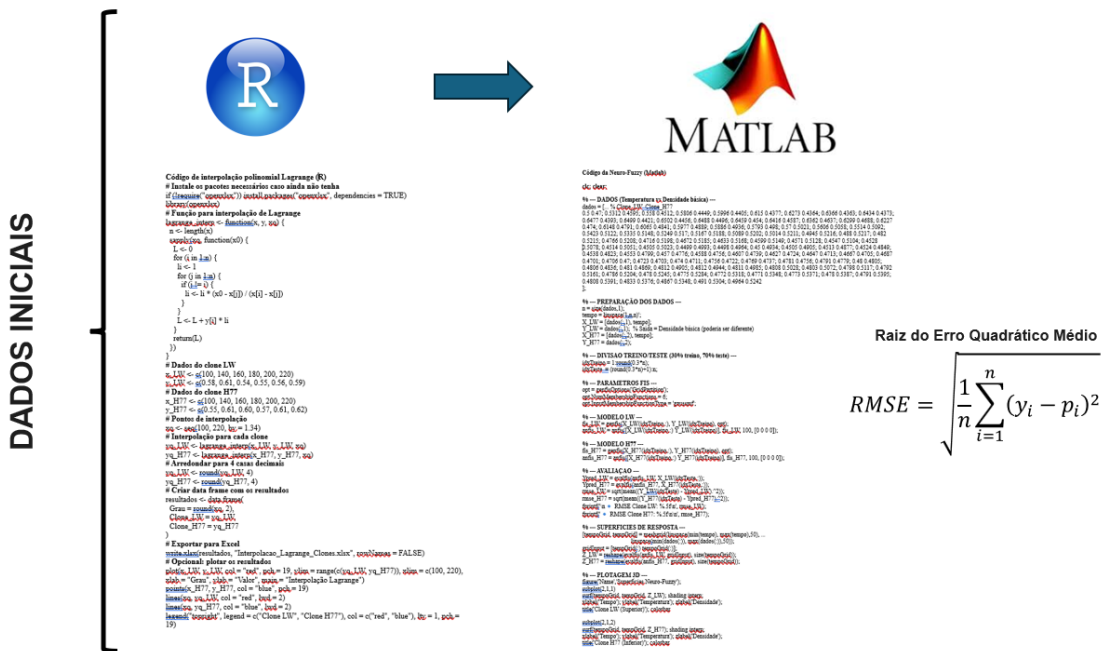
Godinho; Frigo; Caneppele, (2023) estudaram dois modelos matemáticos para otimizar a fermentação alcoólica do mosto de cana-de-açúcar, utilizando Lógica *Fuzzy* e o sistema híbrido *Neuro-Fuzzy* (ANFIS), demonstrando que o modelo *Neuro-Fuzzy* apresentou maior precisão na predição do processo, especialmente na dosagem de biológicos e controle de temperatura, resultando em fermentação eficiente a 10,2 °GL com 10 g de biológico a 94 °C.

Diante desse contexto, o objetivo desta pesquisa foi desenvolver uma modelagem matemática aplicando o método *Fuzzy* e a Inteligência Artificial da Lógica *Fuzzy* (*Neuro-Fuzzy*), otimizando o processo de termorretificação da madeira em dois clones híbridos de eucalipto, buscando-se prever a busca pela melhor temperatura (°C) e o melhor tempo de termorretificação.

2.2 MATERIAL E MÉTODOS

A Figura 1 ilustra o fluxograma de metrologia experimental para modelagem *Neuro-Fuzzy* dos indicadores de termorreificação de 2 clones de madeira, ilustrando o processo metodológico adotado, que se iniciou com o desenvolvimento de um código em R para interpolação polinomial quadrática utilizando o método de Lagrange, com o objetivo de ajustar os dados experimentais e gerar os valores previstos. Em seguida, foi utilizado o software MATLAB para a construção de um sistema *Neuro-Fuzzy*, visando aprimorar a modelagem dos dados por meio de técnicas de inteligência artificial. Por fim, aplicou-se a métrica estatística da Raiz do Erro Quadrático Médio (RMSE) para avaliar a precisão dos modelos gerados, conforme evidenciado pela fórmula apresentada no canto inferior da imagem. A figura demonstra, portanto, a integração entre métodos matemáticos clássicos e abordagens computacionais avançadas na análise de dados.

Figura 1 – Fluxograma de metrologia experimental



Fonte: Próprio autor.

2.2.1 Interpolação polinomial pelo método de Lagrange

No presente estudo, foi utilizado o *software* R para o desenvolvimento de um código específico (Apêndice A) com o objetivo de realizar a interpolação polinomial dos dados experimentais, aplicando o método de Lagrange.

O *software* R oferece diversos benefícios em aplicações estatísticas e matemáticas, sendo amplamente reconhecido por sua flexibilidade, robustez e ampla gama de recursos, entre suas principais vantagens, destaca-se o fato de ser uma plataforma gratuita e de código aberto, o que facilita o acesso e o compartilhamento de métodos inovadores (Ramos et al., 2019).

Este *software* possui uma vasta coleção de pacotes especializados para análise estatística, modelagem matemática, simulações, visualização de dados e *machine learning*, permitindo que usuários de diferentes níveis de experiência realizem desde análises básicas até estudos avançados (Portela; Oliveira; Viola, 2023). Além disso, destaca-se pela sua alta adaptabilidade, favorecendo a reprodução e automação de análises.

O Método de Lagrange para interpolação polinomial consiste em construir um polinômio que passa exatamente por um conjunto de $n + 1$ pontos distintos (x_0, y_0) , (x_1, y_1) , ..., (x_n, y_n) , onde $y_k = f(x_k)$ são os valores conhecidos da função em cada ponto x_k . O polinômio interpolador de Lagrange $P_n(x)$ é único e tem grau no máximo n , a fórmula geral do polinômio de Lagrange é dada pela Equação 1:

$$P_n(x) = \sum_{k=0}^n y_k L_k(x), \quad (1)$$

onde cada polinômio base $L_k(x)$ é definido como (Equação 2):

$$L_k(x) = \prod_{\substack{i=0 \\ i \neq k}}^n \frac{x - x_i}{x_k - x_i}. \quad (2)$$

cada $L_k(x)$ tem a propriedade fundamental de ser igual a 1 no ponto x_k e 0 em todos os outros pontos x_i com $i \neq k$. Isso garante que $P_n(x_k) = y_k$, ou seja, o polinômio passa exatamente pelos pontos dados.

O método de Lagrange foi implementado para construir um polinômio interpolador capaz de representar o comportamento dos dados gerais observados, permitindo a estimativa de valores intermediários com elevado grau de precisão (SCHEMMER, 2013). Esta abordagem apresenta ser eficiente na modelagem do fenômeno estudado, oferecendo uma alternativa robusta e de fácil aplicação para a análise matemática e estatística dos resultados (FERREIRA & SILVA, 2022).

2.2.2 Modelagem Matemática *Neuro-Fuzzy*

Foi desenvolvido um código (Apêndice B) para o *software* MATLAB utilizando o sistema *Neuro-Fuzzy*. Iniciou-se com o treinamento do modelo utilizando 30% dos valores totais de cada clone e, posteriormente, testou-se o restante dos dados (70%) para validar o sistema *Neuro-Fuzzy*.

Para a modelagem específica, estabeleceu-se a utilização de (6) seis funções de pertinência para cada uma das duas variáveis de entrada (Temperatura, em graus Celsius, e Tempo, em minutos), considerando uma variável de saída para cada modelo (Densidade Aparente, Densidade Básica, Perda de Massa, Inchamento Volumétrico Total, Módulo de Ruptura e Módulo de Elasticidade). Após a implementação, foi requisitada a geração de figuras de superfícies de resposta tridimensionais para cada clone pelo sistema.

