



**UNIVERSIDADE FEDERAL DE SÃO JOÃO *DEL-REI*
PRÓ-REITORIA DE ENSINO DE GRADUAÇÃO
BACHARELADO EM ENGENHARIA FLORESTAL
CAMPUS SETE LAGOAS**

GUILHERME SÁVIO CAMARGOS LIMA

**MODELAGEM DA PRODUÇÃO DE *Eucalyptus* EM NÍVEL DE
ÁRVORE INDIVIDUAL EM SISTEMA DE INTEGRAÇÃO LAVOURA
PECUÁRIA FLORESTA (ILPF)**

Sete Lagoas, MG

2024

GUILHERME SÁVIO CAMARGOS LIMA

**MODELAGEM DA PRODUÇÃO DE *Eucalyptus* EM NÍVEL DE ÁRVORE INDIVI-
DUAL EM SISTEMA DE INTEGRAÇÃO LAVOURA PECUÁRIA FLORESTA
(ILPF)**

Trabalho de Conclusão apresentado ao Curso de Engenharia Florestal da Universidade Federal de São João del-Rei, como requisito parcial para obtenção do grau de Bacharel em Engenharia Florestal.

Orientador: Prof. Renato Vinícius Oliveira Castro

Sete Lagoas, MG

2024

GUILHERME SÁVIO CAMARGOS LIMA

**MODELAGEM DA PRODUÇÃO DE *Eucalyptus* EM NÍVEL DE
ÁRVORE INDIVIDUAL EM SISTEMA DE INTEGRAÇÃO LAVOURA
PECUÁRIA FLORESTA (iLPPF)**

Trabalho de Conclusão apresentado ao Curso de Engenharia Florestal da Universidade Federal de São João del-Rei, como requisito parcial para obtenção do grau de Bacharel em Engenharia Florestal.

Sete Lagoas, 19 de fevereiro de 2024.

Banca avaliadora:

Dr. Renato Vinicius Oliveira Castro, Orientador — Universidade Federal de São João del-Rei.

Dra. Glauciana da Mata Ataíde — Universidade Federal de São João del-Rei.

Dra. Mayra Luiza da Silva Marques — Universidade Federal de São João del-Rei.

Caminhante, não há caminho, o caminho se faz ao caminhar.

Antônio Machado (Poeta espanhol)

AGRADECIMENTOS

À Deus, aos meus guias, mentores e protetores espirituais. À minha Família, aos meus Amigos e aos meus Professores. Aos colegas Pesquisadores Flávia, Ricardo e Virgínio da EMBRAPA Milho e Sorgo e à toda equipe da Fazenda Trijunção por nos ter cedido, tempo dados e experiências que contribuíram para execução deste projeto. Por fim, à UFSJ e ao Campus Sete Lagoas.

Que a Luz se faça eternamente presente e que a gente acesse e reverbere essa Luz!!

LISTA DE ILUSTRAÇÕES

Figura 1: Croqui com mapa de localização do iLPF instalado em Jaborandi, na Bahia.....	13
Figura 2: Distribuição diamétrica de árvores de <i>Eucalyptus</i> spp. em sistema iLPF no sul da Bahia, medidas em cinco ocasiões.....	24
Figura 3: Figura 3: Figura 3: Gráficos com valores estimados e observados (A) e gráficos de resíduos percentuais (B) para os ajustes realizados com as diferentes técnicas.	27
Figura 4: Área basal (m^2) (A), volume (m^3) (B) e Biomassa e Carbono (toneladas) (C) por hectare no componente arbóreo de um Sistema de iLPF	29

LISTA DE TABELAS

Tabela 1: Características dos modelos ajustados para prognose de área basal em nível de árvore individual com dados de inventário florestal contínuo realizado em iLPF de 15 hectares em Jaborandi – BA.	17
Tabela 2: Variáveis e Hiper parâmetros empregados para ajuste de árvore de decisão com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF	18
Tabela 3: Variáveis e Hiper parâmetros empregados para ajuste de Floresta Aleatória com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF	19
Tabela 4: Variáveis e Hiper parâmetros empregados para ajuste de Rede Neural Artificial com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF.	20
Tabela 5: Variáveis e Hiper parâmetros empregados para ajuste de Regressão com vetor de suporte com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF.....	21
Tabela 6: Variáveis e Hiper parâmetros empregados para ajuste de algoritmo do vizinho mais próximo com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF.....	22
Tabela 7: Resultados quantitativos de cinco inventários florestais (censos) realizados em um Sistema de Integração Lavoura Pecuária Floresta em Jaborandi – BA	23
Tabela 8: Parâmetros de produção do componente florestal representado pelo fuste de Eucalyptus spp. em sistema ILPF de 15 hectares no sul da Bahia, aos cinco anos de idade...23	
Tabela 9: Métricas de avaliação de oito modelos aplicados a prognose do componente florestal (Eucalyptus spp.) em sistema iLPF no sul da Bahia.	25
Tabela 10: Parâmetros dos modelos clássicos e hiper parâmetros dos algoritmos de aprendizado de máquinas aplicados para projeção em nível de árvores individuais representado pelo fuste de Eucalyptus spp. em sistema ILPF de 15 hectares no sul da Bahia, encontrados por pesquisa em grade.....	26

Sumário

1	Modelagem da Produção de <i>Eucalyptus</i> em Nível de Árvore Individual EM SISTEMA de Integração Lavoura Pecuária Floresta (iLPF)	10
2	Materiais e métodos.....	13
2.1	Modelagem em Nível de Árvore Individual	15
2.2	Algoritmos empregados de aprendizado de máquinas empregados.....	17
2.2.1	Árvores de decisão	17
2.2.2	Floresta Aleatória	18
2.2.3	Redes Neurais Artificiais.....	19
2.2.4	Regressão com vetor de suporte	20
2.2.5	Algoritmo do Vizinho mais próximo.	21
3	Resultados.....	23
3.1	Produção florestal.....	23
3.2	Modelos de projeção	24
3.3	Aplicações do Modelo.....	29
4	Discussão	30
5	Conclusões.....	32
6	Referências	33
7	APÊNDICES E ANEXOS.....	Erro! Indicador não definido.

Termo de autorização para publicação no Repositório Institucional da UFSJ **Erro!**
Indicador não definido.

RESUMO

Este estudo avaliou um Sistema de Integração Lavoura Pecuária Floresta (iLPF) de *Eucalyptus* spp. no sul da Bahia e aplicou diferentes técnicas para modelagem do crescimento e produção em nível de árvores individuais. Através de cinco inventários florestais contínuos, monitoramos o crescimento das árvores e estimamos a produção de madeira e o potencial de sequestro de carbono. A produção volumétrica total aos 61 meses foi de 44,43 m³/ha e a biomassa total estimada foi de 20,09 ton/ha, com um estoque de carbono de 10,04 ton/ha. Quanto às projeções, avaliou-se oito estratégias para a prognose da área basal futura das árvores individuais por: a) regressão linear múltipla, adotando-se na idade atual a área basal, altura dominante, índice de competição e as idades atual e futura como variáveis dependentes; b) Piennar e Schiver (1981) que adota área basal na atual e a as idades atual e futura como variáveis dependentes, c) regressão logística, adotando-se área basal na idade futura como variável independente; d) árvores de decisão; e) florestas aleatórias; f) redes neurais artificiais; g) regressão com vetor de suporte e h) algoritmos do vizinho mais próximos, sendo estes cinco últimos, pelas mesmas variáveis do modelo de regressão linear múltipla. A regressão linear múltipla foi o modelo mais adequado para a projeção da área basal em nível de árvore individual, apresentando um comportamento coerente na projeção de 61 para 97 meses. Os resultados apontam que a iLPF analisada apresenta bom potencial de crescimento e produtividade, com produção de madeira e sequestro de carbono satisfatórios.

Palavras-chave: Inventário Florestal. Aprendizado de Máquinas. Crescimento. Produtividade. Sequestro de Carbono. Projeção de Crescimento. Solos arenosos.

ABSTRACT

This study evaluated a Crop Livestock Forest Integration System (iLPF) of *Eucalyptus* spp. in southern Bahia and applied different techniques to model growth and production at the level of individual trees. Through five continuous forest inventories, we monitor tree growth and estimate wood production and carbon sequestration potential. The total volumetric production at 61 months was 44.43 m³/ha and the estimated total biomass was 20.09 ton/ha, with a carbon stock of 10.04 ton/ha. Regarding projections, eight strategies were evaluated to predict the future basal area of individual trees by: a) multiple linear regression, adopting the current age as the basal area, dominant height, competition index and current and future ages as dependent variables; b) Piennar and Schiver (1981) which adopts basal area at current and current and future ages as dependent variations, c) logistic regression, adopting basal area at future age as independent variable; d) decision trees; e) forests researched; f) artificial neural networks; g) support vector regression and h) nearest neighbor algorithms, the last five of which use the same variables as the multiple linear regression model. Multiple linear regression was the most appropriate model for the projection of the basal area at the individual tree level, showing coherent behavior in the projection from 61 to 97 months. The results indicate that iLPF has good potential for growth and productivity, with overwhelming wood production and carbon sequestration.

Key words: Forest Inventory. Machine Learning. Growth. Productivity. Carbon Sequestration. Growth Projection. Sandy soils.

1 MODELAGEM DA PRODUÇÃO DE *EUCALYPTUS* EM NÍVEL DE ÁRVORE INDIVIDUAL EM SISTEMA DE INTEGRAÇÃO LAVOURA PECUÁRIA FLORESTA (ILPF)

Embora a população mundial venha crescendo em ritmo menos acelerado, a demanda por commodities agrícolas e florestais vem seguindo pleno crescimento (OECD/FAO, 2022). Frente ao exposto, o mercado agrário brasileiro e mundial tem buscado atender à crescente demanda por alimentos, madeira, fibras e bioenergia (MAXIMO, et al., 2022). Concomitantemente à necessidade de aumento de produtividade, crescem as restrições para expansão sobre novas áreas para uso agrícola e/ou florestal (EMBRAPA, 2018) e paralelamente, nota-se por parte da sociedade em geral, uma preocupação crescente com a conservação ambiental e a necessidade de uso mais eficiente dos recursos naturais e de insumos para atendimento dessas demandas atuais e de demandas futuras (ALVES, ALMEIDA, & LAURA, 2015). Há então necessidade de intensificação do uso das áreas com pastagens cultivadas, pela combinação de uso otimizado de insumos, melhoria de técnicas de manejo, incremento da suplementação alimentar e utilização de sistemas de produção em integração (ALVES, ALMEIDA, & LAURA, 2015).

Em resumo, o resultado destas questões são as demandas globais crescentes por produtos agrícolas e florestais de origem socialmente justas, economicamente viáveis e ambientalmente corretas.

Neste contexto, a Integração Lavoura-Pecuária-Floresta (iLPF) é uma estratégia de produção que integra manejos de produção agrícola, pecuária e florestal em uma mesma área de forma consorciada, rotacionada ou em sucessão (Telles & et al., 2021). Esta integração deve ser adaptada em função das condições regionais e locais, permitindo contemplar diferentes arranjos com diferentes atividades (MELOTTO, et al., 2019). A relevância destes sistemas está em suas contribuições para questões sociais, econômicas e ambientais, pois em seu escopo, projetos desta natureza abarcam o favorecimento de diferentes serviços ecossistêmicos, como o sequestro de carbono e a ciclagem de nutrientes; a redução de desigualdades sociais em função da geração de emprego e renda, fomentada inclusive pela elevada adaptabilidade destes

sistemas para as diferentes realidades do produtor e o aumento da produtividade e a redução de custos com insumos.

Outra substancial importância é o favorecimento do bem-estar animal, aspecto com o qual a iLPF dialoga fortemente ao contribuir para adequação da ambiência para o manejo, principalmente em termos de temperatura e qualidade do ar (ALVES, y Porfírio-da-Silva, & Karvatte, Bem-estar animal e ambiência na ILPF., 2019). Especialmente no Brasil, país com maior volume de exportação de carne bovina do mundo, com número efetivo de rebanhos bovinos igual a 224.602.112 cabeças para o ano de 2021 (IBGE, 2021), há ainda de se considerar o potencial da iLPF para neutralização das emissões de gases do efeito estufa oriundos da criação animal.

Em revisões de literaturas, estima-se que os valores de emissão de metano (CH_4) por animal no Brasil, varie de 56 a 70 $\text{kg CH}_4 \text{ animal}^{-1} \text{ ano}^{-1}$ (Resende, et al., 2020). Considerando então emissão de 66 kg de CH_4 (metano) oriundos dos processos digestivos de um bovino ao ano e multiplicando pelo potencial de aquecimento deste gás, podemos estimar a emissão de 14.823.739,392 toneladas de carbono equivalente pelos rebanhos em 2021.

Postos os benefícios das estratégias de integração entre lavoura, pecuária e florestas, pode-se considerar ser esta uma aliada no enfrentamento das questões ambientais, econômicas e sociais que se encontram em curso ao redor do globo e por este e outros motivos como a elevada adaptabilidade dos projetos, tem-se crescido o interesse e adoção destas estratégias de produção (WRUCK, et al., 2019). No Brasil, estimativas obtidas com base nas tendências de crescimento do período de 2005 a 2015 e em dados reportados pela Plataforma ABC de acordo com o resumo do Ministério da Agricultura, Pecuária e Abastecimento (MAPA), apontam para o crescimento da áreas ocupada por iLPF no território, estimando que na safra 2020/2021, o Brasil tenha aumentado a área com integração para 17,43 milhões de hectares, que corresponderiam a um incremento aproximado de 52% em comparação a área ocupada pelas safras de 2015/2016 (Rede iLPF, 2021).

O crescimento do interesse e implantação de sistemas de integração no Brasil é justificado em especial pela possibilidade de mitigação das emissões entéricas de bovinos, ao ponto que em 2015, desenvolveu-se no país, o conceito “Carne Carbono Neutro” (CCN), que é representado por um selo alusivo à produção de bovinos de corte sob sistemas de integração, com a introdução obrigatória do componente arbóreo como diferencial, sendo capaz de

neutralizar o metano emitido pelo rebanho, agregando assim, valor à carne produzida, pois além da neutralidade de carbono, a presença de sombra proporcionada pelas árvores contribuem para que os animais sejam manejados em ambiente termicamente confortável, com alto grau de bem-estar (ALVES, ALMEIDA, & LAURA, 2015). PEREIRA, et al., 2019 , ao comparar a viabilidade econômica de dois projetos sendo um deles com certificação pelo selo CCN e um sem a certificação, constatou que o projeto com CCN apresenta VPL 10,48% superior ao sem CCN, bem como de 10,52% no Valor Presente Líquido Anual, 4,76% na Taxa Interna de Retorno e redução de 8,57% no Tempo de Retorno do Capital. Em se tratando de produção de leite, há também benefícios atrelados ao manejo do rebanho em iLPF. (FERREIRA, et al., 2021), comparou a produção de leite de vacas Gir e Girolando em pleno sol (iLP) e na sombra (iLPF) e constatou haver incremento em produção de leite ao dia por vaca em iLPF 24,24% e 6,06% superiores para Gir e Girolando respectivamente.