Foi utilizado o *software* MATLAB, sob licença institucional vinculada ao Grupo de Pesquisa Agroenerbio da Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo (FZEA/USP), para a modelagem matemática dos dados por meio da técnica de sistemas *Neuro-Fuzzy*. Esta abordagem combina a lógica *Fuzzy* com redes neurais artificiais, possibilitando a construção de modelos capazes de lidar com incertezas e não linearidades presentes nos dados experimentais (Nikolovski; Baghaee; Mlakic, 2018).

O ambiente de desenvolvimento do MATLAB, aliado à *toolbox* é específica para sistemas *Neuro-Fuzzy* (*Fuzzy Logic Toolbox*) e permitiu a geração de um sistema adaptativo de inferência capaz de aprender e ajustar-se aos padrões dos dados, contribuindo significativamente para a análise preditiva e a compreensão do comportamento dos fenômenos estudados.

2.2.3 Análise Estatística

Para a validação dos modelos desenvolvidos, foi aplicado o teste estatístico do Erro Quadrático Médio da Raiz (*Root Mean Square Error* – RMSE), conforme Equação 3, amplamente utilizado para avaliar a acurácia de predições em modelagens matemáticas. O RMSE permite quantificar a diferença média entre os valores observados e os valores estimados pelos modelos, sendo uma medida sensível a grandes desvios e, portanto, eficaz na detecção de erros significativos (Carmo; Silva, 2023).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad (3)$$

Onde:

- n é o número de amostras
- y_i é o valor observado para a amostra i
- p_i é o valor previsto pelo modelo para a amostra i

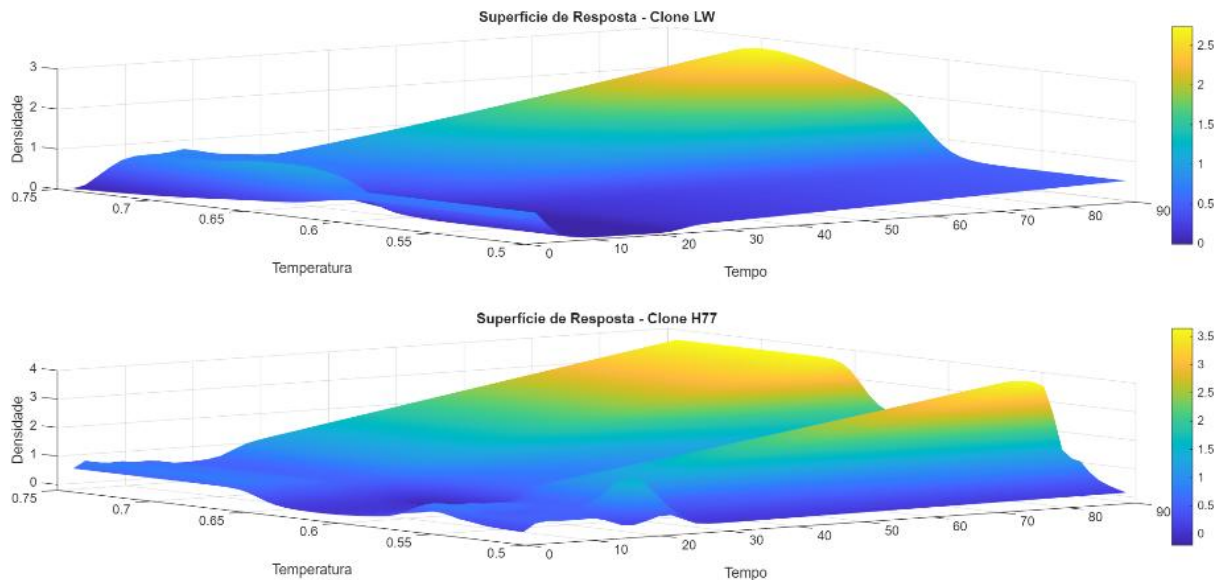
Quanto menor o valor do RMSE, maior é a precisão do modelo em representar os dados reais. Dessa forma, a aplicação desse teste estatístico foi essencial para aferir a qualidade das modelagens obtidas tanto pelo método de interpolação polinomial de Lagrange quanto pelo sistema *Neuro-Fuzzy* (Filho, 2023).

2.3 RESULTADOS E DISCUSSÃO

2.3.1 Densidade Aparente

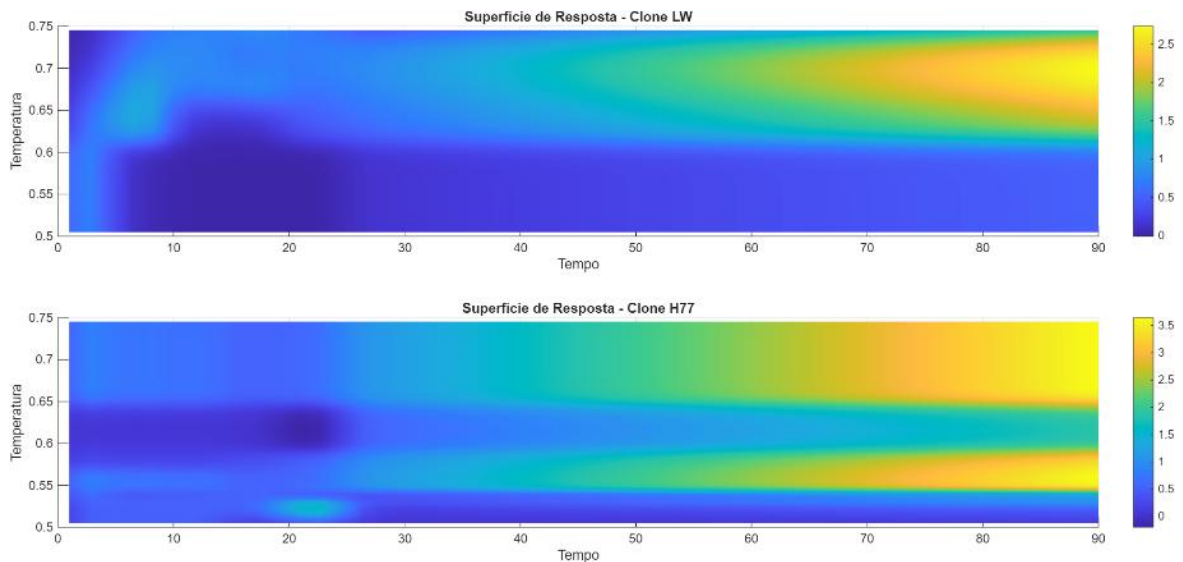
As Figuras a seguir (2 e 3) ilustram a Superfície de Resposta 3D dos Clones LW e H77 para a Densidade Aparente e as Superfícies de Resposta 3D dos mesmos clones visualizadas em projeção superior.

Figura 2 – Superfície de Resposta 3D dos Clones LW e H77 para a Densidade aparente



Fonte: Próprio autor.

Figura 3 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior - Densidade aparente



Fonte: Próprio autor.

As Figuras 2 e 3, mostram que para o clone LW, os melhores resultados de densidade aparente foram observados em tratamentos realizados com tempo de exposição entre 75 e 90 minutos e temperatura variando na faixa de 0,65 a 0,73 C.

Esses parâmetros indicam que a estabilidade e compactação estrutural da madeira do clone LW são significativamente otimizadas dentro desse intervalo de

condições, refletindo em maiores valores de densidade aparente, característica desejada para várias aplicações tecnológicas do material.

No caso do clone H77, nas mesmas figuras, percebe-se a existência de duas faixas de condições ideais para a obtenção de densidade aparente elevada:

- A primeira ocorre com tempo entre 70 e 90 minutos e temperatura variando entre 0,65 e 0,75.
- A segunda abrange tempo entre 75 e 90 minutos e temperatura de 0,55 a 0,60.