Iniciativas relacionadas a instituição de iLPF e mitigação das mudanças climáticas através da neutralização de emissões de carbono na agricultura são fomentadas no Brasil através do Plano ABC, cuja versão vigente é o “Plano Setorial para Adaptação à Mudança do Clima e Baixa Emissão de Carbono na Agropecuária, com vistas ao Desenvolvimento Sustentável (2020-2030) – ABC+”, que tem como objetivo, continuar as ações fomentadoras para o estabelecimento de uma agropecuária nacional mais sustentável, resiliente, capaz de controlar suas emissões de GEE, e que garanta a oferta de alimentos, grãos, fibras e bioenergia, em quantidade e qualidade, com conservação dos recursos naturais, mesmo diante da crescente incerteza climática. (MAPA, 2023).

Em projetos de gases do efeito estufa (GEE), tem-se as atividades que alteram as condições de uma linha de base de GEE que são referências quantitativas das emissões e/ou remoções de GEE, que fornecem também um cenário de referência hipotético que melhor representa as condições mais prováveis de ocorrer na ausência do projeto (NBRISO14064-1, 2022). No contexto de iLPF's, os inventários florestais fornecem as informações necessárias para o atendimento desta necessidade.

O entendimento acerca da produção florestal de carbono, passa pelo computo da biomassa do sistema, que pode ser expressa em massa verde (MV) ou massa seca na estufa (MS). Conhecendo-se a biomassa do fuste das árvores, torna-se possível com a aplicação de


fator de conversão, inferir sobre a quantidade de carbono ali presente (CAMPOS & LEITE, 2017).

A partir dos inventários, torna-se possível o ajuste de modelos de crescimento e produção (MCP's) que simulam a dinâmica natural dos sistemas, fornecendo previsões acerca da produção ao longo do tempo (CASTRO, et al., 2013) e assim o presente estudo objetivou avaliar o desenvolvimento inicial de clones de *Eucalyptus*, instituído em iLPF, no município de Jaborandi na Bahia, quantificando a produção florestal nos fustes das árvores aos 61 meses em termos de volume, biomassa e carbono e o desenvolvimento de um modelo para obtenção destas variáveis ao longo do tempo, a partir da projeção da área basal em nível de árvores individuais.

2 MATERIAIS E MÉTODOS

A área de estudo possui 15 hectares com Sistema de Integração Lavoura-Pecuária-Floresta (iLPF) e fica localizada na Fazenda Trijunção em Jaborandi na Bahia. Foi implantada em dezembro de 2018 (Figura 01). Nessa região, os solos apresentam texturas médias a arenosas e são predominantemente do tipo Latossolo Vermelho Amarelo distrófico típico. O clima apresenta precipitação média anual de 1.800 mm e temperatura média anual de 25°C. A estação chuvosa se concentra entre os meses de outubro e abril, enquanto a estação seca vai de maio a setembro (DOS SANTOS, et al., 2018).

Figura 1: Croqui com mapa de localização do iLPF instalado em Jaborandi, na Bahia.



Na área, foram alternados o plantio de dois clones de *Eucalyptus* spp. com diversas culturas, como girassol, feijão caupi, sorgo forrageiro, soja e capim. Essas plantações foram organizadas em renques espaçados de 25m com 1,5m entre plantas, totalizando quinze linhas de *Eucalyptus*. Antes e após o plantio, foram realizadas correções e adubações no solo para garantir um ambiente propício ao desenvolvimento das culturas. Durante a safra 2019/2020, sorgo forrageiro e milho foram consorciados com braquiária, e tanto as culturas quanto o *Eucalyptus* spp. receberam adubações de cobertura ao longo do período de cultivo.

Os dados utilizados para estudar o comportamento da produção volumétrica e do carbono nas árvores individuais e no povoamento foram obtidos de inventários florestais contínuos realizados entre 2018 e 2023. Os cinco inventários foram realizados por censo, tendo sido a primeira medição 21 meses após o plantio e a última aos 61 meses após o plantio, com intervalo médio de 10 meses entre cada uma das medições.

Todas as árvores foram medidas em relação à circunferência à altura do peito a 1,3 m de altura (CAP) usando fitas dendrométricas e altura (H) de 20% das árvores de forma sistematizada, usando um clinômetro Haglöff (CAMPOS & LEITE, 2017). Com trado de incremento, foram coletadas amostras do lenho de 15 árvores de cada clone de *Eucalyptus*, na altura do DAP (MORAES, et al., 2014), contemplando cada uma das 12 classes de DAP encontradas aos 49 meses. Em laboratório, a densidade básica das amostras foi determinada pelo método de medição direta do volume por paquímetro seguido de saturação das amostras em água e posteriormente, secagem até peso constante, obtendo-se a densidade pela razão entre peso seco e volume (TEUGILHO, et al., 1990). A medição de densidade aos 49 meses, foi aplicada para estimativas de biomassa também nas medições anteriores e posteriores ao inventário aos 49 meses.

As alturas das árvores não mensuradas foram estimadas usando uma equação hipsométrica desenvolvida especificamente para a área de estudo.

$$\ln(H) = 3,155357 - 5,95511 * \frac{1}{DAP}; R^2 = 0,53. \quad (\text{equação 01}).$$

Em que H é a altura em metros e DAP o diâmetro a 1,30 m do solo.

O volume de cada árvore foi estimado pela equação 01; em que V é volume com casca total do fuste, em m³ (SOARES, et al., 2017), considerando um fator de forma de 0,47.

$$V = \pi * \frac{DAP^2}{40000} * H * 0.47 \quad (\text{equação 02}).$$

Em que: V o volume em metros cúbicos por árvore, H a altura individual da árvore em metros.

Em seguida, os volumes das árvores foram totalizados e a produção de madeira com casca foi extrapolada para m³/ha (SOARES, et al., 2017). O estoque de biomassa do povoamento foi equação 03 e o estoque de carbono estimado multiplicando-se a biomassa (toneladas por hectare) pelo fator 0.5, conforme indicado pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC) (equação 05) (HOUGHTON, et al., 1996). As variáveis médias do povoamento foram calculadas para avaliar a produtividade dos fustes das árvores.

$$B(kg/ha) = DB (kg/m^3) * V (m^3/ha) \quad (\text{equação 03}).$$

Em que: B é a biomassa em quilogramas por hectare, DB a densidade básica da madeira em quilograma por metro cúbico e V o volume em metros cúbicos por hectare.

Quanto a modelagem de ingresso e sobrevivência, ao que consta no banco de dados, as árvores faltantes são falhas de plantio e desbastes de fustes bifurcados, por tanto, não foram realizadas modelagens de ingresso e sobrevivência. Os dados foram organizados em planilhas eletrônicas no Excel e os ajustes realizados em linguagem Python de programação, com scripts construídos com assistência virtual da OpenAI.

2.1 Modelagem em Nível de Árvore Individual

Dentre os modelos de produção florestal (MPC), os modelos de árvores individuais (MAI), possuem o indivíduo arbóreo como unidade básica na modelagem para simulação do crescimento, do ingresso e da mortalidade, sendo a extrapolação para hectare, obtida a partir do somatório do volume das árvores individuais (CAMPOS & LEITE, 2017). Empregou-se como variável dependente para prognose, a área basal das árvores obtidas com a equação 04.

$$g (m^2) = \frac{(\pi * DAP^2)}{40000} \quad (\text{equação 04}).$$

Em que: g é a área basal e DAP o diâmetro a 1,30 m do solo.