Essas variações sugerem que o clone H77 apresenta maior flexibilidade quanto aos parâmetros ótimos do tratamento térmico, sendo capaz de atingir bons resultados de densidade aparente tanto em temperaturas mais altas, quando o tempo é proporcional, quanto em temperaturas moderadamente menores, desde que o tempo também esteja no intervalo mais prolongado.

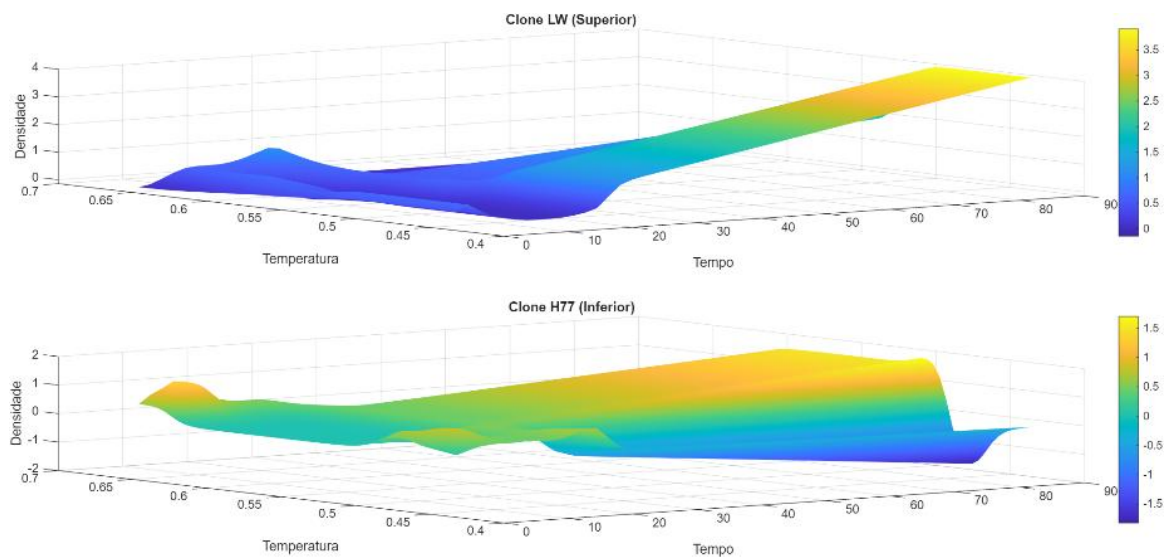
Em síntese, essas observações evidenciam que cada clone reage de modo particular ao ajuste fino do processo de termorretificação, reforçando a importância da personalização dos parâmetros de tratamento para maximizar propriedades como a densidade aparente, em função das características genéticas e estruturais de cada material lignocelulósico.

Estatisticamente o RMSE (*Root Mean Square Error*) da densidade aparente calculado a partir da estatística aplicada aos dados dos clones LW e H77 foi de 0,1007843. O RMSE indicou que, em média, as previsões do modelo diferem dos valores reais da densidade aparente em aproximadamente 0,10 unidades. Quanto menor esse valor, melhor é o ajuste do modelo aos dados, o que demonstra uma boa capacidade do sistema *Neuro-Fuzzy* em captar o comportamento dos clones (Godinho; Fermino; Barreiros, 2025). Reforçando que o modelo apresenta fortemente uma precisão satisfatória com erros moderados e controlados na previsão da densidade aparente.

2.3.2 Densidade Básica

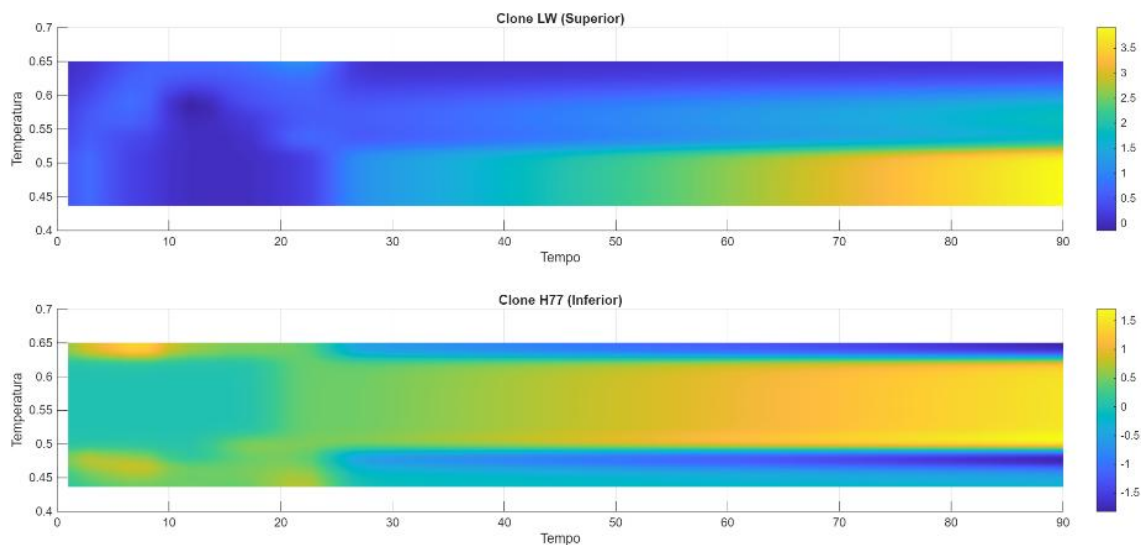
As Figuras a seguir (4 e 5) ilustram a Superfície de Resposta 3D dos Clones LW e H77 para a Densidade Básica e as Superfícies de Resposta 3D dos mesmos clones visualizadas em projeção superior.

Figura 4 – Superfície de Resposta 3D dos Clones LW e H77 para a Densidade básica



Fonte: Próprio autor.

Figura 5 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior - Densidade básica



Fonte: Próprio autor.

A análise dos dados referentes à densidade básica (Figuras 4 e 5) nos clones LW e H77 revela padrões específicos em função do tempo e da temperatura de termorretificação, evidenciando respostas diferenciadas entre os materiais.

Para o clone LW, os melhores resultados de densidade básica ocorrem dentro da faixa de tempo entre 70 e 90 minutos e temperatura entre 0,45 e 0,55. Esses valores sugerem que esse clone responde positivamente a tempos de exposição mais

longos combinados com temperaturas moderadas, podendo favorecer a manutenção ou até o aumento da densidade sem comprometer a estrutura celular da madeira.

Já o clone H77 apresenta dois conjuntos distintos de condições otimizadas para essa mesma propriedade. O primeiro agrupa valores de tempo entre 7 e 10 minutos e temperatura de 0,64 a 0,65, demonstrando que, mesmo em exposições curtas, esse clone pode atingir alta densidade básica sob temperaturas específicas. O segundo intervalo, mais prolongado, ocorre com tempo entre 70 e 90 minutos e temperatura variando de 0,50 a 0,63, indicando que a densidade básica também pode ser favorecida sob tratamentos mais longos e temperaturas mais moderadas.

Esses achados reforçam a influência direta dos parâmetros térmicos na densidade básica dos materiais lignocelulósicos e destacam o comportamento mais versátil do clone H77 frente às condições de termorreificação, diferente do clone LW, que apresenta desempenho otimizado dentro de uma faixa mais restrita. Assim, estratégias ajustadas por clone são essenciais para aperfeiçoar o tratamento térmico e alcançar propriedades físico-mecânicas superiores na madeira modificada termicamente.