Embora pouco aplicados no país, MAI são importantes nos casos em que se intenciona a produção de madeira nobre ou de uso múltiplo e podem ser obtidos a partir de ajustes de regressão lineares e não lineares ou com técnicas de inteligência artificial (CASTRO, et al., 2013). Neste contexto, Regressão linear múltipla, Pienaar e Schiver (1981) e regressão logística são abordagens de fácil aplicação comumente empregados (CAMPOS & LEITE, 2017; ZEIDE, 1989). Alternativamente, tem-se ampliado a aplicação de algoritmos de aprendizado de máquina para diferentes fins nas ciências florestais. Estes algoritmos, quando comparados aos modelos clássicos são mais flexíveis e possuem maior potencial de generalização em função da aplicação de técnicas como a validação cruzada que garante que os modelos de machine learning não sejam superajustados a um conjunto específico de dados (ABREU, 2019).

COSTA-FILHO, et al., 2019 , ao avaliar quatro algoritmos de aprendizado de máquinas para modelagem da relação hipsométrica de povoamentos de *Pinus taeda* L. em diferentes idades, adotou pesquisa em grade combinada com validação cruzada k-fold para encontrar os melhores parâmetros dentro de um conjunto de parâmetros avaliados para cada um dos modelos. Aplicamos então pesquisa em grade combinada com validação cruzada ShuffleSplit, pois de acordo com a documentação do scikit-learn diferente de k-fold, ShuffleSplit realiza a aleatorização dos dados antes de realizar cada uma das divisões dos diferentes conjuntos de treino e teste. Foram consideradas cinco iterações e uma proporção de 70:30 para treino e teste respectivamente, para avaliação dos cinco algoritmos de aprendizado de máquinas avaliados, tendo sido eles árvore de decisão, floresta aleatória, redes neurais artificiais do tipo Multilayer Perceptron, regressão com vetor de suporte e algoritmo do vizinho mais próximo. Todos os ajustes foram procedidos com suas respectivas funções disponíveis na bibliotecas scikit-learn para os modelos de aprendizado de máquinas e scipy. optimize para os modelos clássicos, sendo tais pacotes disponíveis em linguagem Python de Programação.

Para avaliação de desempenho dos modelos, computou-se o erro médio quadrático (MSE), erro médio absoluto, coeficiente de determinação (R^2) para cada um dos ajustes, empregando-se as médias entre as métricas de treino e teste para os algoritmos de aprendizagem de máquinas. Para todos os ajustes foram plotados gráficos de correlação e gráficos de resíduos percentuais, tendo-se no final, ranqueado o desempenho dos através do R^2 , uma vez que está métrica melhor capta o desempenho dos ajustes de maneira mais independente da escala das variáveis dependentes do que o MAE e o MSE (CHICCO, et al., 2021).

Em cada um dos ajustes e para os algoritmos de aprendizado de máquinas, os valores envolvidos nas pesquisas em grade e nos ajustes foram definidos arbitrariamente. Em cada uma das idades, considerando cada uma das linhas de plantio, fez-se o computo da altura dominante (HD1) como sendo a média de altura de 20% das árvores com maiores DAP (OLIVEIRA, 2015) e do índice de competição (IC1) como sendo a razão entre área basal da árvore e a área basal média da linha de plantio em questão (CAMPOS & LEITE, 2017). Na tabela 01, tem-se os modelos clássicos aplicados para prognose florestal ao passo que os valores empregados nas pesquisas em grades encontram-se nas demais tabelas relacionadas a cada uma das abordagens.

Tabela 1: Características dos modelos ajustados para prognose de área basal em nível de árvore individual com dados de inventário florestal contínuo realizado em iLPF de 15 hectares em Jaborandi – BA.

Técnica	Variáveis	Modelos
Regressão linear múltipla	Area basal 01 (m²), Altura dominante (m), Índice de competição, Idade 01 e Idade 02.	$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5$
Ajuste logístico	Area basal 01 (m²)	$Y = \frac{\beta_0}{1 + \beta_1 * e^{\beta_3 * x}}$
Pienaar e Schiver (1981)	Area basal 01(m²), Idade 01 e Idade 02	$Y = X e^{-\beta_0 * (idade_2^{\beta_1} - idade_1^{\beta_1})}$

Y = área basal na idade 2.

2.2 Algoritmos empregados de aprendizado de máquinas empregados

2.2.1 Árvores de decisão

As árvores de decisão são modelos de aprendizado supervisionado úteis para prever valores numéricos ou categóricos de uma variável de interesse. Essas estruturas hierárquicas consistem em nós de decisão e folhas terminais, sendo cada nó um teste aplicado aos dados de entrada, direcionando o fluxo para ramos subsequentes ou para folhas terminais (VIEIRA,

2010; DA SILVA, et al., 2019), que determinam o valor predito da variável de interesse (GOMES, 2021). A profundidade de uma árvore de decisão indica a quantidade de observações em cada folha e apesar de uma árvore profunda produzir bons resultados no treinamento, é propensa a overfitting (IZBICKI & SANTOS, 2020).

Para pesquisa em grade para otimização dos hiper parâmetros para o ajuste de árvore de decisão, empregou-se combinações de números de 1 a 100 para cada um dos hiper parâmetros com intervalos de cinco entre os valores após o cinco, de modo que a combinação entre 21 valores, a incluir o 1, foram testados (Tabela 01).

Tabela 2: Variáveis e Hiper parâmetros empregados para ajuste de árvore de decisão com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF

Variáveis do modelo	Hiper parâmetros avaliados		
	Profundidade máxima	Mínimo de Amostras para Divisão	Mínimo de Amostras por Folha
	1	1	1
Area basal (m ²), Altura	5	5	5
dominante (m), Índice de	10	10	10
competição, Idade 01 e	.	.	.
Idade 02.	.	.	.
	100	100	100

2.2.2 Floresta Aleatória

Floresta Aleatória foi o segundo algoritmo de aprendizado de máquina avaliado. Esta técnica combina diversas árvores de decisão individuais para realizar previsões. Cada árvore é treinada em uma amostra de dados aleatória com substituição e usa uma seleção aleatória de atributos. Este método visa melhorar a eficácia das previsões, compensando as limitações das árvores individuais (IZBICKI & SANTOS, 2020, p. 82).

A combinação de previsões de várias árvores visa superar os pontos fracos de uma única árvore, resultando em estimativas mais confiáveis, especialmente em problemas de regressão (WANG, et al., 2016). Da mesma forma que para árvores de decisão, considerou-se intervalos com incrementos contínuos após de cinco após 1 e 5, no entanto considerando limite superior dos valores de hiper parâmetros considerados na pesquisa em grade iguais a 50 (Tabela 03).

Tabela 3: Variáveis e Hiper parâmetros empregados para ajuste de Floresta Aleatória com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF

Variáveis do modelo	Hiper parâmetros avaliados			
	Número de estimadores	Profundidade máxima das árvores	Mínimo de amostras para divisão	Mínimo de amostras por folhas
Area basal (m ²)	1	1	1	1
Altura dominante (m), Índice de competição, Idade 01 e Idade 02.	5	5	5	5
	10	10	10	10
	.	.	.	.
	.	.	.	.
	50	50	50	50

2.2.3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são sistemas computacionais paralelos, compostos por várias unidades de processamento (neurônios artificiais). Essas redes são aplicadas na aproximação de funções, visando modelar o mapeamento entre pares de entrada e saída de um conjunto de treinamento (DA SILVA, 2010). Contudo, a definição da arquitetura ótima de uma RNA para um problema específico é desafiadora, dadas as variações nos parâmetros durante o treinamento (CORDEIRO, et al., 2022)

Segundo FLECK, et al., 2016 , uma das principais dificuldades ao usar redes neurais é estabelecer uma arquitetura adequada. Diversas formas de RNAs são propostas, variando em número de neurônios, funções de ativação, camadas ocultas, e conexões entre neurônios. A escolha da quantidade de neurônios na camada oculta é crucial para evitar *overfitting* e *underfitting* (BUENO, et al., 2020). Entretanto há indícios de que estruturas complexas não são sempre necessárias para a estimação de variáveis dendrométricas (BINOTI, et al., 2014). As MLPs (Perceptron Multicamadas) são um tipo de RNA com arquitetura feedforward, compreendendo camadas de entrada e saída obrigatórias, e camadas ocultas opcionais, úteis para capturar relações não lineares (SANTOS, 2019).