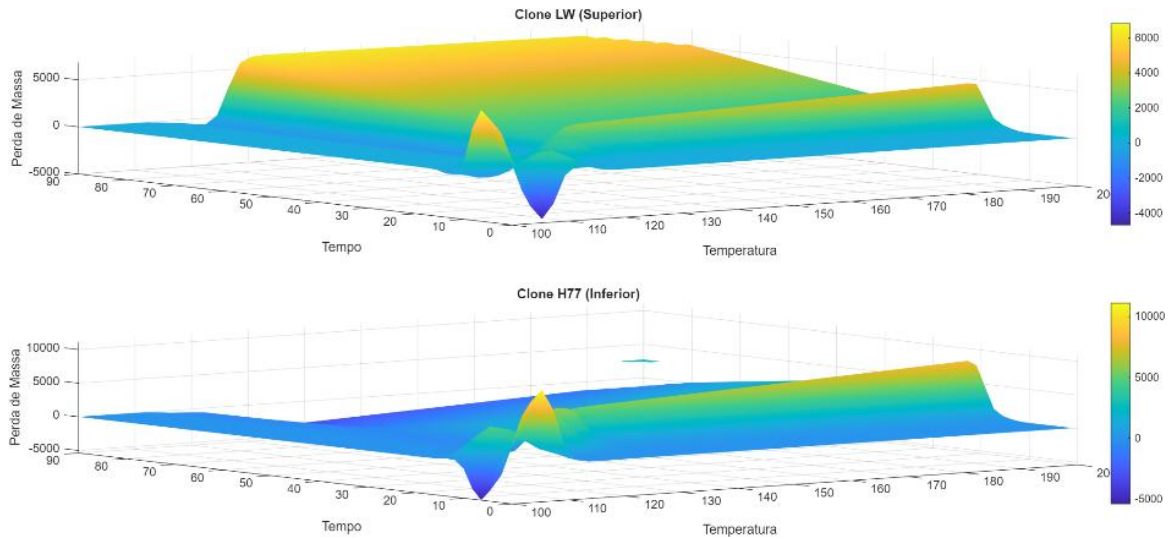
Quando se avalia a estatística, o valor do RMSE obtido 0,08710769, indicou que a diferença média entre os valores observados e previstos da densidade básica nos clones LW e H77 é aproximadamente 0,087 unidades. Esse resultado sugere que o modelo ou a comparação entre os dados dos clones apresentou um erro relativamente baixo, demonstrando boa precisão na estimativa da densidade básica.

Portanto, um RMSE de 0,0871 indica que o sistema *Neuro-Fuzzy* ou a análise realizada conseguiu captar de forma satisfatória o comportamento dos clones, com erros moderados e controlados, o que confere confiabilidade às conclusões extraídas a partir desses dados.

2.3.3 Perda de Massa

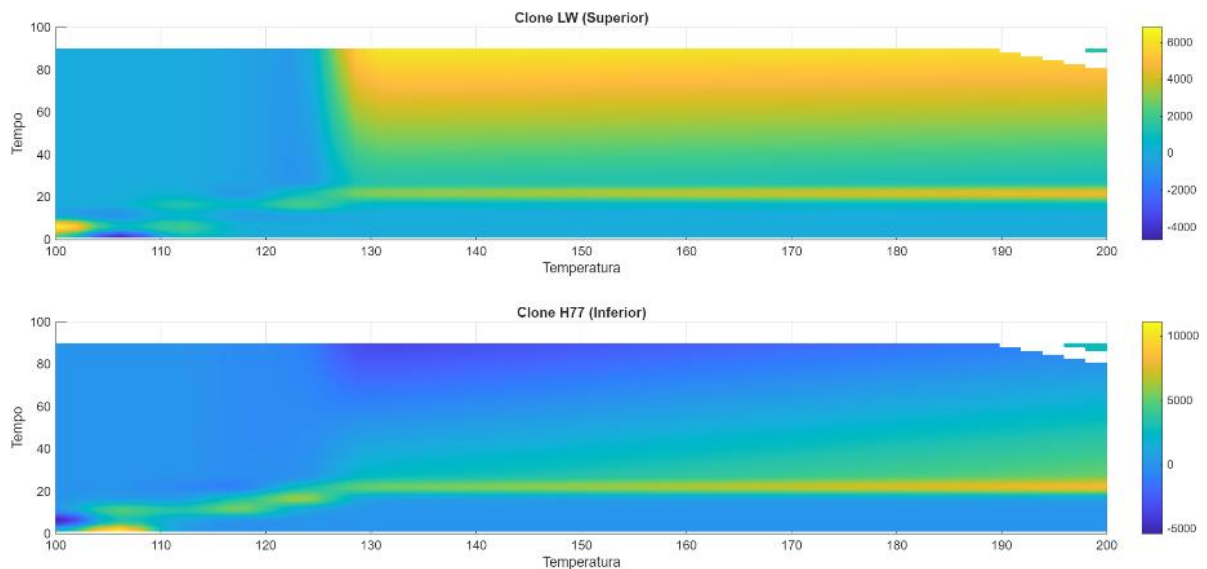
As Figuras a seguir (6 e 7) ilustram a Superfície de Resposta 3D dos Clones LW e H77 para a Perda de massa e as Superfícies de Resposta 3D dos mesmos clones visualizadas em projeção superior.

Figura 6 – Superfície de Resposta 3D dos Clones LW e H77 para a Perda de massa



Fonte: Próprio autor.

Figura 7 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Perda de massa



Fonte: Próprio autor.

Quando analisado a variável perda de massa nos dois clones de madeira estudados (LW e H77) (Figura 6 e 7), nota-se diferenças relevantes nas respostas ao processo de termorretificação, especialmente em função do tempo e da temperatura aplicados.

O clone LW apresentou maior variação em perda de massa quando submetido a tratamentos térmicos em temperaturas entre 100°C e 105°C e tempos dentro do intervalo de 0 a 7 minutos, evidenciando que essa faixa proporciona alterações significativas em sua composição estrutural inicial. Já para o clone H77, a maior perda de massa foi observada no espectro de temperatura de 102°C a 107°C com exposição de 0 a 5 minutos, indicando que, mesmo com um tempo de tratamento mais curto, suas características físicas são rapidamente impactadas dentro dessa janela térmica.

Esses achados ressaltam como as condições do tratamento térmico afetam cada clone de maneira distinta, tornando essencial a personalização dos parâmetros para otimizar a eficiência da termorreificação em diferentes materiais lignocelulósicos.

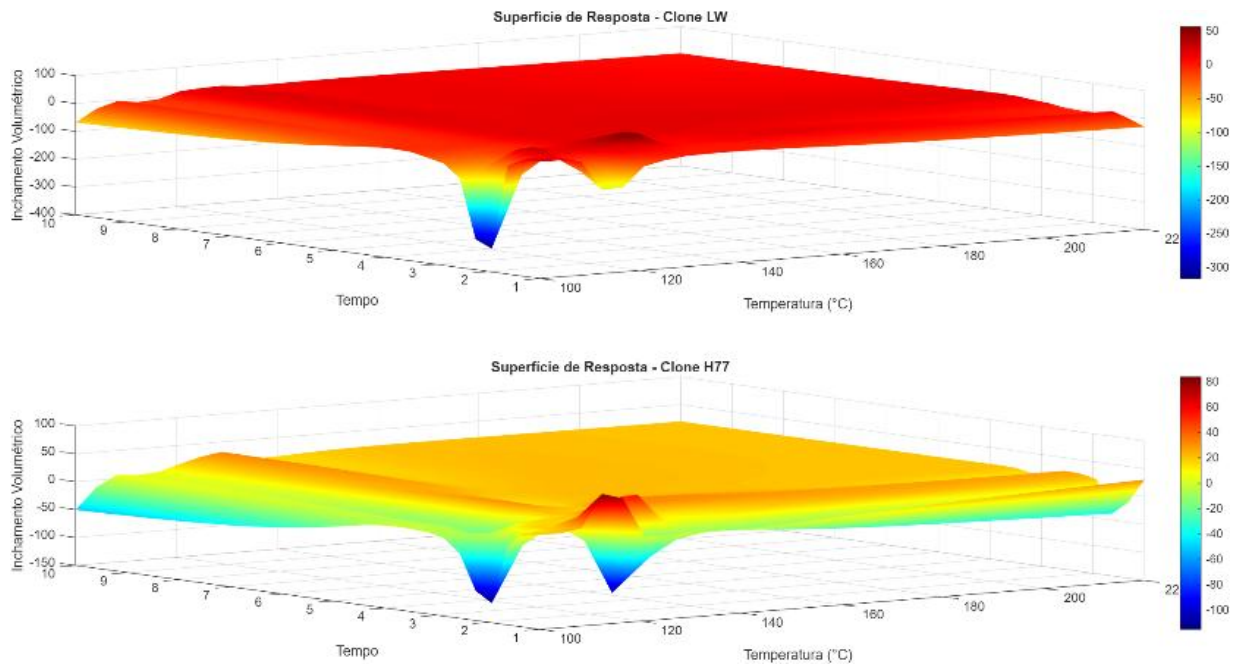
Comprovando esses resultados (Figuras 6 e 7), o valor do RMSE obtido entre os clones LW e H77 foi de 1.468,918, indicando a magnitude média do erro quadrático entre os valores observados para cada clone.