A função de ativação em uma RNA é crucial para aprender relações não lineares entre dados de entrada e saída. O parâmetro "alpha" controla a força da penalidade L2 (regularização Ridge) aplicada aos parâmetros da RNA, sendo relevante para a generalização do modelo (CORREIA, 2022; PASSOS, 2022) Na tabela 03, encontram-se os valores empregados para pesquisa em grade das redes.

Tabela 4: Variáveis e Hiper parâmetros empregados para ajuste de Rede Neural Artificial com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF.

Variáveis empregadas	Hiper parâmetros avaliados					
	Nº de camadas ocultas	Nº de neurônios camada 01	Nº de neurônios camada 02	Nº de neurônios camada 03	Funções de ativação avaliadas	Taxas de penalização avaliadas
Area basal (m²) Altura dominante (m), Índice de competição, Idade 01 e Idade 02.	1	1	-	-	relu (Rectified Linear Unit)	0,0001
	1	2	-	-	tanh (tangente hiperbólica).	0,001
	1	3	-	-	-	0,01
	1	4	-	-	-	-
	1	5	-	-	-	-
	1	6	-	-	-	-
	1	7	-	-	-	-
	1	8	-	-	-	-
	1	9	-	-	-	-
	1	10	-	-	-	-
	2	1	1	-	-	-
	2	2	2	-	-	-
	2	2	3	-	-	-
	2	2	4	-	-	-
	2	5	5	-	-	-
	2	5	3	-	-	-
	2	5	4	-	-	-
	2	5	5	-	-	-
	2	10	2	-	-	-
	2	10	10	-	-	-
	3	50	50	50	-	-
	3	100	-	-	-	-
	3	100	100	-	-	-

2.2.4 Regressão com vetor de suporte

O algoritmo de Support Vector Regression (SVR) é uma técnica de regressão baseada em vetores de suporte, buscando encontrar a melhor função de regressão para mapear os dados de entrada às saídas correspondentes (ZUBA et al., 2019). Vetores de suporte são pontos críticos para o modelo SVR, determinando-o totalmente (IVANOVA, 2020; HAYKIN, 2001; SANTOS, 2002).

Os hiper parâmetros "C", "epsilon" e "kernel" desempenham papéis fundamentais na flexibilidade e desempenho da função de regressão. Em resumo, C ajusta a margem e a penalização por erros, epsilon define a tolerância a erros e o kernel define a similaridade entre pontos (HAYKIN, 2001). Na tabela 04 tem-se os valores de "C", "epsilon" e "kernel" empregados nas combinações da pesquisa em grade.

Tabela 5: Variáveis e Hiper parâmetros empregados para ajuste de Regressão com vetor de suporte com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF.

Variáveis empregadas	Hiper parâmetros avaliados		
	Regularização	Faixa de Insensibilidade	Tipo de kernel
Area basal (m ²) Altura dominante (m), índice de competição, Idade 01 e Idade 02.	0,1	0,01	Linear
	1	0,1	Função de base radial
	10	1	polinomial

2.2.5 Algoritmo do Vizinho mais próximo.

O algoritmo K-Nearest Neighbors (K-NN) é um método de aprendizado de máquina que utiliza a similaridade local entre dados para realizar previsões. Ele funciona através da seleção dos "k" vizinhos mais próximos da árvore de interesse, com base em características semelhantes.

Os vizinhos podem ser ponderados de acordo com sua distância da árvore, com os mais próximos tendo maior influência na estimativa final. O valor de interesse para a árvore é então calculado como a média ponderada dos valores dos "k" vizinhos selecionados, cuja escolha do valor pode ser crucial para o desempenho do algoritmo (ARAGÃO, et al., 2019; JUNIOR, 2022).

Tabela 6: Variáveis e Hiper parâmetros empregados para ajuste de algoritmo do vizinho mais próximo com pesquisa em grade com dados oriundos de IFC contínuos coletados em Sistemas iLPF.

Variáveis empregadas	Hiper parâmetros avaliados		
	Nº de vizinhos	Pesos dos vizinhos	Algoritmo
	3	Uniforme	Auto
Area basal (m ²)	5	baseado em distância	Ball Tree
Altura dominante	7	-	KD Tree
(m), índice de competição,	9	-	Brute Force
Idade 01 e Idade 02.	11	-	-
	13	-	-
	15	-	-

Em todos os ajustes relacionados a aprendizagem de máquinas, fez-se pesquisa em grade com validação cruzada verificando-se a qualidade de ajustes realizados como cada uma das possíveis combinações de todos os hiper parâmetros avaliados, de modo que, para árvore de decisão, foram avaliadas 9.261 combinações, 1331 combinações para floresta aleatória, 38.088 para redes neurais, 27 para algoritmo com vetor de suporte e 56 para algoritmo do vizinho mais próximo.

Os resultados obtidos com cada um dos ajustes foram submetidos a teste de Shapiro-Wilk para verificar a normalidade dos resíduos das estimativas e teste de Levene para verificar a homogeneidade das variâncias em cada um dos grupos e em seguida submetidos a testes paramétricos e não paramétricos para inferências acerca da equivalência estatísticas dentre as estimativas.

Com o melhor ajuste encontrado, realizou-se as projeções para prognose do crescimento em área basal das árvores até os 97 meses, a cada 12 meses. Para tal, os dados foram organizados em esquema de projeção e a partir dos dados coletados, cada ciclo passou a considerar a idade i como sendo a idade $i + 12$ do ciclo anterior. Quanto à altura dominante e índice de competição, para cada um dos ciclos projetados, empregou-se os valores encontrado no ciclo anterior imediatamente anterior, que eram constantemente atualizados. Após projetar área basal e convertê-la à DAP, empregou-se a equação para estimar altura, fez-se o computo da altura dominante e dos índices de competição para servir de input do próximo ciclo de projeção.

3 RESULTADOS

3.1 Produção florestal.

Sobre o DAP e a altura das árvores, constatou-se que o povoamento passou de uma média 9,06 cm e 6,63 m para 20,65 cm e 17,89 m respectivamente, entre o primeiro inventário, realizado 21 meses e o inventário realizado 61 meses (Tabela 07).