Com o RMSE de aproximadamente 1.469 unidades revelou uma discrepância significativa entre os dois conjuntos, refletindo diferenças substanciais no comportamento dos clones ao longo das medições, isso pode ser decorrente das variações consideráveis entre clones e possíveis fatores genéticos, ambientais ou experimentais. Portanto, esse valor reforça que os clones LW e H77 apresentam perfis distintos para a variável analisada, o que deve ser considerado na interpretação dos resultados e no desenvolvimento de modelos preditivos ou estratégias de manejo.

2.3.4 Inchamento Volumétrico Total


As Figuras a seguir (8 e 9) ilustram a Superfície de Resposta 3D dos Clones LW e H77 para o Inchamento volumétrico total e as Superfícies de Resposta 3D dos mesmos clones visualizadas em projeção superior.

Figura 8 – Superfície de Resposta 3D dos Clones LW e H77 para o Inchamento volumétrico total



Fonte: Próprio autor.

Figura 9 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Inchamento volumétrico total



Fonte: Próprio autor.

Com base na análise dos dados extraídos das Figuras 8 e 9 referentes aos dois clones de madeira estudados (H77 e LW), observa-se um comportamento distinto em

relação à variável de saída inchamento volumétrico total, considerando como variáveis de entrada o tempo e a temperatura de termorreificação.

Para o clone H77, os melhores resultados foram caracterizados por menores valores de inchamento volumétrico, indicativos de maior estabilidade dimensional da madeira após o tratamento térmico e concentraram-se na faixa de temperaturas entre 100°C e 120°C, com tempos de exposição variando de 1 a 10 minutos. Esse intervalo sugere que o clone H77 apresenta boa resposta à estabilização dimensional mesmo em tratamentos com duração moderada.

Por outro lado, o clone LW demonstrou os melhores desempenhos dentro de uma faixa de 110°C a 120°C, porém com exposição muito curta, entre 1 e 2 minutos, indicando uma sensibilidade maior ao tempo, e possíveis alterações mais rápidas em sua estrutura com o incremento da temperatura.

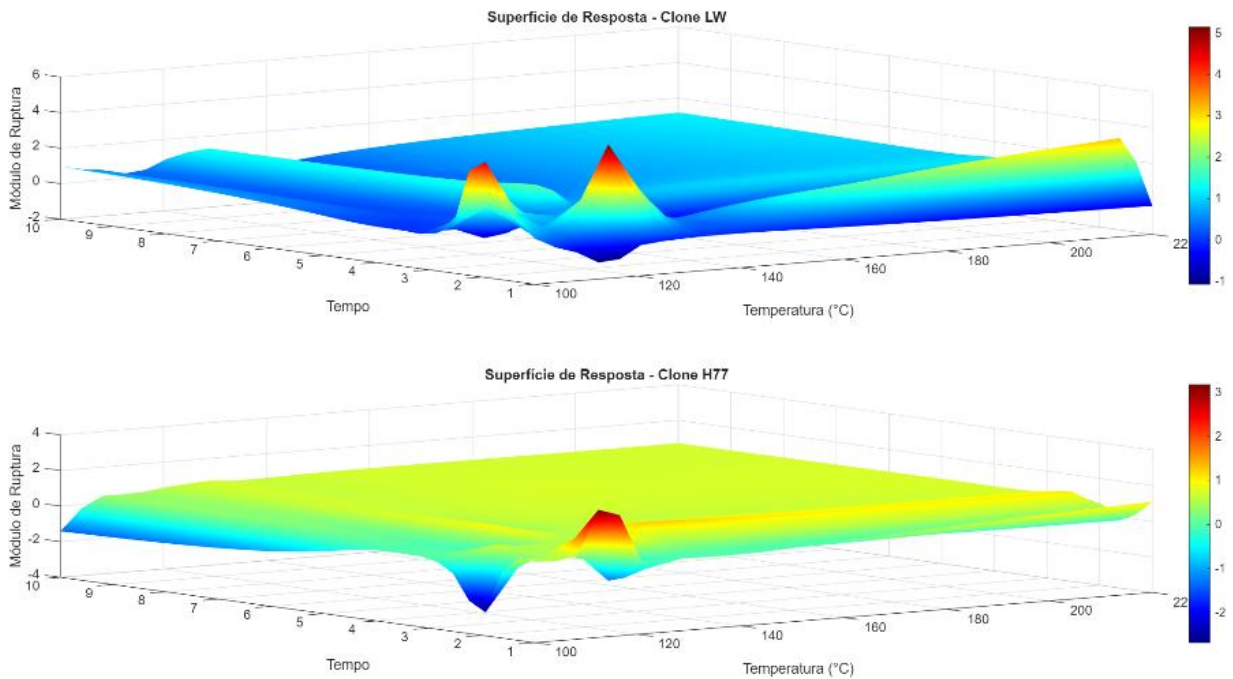
Esses resultados evidenciaram a influência direta das condições de tratamento nas propriedades físicas finais dos diferentes materiais lignocelulósicos e reforçam a necessidade de ajustes específicos por tipo de madeira para otimização dos parâmetros de termorreificação.

O valor do RMSE de 2,115536 obtido na comparação entre os clones LW e H77 representa uma magnitude média do erro quadrático entre os valores observados para cada clone, expressa na mesma unidade da variável analisada. Em termos práticos, isso significa que, em média, as previsões ou medições diferem dos valores reais em aproximadamente 2,12 unidades. Portanto, um RMSE relativamente baixo como esse indica que os valores dos clones LW e H77 são próximos, sugerindo boa concordância entre eles para a variável analisada.

2.3.5 Módulo de Ruptura


As Figuras a seguir (10 e 11) ilustram a Superfície de Resposta 3D dos Clones LW e H77 para o Módulo de ruptura e as Superfícies de Resposta 3D dos mesmos clones visualizadas em projeção superior.

Figura 10 – Superfície de Resposta 3D dos Clones LW e H77 para o Módulo de ruptura



Fonte: Próprio autor.

Figura 11 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Módulo de ruptura



Fonte: Próprio autor.

Ao analisar os dados experimentais relativos ao módulo de ruptura (MOR) em diferentes condições de termorretificação para os clones de madeira LW e H77 (Figura

10 e 11), observa-se padrões específicos de desempenho conforme o tempo e a temperatura aplicados no processo.

As melhores respostas para o módulo de ruptura do clone LW concentram-se nos tratamentos realizados com curta exposição (1 a 2 minutos) e temperatura de 120°C. Esses resultados sugerem que esse clone contém potencial para manter ou até elevar sua capacidade resistente sob curtos intervalos de tempo e temperatura moderadamente elevada, fator que pode ser vantajoso em processos produtivos que buscam eficiência e rápida modificação estrutural sem grande comprometimento das propriedades mecânicas.