Tabela 7: Resultados quantitativos de cinco inventários florestais (censos) realizados em um Sistema de Integração Lavoura Pecuária Floresta em Jaborandi – BA

Idade (meses)	DAP (cm)					Altura (m)				
	Mínimo	μ	$\pm$	σ	Máximo	Mínimo	μ	$\pm$	σ	Máximo
21	1,15	9,06	$\pm$	1,50	14,26	0,61	6,64	$\pm$	0,64	7,63
31	0,95	12,35	$\pm$	1,63	23,55	0,00	10,09	$\pm$	1,06	13,98
39	1,46	15,09	$\pm$	1,76	22,92	0,07	11,42	$\pm$	0,93	16,78
49	5,03	17,79	$\pm$	1,96	27,06	7,18	16,74	$\pm$	1,08	20,80
61	10,82	20,65	$\pm$	1,90	29,92	10,30	17,89	$\pm$	1,18	24,10

Na Tabela 8 são apresentados os resultados da análise descritiva da produção do componente florestal, em cada uma das medições. A produção volumétrica foi igual a 44,43 m³/ha, representando uma estocagem de carbono de 10,04 toneladas por hectare aos 61 meses. Destaca-se que o componente florestal está em fase de desenvolvimento e que será conduzido até aproximadamente 10 anos. Deve-se, no entanto, considerar que os modelos ainda não contemplam essa faixa de idade final, podendo incorrer em erros de prognose por desconhecimento da tendência de crescimento no local.


Tabela 8: Parâmetros de produção do componente florestal representado pelo fuste de *Eucalyptus* spp. em sistema ILPF de 15 hectares no sul da Bahia, aos cinco anos de idade.

Estimativas	21 meses	31 meses	39 meses	49 meses	61 meses
Média de volume individual (m ³)	0,0212	0,0591	0,0988	0,1995	0,2852
Volume total (m ³)	49,9431	138,3162	231,6881	466,8032	666,4180
Volume total (m ³ /ha)	3,3295	9,2211	15,4459	31,1202	44,4279
Densidade básica do fuste (kg/m ³)				452,11	
Biomassa (ton./ha)	1,5053	4,1689	6,9832	14,0698	20,0863
Carbono (ton./ha)	0,7527	2,0845	3,4916	7,0349	10,0431
IMA (m ³ /ha/ano)	1,9026	3,5695	4,7526	7,6213	8,7399
Média de DAP (cm)	9,06	12,35	15,09	17,79	20,65
B (m ² /ha)	1,0433	1,9004	2,8343	3,9237	5,2634
Média de Altura (cm)	6,64	10,09	11,42	16,74	17,89
N	2355	2340	2340	2340	2340

Em que IMA é o incremento médio anual, B é a área basal e N é o número de árvores vivas por hectare (CAMPOS & LEITE, 2017).

A distribuição diamétrica do povoamento com dados de cada um dos inventários realizados evidenciam o desenvolvimento inicial do povoamento, sendo o menor achatamento da curva aos 39 meses atrelado a diferentes fatores que podem estar associados ao estágio de desenvolvimento do povoamento, as condições climáticas durante o período e a aplicações de técnicas de manejos nos componentes agrícolas e florestais do sistema (Figura 02).

Figura 2: Distribuição diamétrica de árvores de *Eucalyptus* spp. em sistema iLPF no sul da Bahia, medidas em cinco ocasiões.



3.2 Modelos de projeção

Todos os modelos avaliados foram consistentes para prognose da área basal do componente florestal. No entanto, para os modelos baseados em árvores e com o algoritmo do vizinho mais próximo notou-se severa degradação nas projeções com o avançar das idades evidenciada pela tendência de resultados com valores únicos, podendo então estas técnicas serem aplicadas em projetos com horizontes de planejamento mais curtos, permitindo estimativas futuras para um ou dois anos. Desta forma, considerou-se para prognose até os 97 meses, a regressão linear múltipla pois embora não tenha apresentado o maior coeficiente de

determinação, foi a abordagem que melhor se adequou ao comportamento que se espera do desenvolvimento de um componente florestal em iLPF (Tabela 9). Na tabela 10, se encontram os parâmetros dos modelos clássicos avaliados e os hiper parâmetros encontrados para cada um dos ajustes com algoritmos de aprendizado de máquinas.


Tabela 9: Métricas de avaliação de oito modelos aplicados a prognose do componente florestal (*Eucalyptus* spp.) em sistema iLPF no sul da Bahia.


Ajustes	Treino			Teste			Média		
	MAE	MSE	R ²	MAE	MSE	R ²	MAE	MSE	R ²
Reg. linear múltipla	0,00204	0,00001	0,869				0,00206	0,00001	0,869
Floresta aleatória	0,00177	0,00001	0,903	0,00199	0,00001	0,872	0,00188	0,00001	0,887
Vizinho mais próximo	0,00179	0,00001	0,899	0,00205	0,00001	0,868	0,00192	0,00001	0,883
Árvore de decisão	0,00182	0,00001	0,899	0,00205	0,00001	0,864	0,00194	0,00001	0,881
Ajuste logístico	0,00204	0,00001	0,859				0,00204	0,00001	0,859
Reg. c. vetor de suporte	0,00280	0,00001	0,834	0,00290	0,00002	0,824	0,00285	0,00001	0,829
Piennae e Schiver	0,00234	0,00002	0,823				0,00234	0,00002	0,823
Rede Neural Artificial	0,00442	0,00003	0,664	0,00448	0,00003	0,666	0,00445	0,00003	0,665

Tabela 10: Parâmetros dos modelos clássicos e hiper parâmetros dos algoritmos de aprendizado de máquinas aplicados para projeção em nível de árvores individuais representado pelo fuste de *Eucalyptus* spp. em sistema ILPF de 15 hectares no sul da Bahia, encontrados por pesquisa em grade.

Parâmetros e hiper parâmetros dos modelos avaliados		
Floresta aleatória	Nº de estimadores	16
	Profundidade máxima	6
	Mínimo de árvores para divisão	41
	Mín. de amostras por folha	1
Vizinho mais próximo	Nº de vizinhos	15
	Pesos dos vizinhos	"uniforme"
	Algoritmo	"ball tree"
Árvore de decisão	Profundidade máxima	6
	Mínimo de amostras para divisão	42
	Mínimo de amostras por folha	1
Regressão linear múltipla	B0	-0.00679773338243371
	B1	0.6355797736667143
	B2	-0.0001345298887402199
	B3	0.0003725602326621188
	B4	0.004739821017279641
	B5	0.0002103924604565234
Logística	a	0,0447449
	b	5,57500739
	c	109,459526
Piennae e Schiver (1981)	B0	-4465,799848514941
	B1	0.00030659462306447625
Regressão com vetor de suporte	P. Regularização	0,1
	Faixa de Insensibilidade	0,01
	Kernel	linear
Rede Neural Artificial	Nº de camadas ocultas	3
	Nº de neurônios camada oculta 1	5
	Nº de neurônios camada oculta 2	8
	Nº de neurônios camada oculta 3	1
	Função de ativação	relu
	Taxa de penalização	0,0001

Figura 3: Figura 3: Figura 3: Gráficos com valores estimados e observados (A) e gráficos de resíduos percentuais (B) para os ajustes realizados com as diferentes técnicas.






Com as projeções de área basal futura, obtidas com cada um dos métodos, realizou-se teste de Shapiro-Wilk para verificar a normalidade das estimativas e teste de Levene para verificar a homogeneidade das variâncias em cada um dos grupos. As variâncias foram homogêneas, no entanto o teste de Shapiro-Wilk indicou não normalidade dos dados, que embora não normais, apresentaram esta tendência em histogramas com distribuição de frequências. Quando comparados em pares com técnicas paramétricas e não paramétricas, verificou-se não haver diferenças estatisticamente significativas entre os grupos.

Com as projeções realizadas com o Regressão linear múltipla, encontrou-se aos 97 meses 187,2262 m³ de madeira por hectare que corresponde a incremento médio anual de 23,1620 m³. ano⁻¹. Empregando-se a densidade básica mensurada aos 49 meses, estima-se que aos 08 anos, o povoamento terá biomassa correspondendo a 84,6468 ton. ha⁻¹, que corresponderiam a sequestro de 42,3234 toneladas de Carbono por hectare (Figura 03).

3.3 Aplicações do Modelo

Figura 4: Área basal (m²) (A), volume (m³) (B) e Biomassa e Carbono (toneladas) (C), hectare no componente arbóreo de um Sistema de iLPF



4 DISCUSSÃO

A partir dos quatro anos, o crescimento de espécies florestais de rápido desenvolvimento, como o *Eucalyptus*, apresentam taxas de incrementos mais elevados que nos anos iniciais. Tem-se então perspectiva de aumento significativo na produção florestal nos anos que se seguem. Ainda, precisa-se considerar que há a estocagem de carbono no sistema radicular, nas copas e nos componentes agrícolas do iLPF que não foram avaliados neste estudo.

Pode-se verificar na Figura 01 que a distribuição diamétrica tende à normalidade comumente observada em florestas plantadas. De uma forma geral, resultados semelhantes foram encontrados por LEITE, et al., 2006 e REINER, et al., 2011 .

Embora LEITE, et al., 1997 , relate que em florestas de eucalipto é esperado que espaçamentos mais amplos apresentem maiores valores de DAP e de produção volumétrica por indivíduo, quando comparada a produção florestal do sistema com estudos correlatos, a produção volumétrica do sistema aos 61 apresentou menor volume médio individual que o encontrado por SALLES, 2010 , aos 44 meses (0,307 m³ em SAF com número médio de árvores igual a 242 por hectare contra 0,2852 m³ tendo 156 árvores por hectare no iLPF aqui avaliado).

Para carbono, o valor encontrado foi inferior ao encontrado por PRASAD, et al., 2012 , aos quatro anos (29,81 ton. ha⁻¹, em SAF com espaçamento de 7 x 1,5 com linhas emparelhadas contra 7,0349 ton.ha⁻¹ com espaçamento mais amplo deste estudo).

A biomassa encontrada aos 61 meses, foi inferior ao valor encontrado por PEZZOPANE, et al., 2021 , sendo 46.9 ton. ha⁻¹ (plantio com fileiras simples e espaçamento de 15 m de distância entre linhas e 2 m entre plantas totalizando 333 árvores ha⁻¹) contra 43,4613 ton.ha⁻¹ no presente estudo.

Ao considerarmos as emissões entéricas oriundas do metabolismo de bovinos iguais 66 kg CH₄ animal⁻¹ ano⁻¹ e o potencial de aquecimento do metano igual a 28 (MYHRE, et al., 2013), assumindo que a média de idade de abate para bovinos no Brasil é de 36 meses (AMARAL, et al., 2021), que um animal emite 198 kg de CH₄ do mês de vida 0 ao mês 36, seria então necessário a captura de 5544 kg de CO₂ para neutralização das emissões do metano emitido por um animal. Tendo-se encontrado estimativa de carbono igual a 634,8513 toneladas aos 97 meses, podemos considerar que as árvores presentes na área total do iLPF se manejadas

até os oito anos, possuem potencial para neutralização das emissões de metano correspondente a aproximadamente 115 animais.

Frente ao exposto, conclui-se ser a iLPF, uma estratégia eficaz com potencial para mitigação das mudanças climáticas através do sequestro de carbono, promoção do bem-estar animal através da termorregulação promovida pelas árvores e para contribuir com as reduções de disparidades econômicas e sociais tão pungentes no país, através da diversificação da renda e da geração de novos empregos. Para tal, tem-se a necessidade de que novos estudos sejam orientados quanto a melhorias contínuas e adaptação nos sistemas de integração, com vistas a maximização dos seus benefícios sociais, econômicos e ambientais em consonância com as distintas realidades de potenciais produtores agroflorestais.

5 CONCLUSÕES

- Quanto a produção florestal mensurada, aos 61 meses (5,08 anos), a produção florestal encontrada no fuste dos componentes arbóreos de um Sistema de iLPF em Jaborandi na Bahia foi de $44,4279 \text{ m}^2 \cdot \text{ha}^{-1}$ que correspondem a $20,0863 \text{ ton} \cdot \text{ha}^{-1}$ de biomassa das quais $10,0431 \text{ to} \cdot \text{ha}^{-1}$ corresponde a Carbono;
- Para realização das projeções para além do período para o qual se conhece os dados, as diferentes abordagens avaliadas para obtenção de um modelo em nível de árvore individual para o sistema foram consistentes para prognose da área basal ao longo do tempo, ficando árvore de decisão, floresta aleatória e algoritmo do vizinho mais próximo restrito a horizontes mais curtos de planejamento;
- A melhor abordagem encontrada foi regressão linear múltipla, sendo que com suas estimativas, projeta-se haver no oitavo ano do plantio, carbono suficiente para neutralizar as emissões entéricas de aproximadamente 7 animais por hectare.

6 REFERÊNCIAS

- ABREU, J. C., 2019. Alternativas para estimar o volume de árvores individuais em formações florestais no estado de Minas Gerais. *Dissertação de Mestrado -Programa de Pós-Graduação em Ciência Florestal - UFV*.
- ALVES, F. V., Almeida, R. G. d. & Laura, V. A., 2015. *Carne Carbono Neutro: um novo conceito para carne sustentável produzida nos trópicos*. s.l.:Embrapa.
- ALVES, F. V., y Porfírio-da-Silva, V. & Karvatte, N. J., 2019. Bem-estar animal e ambiência na ILPF.. Em: *ILPF inovação com integração de lavoura, pecuária e floresta*. s.l.:Embrapa, pp. 207-223.
- AMARAL, T. B., GOMES, R. d. C. & ROSA, G. J. M., 2021. *Produção de Novilho Precoce no Estado de Mato Grosso do Sul ISSN 1983-9731 Análise exploratória de dados do Programa PROAPE-Precoce MS*. Brasília(DF.): Embrapa.
- ARAGÃO, M. d. A., Santos, J. S. & da Silva, M. L. M., 2019. Técnica de mineração de dados aplicada na estimação do volume de árvores de Eucalyptus. *V SEEFLORE - BA. Semana de Engenharia Florestal da Bahia - II mostra de Pós graduação em ciências florestais da UESB*..
- BINOTI, D., BINITI, M. & LEITE, H., 2014. Configuração de redes neurais artificiais para estimação do volume de árvores. *Revista Ciência da Madeira (Brazilian Journal of Wood Science)*, pp. 10-12953.
- BUENO, G. et al., 2020. Efeito do número de neurônios na camada oculta para relações hipsométricas de eucalipto usando redes neurais artificiais.. *BIOFIX Scientific Journal*, pp. 222-230.
- CAMPOS, J. C. C. & LEITE, H. G., 2017. *Mensuração Florestal - Perguntas e Respostas*. Viçosa: UFV.
- Campos, J. C. C. & Leite, H. G., 2017. Modelos de árvores individuais. Em: *Mensuração Florestal - Perguntas e Respostas*. 5ª ed. s.l.:UFV, pp. 497-508.
- CASTRO, R. V. O., SOARES, C. P. B., MARTINS, B. F. & LEITE, H. G., 2013. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. *Pesquisa Agropecuária Brasileira*, Volume 48.

CHICCO, D., WARRENS, M. & JURMAN, G., 2021. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, p. e623.

CORDEIRO, M. et al., 2022. Estimativas volumétricas em povoamentos de eucalipto utilizando máquinas de vetores de suporte e redes neurais artificiais. *Madera y bosques*.

CORREIA, J. Z., 2022. Modelagem computacional de arranjo em série de antenas patch retangular utilizando métodos de aprendizado de máquina.