Já para o clone H77, a faixa de condições mais destacada envolve igualmente o tempo curto de exposição (1 a 2 minutos), porém em uma janela de temperatura um pouco mais ampla, de 110°C a 120°C. Esse padrão indica que o clone H77 responde com elevação ou manutenção do módulo de ruptura tanto em temperaturas moderadas quanto um pouco mais elevadas, mantendo a resistência estrutural em ambas as situações.

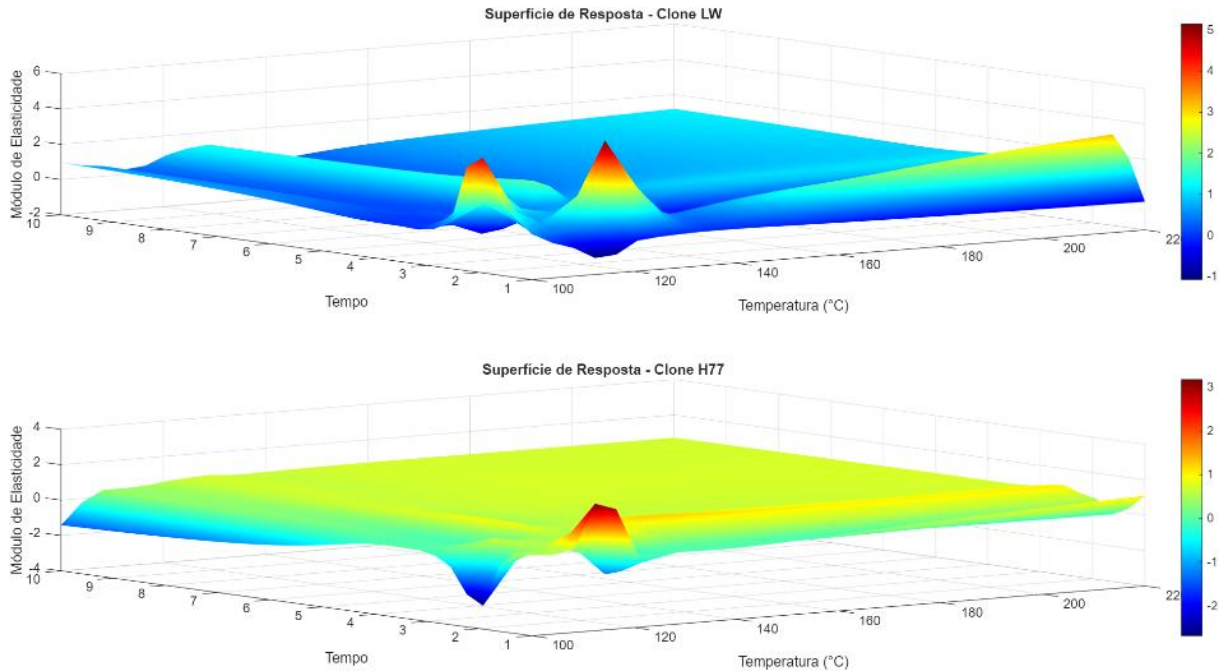
Esses resultados destacam que, em ambos os clones, o módulo de ruptura pode ser otimizado com tratamentos térmicos de curta duração, sendo que o clone LW alcançou seu melhor resultado em uma temperatura específica (120°C), enquanto o clone H77 revelou flexibilidade quanto à faixa térmica (110 a 120°C) para o mesmo tempo de exposição. Tais respostas indicam oportunidades para customização dos processos de termorreificação, visando propriedades mecânicas superiores de acordo com as características de cada material e aplicação pretendida.

Corroborando as Figuras 10 e 11, o valor do RMSE foi de 57,82763 obtido na comparação entre os clones LW e H77, o que representa a magnitude média dos erros quadráticos entre os valores observados para cada clone, expressa na mesma unidade da variável analisada, essa diferença entre os valores dos clones LW e H77 são da ordem de 58 unidades, o que pode refletir variações significativas entre os dois perfis analisados.

2.3.6 Módulo de Elasticidade

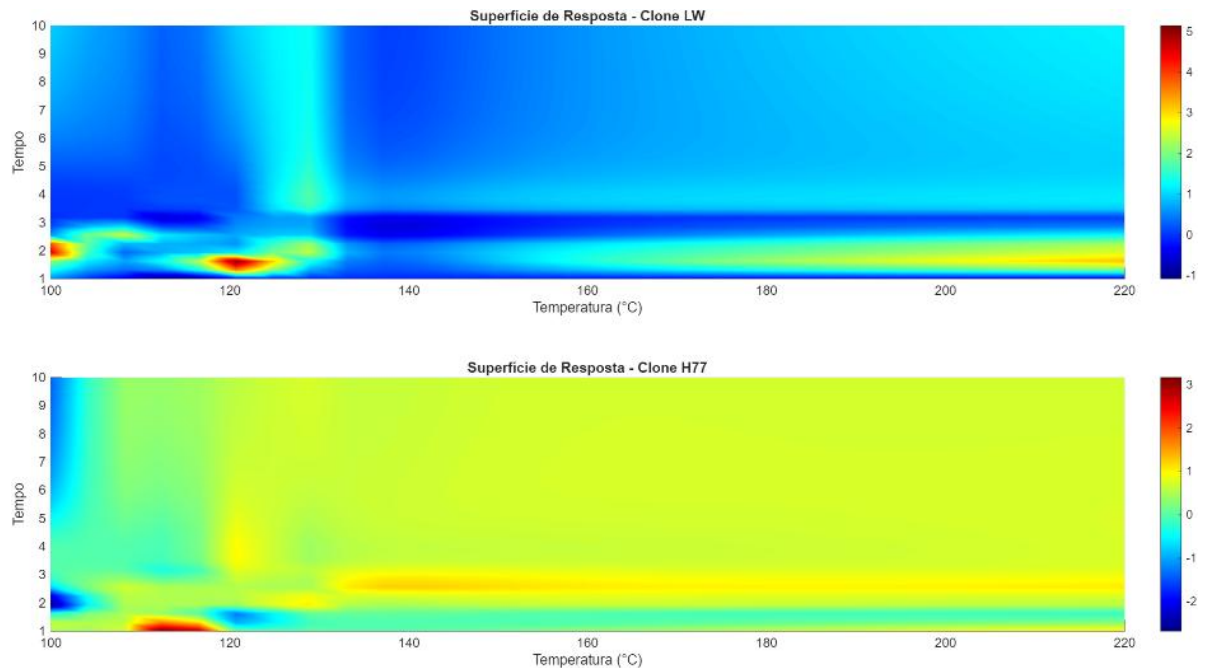
As Figuras a seguir (12 e 13) ilustram a Superfície de Resposta 3D dos Clones LW e H77 para o Módulo de elasticidade e as Superfícies de Resposta 3D dos mesmos clones visualizadas em projeção superior.

Figura 12 – Superfície de Resposta 3D dos Clones LW e H77 para o Módulo de elasticidade



Fonte: Próprio autor.

Figura 13 – Superfície de Resposta 3D dos Clones LW e H77 visualizada em projeção superior – Módulo de elasticidade



Fonte: Próprio autor.

A avaliação do módulo de elasticidade (MOE) para os clones LW e H77 evidencia padrões distintos de acordo com as condições de tempo e temperatura de termorretificação, para o clone LW, os melhores desempenhos para o módulo de elasticidade ocorreram em dois cenários principais. O primeiro envolve exposições muito curtas (1 a 2 minutos) sob temperatura mais elevada (120°C), sugerindo que rápidas elevações térmicas potencializam a rigidez do material sem a necessidade de tratamentos prolongados. O segundo cenário, com tempo fixo de 2 minutos a uma temperatura inferior (100°C), indica que mesmo em condições térmicas mais amenas, curtos períodos são suficientes para promover ganhos ou manutenção dessa propriedade mecânica.

Já para o clone H77, há destaque para faixas similares de tempo entre 1 e 2 minutos associadas a temperaturas de 110°C a 120°C. Essa resposta evidencia o potencial desse clone para atingir elevados valores do módulo de elasticidade sob tratamentos rápidos e temperaturas moderadas a elevadas, mostrando certa flexibilidade térmica.

Quando se avalia a estatística, o valor do RMSE foi de 3.795,525 obtido na comparação entre os clones LW e H77, tendo o RMSE elevado como este indica que há discrepâncias significativas entre os valores dos clones, sugerindo variações substanciais no comportamento ou nas características medidas entre LW e H77. Essa diferença pode decorrer de fatores genéticos, ambientais ou experimentais, e evidencia que os dois clones possuem perfis distintos para a variável analisada.

2.4 CONSIDERAÇÕES FINAIS

Os resultados deste estudo evidenciam que o comportamento dos clones de madeira LW e H77 diante do processo de termorretificação é sensível à combinação dos parâmetros tempo e temperatura, requerendo ajustes específicos para otimizar propriedades como densidade aparente, densidade básica, perda de massa, inchamento volumétrico total, módulo de ruptura (MOR) e módulo de elasticidade (MOE). O clone LW apresentou melhores resultados em faixas mais restritas de tempo e temperatura, enquanto o clone H77 mostrou maior flexibilidade, atingindo bons desempenhos em diferentes cenários operacionais, o que reforça a importância da

personalização dos tratamentos térmicos conforme a genética e a estrutura de cada material.

A aplicação do sistema *Neuro-Fuzzy* demonstrou elevada eficiência na modelagem e previsão dos comportamentos observados, com RMSEs baixos para densidade aparente (0,10) e densidade básica (0,087), atestando boa precisão nas estimativas dessas propriedades. Contudo, variáveis como perda de massa (RMSE \approx 1.469) e MOE (RMSE \approx 3.796) apresentaram maiores discrepâncias entre os clones, indicando variabilidade intrínseca e a necessidade de análise criteriosa para o desenvolvimento de modelos preditivos ainda mais robustos ou estratégias de manejo diferenciadas.

Em síntese, os resultados confirmam que as respostas diferenciadas dos clones perante os parâmetros de termorreificação apontam para a necessidade de estratégias customizadas para maximização das qualidades físico-mecânicas da madeira modificada. Além disso, o uso de ferramentas inteligentes, como o modelo *Neuro-Fuzzy*, proporciona suporte confiável à tomada de decisão para processos industriais e pesquisa, promovendo avanços relevantes na aplicação sustentável e tecnicamente aprimorada da madeira termorreificada.

REFERÊNCIAS

BARREIROS, Ricardo Marques *et al.* Efeitos da termorreificação da madeira em clones de eucalipto. *In: Open Science Research IX*. Cientifica ed. São Paulo, SP: [S.n.]. p. 1443–1455.

BELTRAME, Rafael *et al.* Propriedades físico-mecânicas da madeira de *Araucaria angustifolia* (Bertol.) em três estratos fitossociológicos. **Revista Ciência da Madeira - RCM**, v. 1, n. 2, p. 54–69, 2010.

CARMO, Carlos Roberto Souza; SILVA, Jéssica Rayse Melo. Aprendizado de Máquinas e Prestação de Serviços de Armazenamento de Dados: Métricas para Análise e Validação de Algoritmos Previsores. **Getec**, v. 12, n. 38, p. 123–144, 2023.

FERREIRA, Bruno Santos; RANGEL, Elidiane Cipriano; CAMPOS, Cristiane Inácio de. Efeito da termorreificação na qualidade de colagem de lâminas de madeira para a produção de compensado. **Ciência Florestal**, v. 28, n. 1, p. 274–282, 2018.

FERREIRA, Hipólito Nunes; SILVA, Paulo Cesar Linhares da. **Polinômio de lagrange aplicado ao estudo da eficiência de uma usina solar fotovoltaica**. [S.l.]: UNIVERSIDADE FEDERAL RURAL DO SEMIÁRIDO - UFRSA, 2022.

FERREIRA, Mayra Daniela *et al.* Propriedades Físicas E Mecânicas Da Madeira De Angelim-Pedra Submetida a Tratamento Térmico. **Tecnologia em Metalurgia**

Materiais e Mineração, v. 16, n. 1, p. 3–7, 2019.

FILHO, Mario. **RMSE (Raiz Do Erro Quadrático Médio) em Machine Learning**. Disponível em: <<https://mariofilho.com/rmse-raiz-do-erro-quadratico-medio-em-machine-learning/>>. Acesso em: 13 jul. 2025.

GODINHO, Emmanuel Zullo *et al.* Modeling in the production of biogas from swine manure using *Fuzzy Logic*. **Sodebras**, v. 18, n. 209, p. 62–72, 2023.

GODINHO, Emmanuel Zullo; FERMINO, Caetano Dartiere Zulian; BARREIROS, Ricardo Marques. Kinetic modeling and *Neuro-Fuzzy* application in ethanol production. **Brazilian Journal of Biosystems Engineering**, v. 19, n. February, p. 1–5, 2025.

GODINHO, Emmanuel Zullo; FRIGO, Murilo Miceno; CANEPPELE, Fernando de Lima. Modelagem *Neuro-Fuzzy* na fermentação alcoólica. **Revista Acadêmica Online**, v. IX, n. 46, p. 1–12, 2023.

MELO, Luiz Eduardo de Lima *et al.* Variação anatômica no lenho de *Astronium lecointei* Ducke. **Floresta e Ambiente**, v. 20, n. 1, p. 135–142, 2013.

NIKOLOVSKI, Srete; BAGHAEI, Hamid Reza; MLAKIC, Dragan. ANFIS-Based Peak Power Shaving/Curtailment in Microgrids Including PV Units and BESSs. **Energies**, v. 11, n. 11, 1 nov. 2018.

NUNES, Jéssica Letícia Thomas *et al.* MELHORIA DO PROCESSO PRODUTIVO POR MEIO DE OTIMIZAÇÃO DE PROCESSO DE ENVASE. **Engepro**, v. 2, n. 1, p. 105–122, 2018.

PERTUZZATTI, Anderson *et al.* Propriedades Físicas da Madeira de *Pinus elliottii* var. *elliottii* Termorretrificada Sob Diferentes Atmosferas. **Revista Ciência da Madeira - RCM**, v. 7, n. 1, p. 7–15, 2016.

PORTELA, Adriane Caroline Teixeira; OLIVEIRA, Hugo Henrique Gonsalves dos Santos; VIOLA, Denise Nunes. Utilização do *software* R para auxiliar no processo de ensino-aprendizagem da análise combinatória. **Ensino em ReVista**, v. 30, p. e037, 2023.

RAMOS, Maysa Marinho Antunes *et al.* Utilização do *Software* R em pesquisas na terapia ocupacional. **Cadernos Brasileiros de Terapia Ocupacional**, v. 27, n. 1, p. 217–230, 2019.

SCHEMMER, ROSANGELA CARLINE. **Métodos de interpolação polinômial**. [S.l.]: Trabalho de Conclusão de Curso (Especialização) - Universidade Tecnológica Federal do Parná, 2013.

SILVA, Aldo A. V. da *et al.* Estimativa da produtividade de trigo em função da adubação nitrogenada utilizando modelagem *Neuro Fuzzy*. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 2, p. 180–187, fev. 2014.

APÊNDICE A – Código R desenvolvido para interpolação polinomial pelo método de Lagrange

Instale os pacotes necessários caso ainda não tenha

```
if (!require("openxlsx")) install.packages("openxlsx", dependencies = TRUE)
```

```
library(openxlsx)
```

Função para interpolação de Lagrange

```
lagrange_interp <- function(x, y, xq) {
  n <- length(x)
  sapply(xq, function(x0) {
    L <- 0
    for (i in 1:n) {
      li <- 1
      for (j in 1:n) {
        if (j != i) {
          li <- li * (x0 - x[j]) / (x[i] - x[j])
        }
      }
      L <- L + y[i] * li
    }
    return(L)
  })
}
```

Dados do clone LW

```
x_LW <- c(100, 140, 160, 180, 200, 220)
```

```
y_LW <- c(0.58, 0.61, 0.54, 0.55, 0.56, 0.59)
```

Dados do clone H77

```
x_H77 <- c(100, 140, 160, 180, 200, 220)
```

```
y_H77 <- c(0.55, 0.61, 0.60, 0.57, 0.61, 0.62)
```

Pontos de interpolação

```
xq <- seq(100, 220, by = 1.34)
```

Interpolação para cada clone

```
yq_LW <- lagrange_interp(x_LW, y_LW, xq)
```

```
yq_H77 <- lagrange_interp(x_H77, y_H77, xq)
```

Arredondar para 4 casas decimais

```
yq_LW <- round(yq_LW, 4)
```

```
yq_H77 <- round(yq_H77, 4)
```

Criar data frame com os resultados

```
resultados <- data.frame(
```

```
  Grau = round(xq, 2),
```

```
  Clone_LW = yq_LW,
```

```
Clone_H77 = yq_H77  
)
```

Exportar para Excel

```
write.xlsx(resultados, "Interpolacao_Lagrange_Clones.xlsx", rowNames = FALSE)
```

Opcional: plotar os resultados

```
plot(x_LW, y_LW, col = "red", pch = 19, ylim = range(c(yq_LW, yq_H77)), xlim =  
c(100, 220), xlab = "Grau", ylab = "Valor", main = "Interpolação Lagrange")  
points(x_H77, y_H77, col = "blue", pch = 19)  
lines(xq, yq_LW, col = "red", lwd = 2)  
lines(xq, yq_H77, col = "blue", lwd = 2)  
legend("topright", legend = c("Clone LW", "Clone H77"), col = c("red", "blue"), lty = 1,  
pch = 19)
```

**APÊNDICE B – Código para o Matlab® desenvolvido para modelagem
matemática de *Neuro-Fuzzy***

```
clc; clear;
```

```
% --- DADOS (Temperatura vs Densidade básica) ---
```

```
dados = [... % Clone_LW Clone_H77
```

```
0.5 0.47; 0.5312 0.4595; 0.558 0.4512; 0.5806 0.4449; 0.5996 0.4405; 0.615 0.4377;
0.6273 0.4364; 0.6366 0.4363; 0.6434 0.4373; 0.6477 0.4393; 0.6499 0.4421;
0.6502 0.4456; 0.6488 0.4496; 0.6459 0.454; 0.6416 0.4587; 0.6362 0.4637; 0.6299
0.4688; 0.6227 0.474; 0.6148 0.4791; 0.6065 0.4841; 0.5977 0.4889; 0.5886 0.4936;
0.5793 0.498; 0.57 0.5021; 0.5606 0.5058; 0.5514 0.5092; 0.5423 0.5122; 0.5335
0.5148; 0.5249 0.517; 0.5167 0.5188; 0.5089 0.5202; 0.5014 0.5211; 0.4945 0.5216;
0.488 0.5217; 0.482 0.5215; 0.4766 0.5208; 0.4716 0.5198; 0.4672 0.5185; 0.4633
0.5168; 0.4599 0.5149; 0.4571 0.5128; 0.4547 0.5104; 0.4528 0.5078; 0.4514
0.5051; 0.4505 0.5023; 0.4499 0.4993; 0.4498 0.4964; 0.45 0.4934; 0.4505 0.4905;
0.4513 0.4877; 0.4524 0.4849; 0.4538 0.4823; 0.4553 0.4799; 0.457 0.4776; 0.4588
0.4756; 0.4607 0.4739; 0.4627 0.4724; 0.4647 0.4713; 0.4667 0.4705; 0.4687
0.4701; 0.4706 0.47; 0.4723 0.4703; 0.474 0.4711; 0.4756 0.4722; 0.4769 0.4737;
0.4781 0.4756; 0.4791 0.4779; 0.48 0.4805; 0.4806 0.4836; 0.481 0.4869; 0.4812
0.4905; 0.4812 0.4944; 0.4811 0.4985; 0.4808 0.5028; 0.4803 0.5072; 0.4798
0.5117; 0.4792 0.5161; 0.4786 0.5204; 0.478 0.5245; 0.4775 0.5284; 0.4772 0.5318;
0.4771 0.5348; 0.4773 0.5371; 0.478 0.5387; 0.4791 0.5395; 0.4808 0.5391; 0.4833
0.5376; 0.4867 0.5348; 0.491 0.5304; 0.4964 0.5242
];
```

```
% --- PREPARAÇÃO DOS DADOS ---
```

```
n = size(dados,1);
```

```
tempo = linspace(1,n,n)';
```

```
X_LW = [dados(:,1), tempo];
```

```
Y_LW = dados(:,1); % Saída = Densidade básica (poderia ser diferente)
```

```
X_H77 = [dados(:,2), tempo];
```

```
Y_H77 = dados(:,2);
```

```
% --- DIVISÃO TREINO/TESTE (30% treino, 70% teste) ---
```

```
idxTreino = 1:round(0.3*n);
```

```
idxTeste = (round(0.3*n)+1):n;
```

```
% --- PARÂMETROS FIS ---
```

```
opt = genfisOptions('GridPartition');
```

```
opt.NumMembershipFunctions = 6;
```

```
opt.InputMembershipFunctionType = 'gaussmf';
```

```
% --- MODELO LW ---
```

```
fis_LW = genfis(X_LW(idxTreino,:), Y_LW(idxTreino), opt);
```

```
anfis_LW = anfis([X_LW(idxTreino,:) Y_LW(idxTreino)], fis_LW, 100, [0 0 0 0]);
```

```
% --- MODELO H77 ---
```

```
fis_H77 = genfis(X_H77(idxTreino,:), Y_H77(idxTreino), opt);
```

```
anfis_H77 = anfis([X_H77(idxTreino,:) Y_H77(idxTreino)], fis_H77, 100, [0 0 0 0]);
```

```
% --- AVALIAÇÃO ---
```

```
Ypred_LW = evalfis(anfis_LW, X_LW(idxTeste,:));  
Ypred_H77 = evalfis(anfis_H77, X_H77(idxTeste,:));  
rmse_LW = sqrt(mean((Y_LW(idxTeste) - Ypred_LW).^2));  
rmse_H77 = sqrt(mean((Y_H77(idxTeste) - Ypred_H77).^2));  
fprintf('\n ♦ RMSE Clone LW: %.5f\n', rmse_LW);  
fprintf(' ♦ RMSE Clone H77: %.5f\n\n', rmse_H77);
```

```
% --- SUPERFÍCIES DE RESPOSTA ---
```

```
[tempoGrid, tempGrid] = meshgrid(linspace(min(tempo), max(tempo),50), ...  
    linspace(min(dados(:)), max(dados(:)),50));  
gridInput = [tempGrid(:) tempoGrid(:)];  
Z_LW = reshape(evalfis(anfis_LW, gridInput), size(tempoGrid));  
Z_H77 = reshape(evalfis(anfis_H77, gridInput), size(tempoGrid));
```

```
% --- PLOTAGEM 3D ---
```

```
figure('Name','Superfícies Neuro-Fuzzy');  
subplot(2,1,1)  
surf(tempoGrid, tempGrid, Z_LW); shading interp;  
xlabel('Tempo'); ylabel('Temperatura'); zlabel('Densidade');  
title('Clone LW (Superior)'); colorbar
```

```
subplot(2,1,2)  
surf(tempoGrid, tempGrid, Z_H77); shading interp;  
xlabel('Tempo'); ylabel('Temperatura'); zlabel('Densidade');  
title('Clone H77 (Inferior)'); colorbar
```