COSTA-FILHO, S., ARCE, J., MONTAÑO, R. & PELISSARI, A., 2019. Configuração de algoritmos de aprendizado de máquina na modelagem florestal: um estudo de caso na modelagem da relação hipsométrica. *Ciência Florestal*, pp. 1501-1515.

DA SILVA, F. M., LENZ, M. L., FREITAS, P. H. C. & DOS SANTOS, S. C. B., 2019. *Inteligência Artificial*. Porto Alegre: SAGAH.

DA SILVA, M. L. M., 2010. *Redes Neurais Artificiais para prognose de povoamentos não desbastados de eucalipto*. Viçosa: Dissertação de Mestrado - UFV..

Dos Santos, F. C. et al., 2018. *A agropecuária do sul do Matopiba em perspectiva: Circuito solos arenosos da região Cocos-Jaborandi*. Sete Lagoas(MG): Embrapa.

EMBRAPA, 2018. *Visão 2030 : o futuro da agricultura brasileira*. Brasília: Embrapa.

FERREIRA, I. C. et al., 2021. Produção de Leite em Sistema de Integração Lavoura-PecuáriaFloresta (ILPF) no Bioma Cerrado. *BOLETIM DE PESQUISA E DESENVOLVIMENTO*, Volume 375.

FLECK, L. et al., 2016. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, pp. 47-57.

GOMES, L. V., 2021. *Aplicação de metodologias estatísticas e machine learning para validação de analisadores contínuos para indústria de celulose*. [Online]
Available at:
https://dspace.unipampa.edu.br/jspui/bitstream/riu/5756/1/TCC_LARISSA_VIEIRA_GOMES_2021.pdf.

HAYKIN, S., 2001. *Redes Neurais Princípios e prática*. 2ª ed. s.l.:Bookman.

HOUGHTON, J. et al., 1996. *Revised 1996 IPCC Guidelines for National Greenhouse Gas Inventories*, Bracknell: The Intergovernmental Panel on Climate Change (IPCC).

IBGE, 2021. *Pecuária - Visão Geral*. [Online]

Available at:

<https://observatorio.agropecuaria.inmet.gov.br/paineis/pecuaria/bovinos/visaoGeral>

[Acesso em 10 July 2023].

IVANOVA, D., 2020. *Support Vector Regression desde una perspectiva multiobjetivo: Una aplicación a la esperanza de vida*. s.l.:s.n.

IZBICKI, R. & SANTOS, T. M., 2020. *Aprendizado de Máquinas uma abordagem estatística*. s.l.:s.n.

JUNIOR, D. P., 2022. Previsão de potência gerada por sistema fotovoltaico na cidade de Foz do Iguaçu de acordo com dados meteorológicos.

LEITE, F., NOVAIS, R. S. L. & FABRES, A., 1997. Crescimento de *Eucalyptus grandis* em diferentes densidades populacionais. *Revista Árvore*, jul-set, pp. 313-321.

LEITE, H. et al., 2006. Um modelo de distribuição diamétrica para povoamentos de *Tectona grandis* submetidos a desbaste. *Revista Árvore*, pp. 89-98.

Lima, E. d. S. et al., 2017. Classificação do desenvolvimento inicial do eucalipto utilizando técnicas de mineração de dados. *Cerne*, 23(2), pp. 201-208.

MAPA, 2023. *Ministério da Agricultura e Pecuária*. [Online]

Available at: <https://www.gov.br/agricultura/pt-br/assuntos/sustentabilidade/agricultura-de-baixa-emissao-de-carbono/abc/programas-e-estrategias>

[Acesso em 07 novembro 2023].

MAXIMO, I. Y., HASSEGAWA, M., VERKERK, J. & MISSIO, L. A., 2022. Forest Bioeconomy in Brazil: Potential Innovative Products from the Forest Sector. *Land*, p. 1297.

MELOTTO, A. M., LAURA, V. A. & J., B. D., 2019. Espécies florestais em sistemas de produção em integração.. Em: *ILPF - inovação com integração de lavoura, pecuária e floresta*.. Brasília: Embrapa.

MORAES, K. K. S. et al., 2014. *Densidade básica e crescimento de eucaliptos em Vilhena, Rondônia*. s.l.:s.n.

MYHRE, G. et al., 2013. *Global Warming Potential Values*. [Online]
Available at: https://ghgprotocol.org/sites/default/files/ghgp/Global-Warming-Potential-Values%20%28Feb%2016%202016%29_1.pdf
[Acesso em 7 August 2023].

NBRISO14064-1, 2022. *Gases de efeito estufa - Parte 1: Especificação com orientação no nível da organização para quantificação e notificação de emissões e remoções de gases de efeito estufa*. s.l.:s.n.

OECD/FAO, 2022. *OECD-FAO Agricultural Outlook 2022-2031*, Paris: OECD Publishing.

OLIVEIRA, E. B. d., 2015. *Softwares para manejo de precisão de plantações florestais*. Brasília: Embrapa.

PASSOS, L. F. C., 2022. Métodos de Regularização no Aprendizado de Máquinas: Ridge e LASSO..

PEREIRA, M. d. A., OLIVEIRA, P. S. d. & ALMEIDA, R. G. d., 2019. Viabilidade econômica de um sistema silvipastoril: contribuição do protocolo Carne Carbono Neutro.. *CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA, ADMINISTRAÇÃO E SOCIOLOGIA RURAL*.

PEZZOPANE, J. et al., 2021. Managing eucalyptus trees in agroforestry systems: Productivity parameters and PAR transmittance. *Agriculture, Ecosystems and Environment*.

PRASAD, J., SRINIVAS, C. S. R. R. C. V. K. & VENKATESWARLU, B., 2012. Biomass productivity and carbon stocks of farm forestry and agroforestry systems of leucaena and eucalyptus in Andhra Pradesh, India. *Current Science*, pp. 536-540.

redeILPF, 2021. *ILPF em números - safra 2020/21*. s.l.:s.n.

REINER, D., SILVEIRA, R. & SZABO, M., 2011. O uso do eucalipto em diferentes espaçamentos como alternativa de renda e suprimento da pequena propriedade na região sudoeste do Paraná.. *Synergismus scyentifica UTFPR*.

Resende, L. d. O. et al., 2020. Silvopastoral management of beef cattle production for neutralizing the environmental impact of enteric methane emission. *Agroforestry Systems - An International Journal incorporating Agroforestry Forum*, 94(1), pp. 893-903.

SALLES, T. T., 2010. Modelagem de crescimento e produção de clones de eucalipto em um sistema agroflorestal..

SANTOS, A. P., 2019. Análise e comparação do desempenho de diferentes arquiteturas de redes neurais artificiais profundas aplicadas á triagem de lesões de pele.

SANTOS, E. M., 2002. eoria e Aplicação de Support Vector Machines à Aprendizagem e Reconhecimento de Objetos Baseado na Aparência..

SOARES, C., DEPAULA NETO, F. & DE SOUZA, A., 2017. *Dendrometria e Inventário Florestal*. Viçosa: UFV.

Telles, M. A. & et al., 2021. *Glossário ILPF: Integração Lavoura-Pecuária-Floresta*. 1º ed. Colombo: Embrapa Florestas.

TEUGILHO, P. F., SILVA, D., FRAZÃO, F. & MATOS, J., 1990. Comparação de métodos de determinação da densidade básica em madeira. *Acta Amazônica*.

VIEIRA, P. C. d. C., 2010. *Árvores de Regressão*. s.l.:s.n.

WANG, L. et al., 2016. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. *The Crop Journal*, junho, pp. 212-219.

WRUCK, F. J., LANGE, A. & BEHLING, M., 2019. Produção da lavoura em sistemas de ILPF. Em: *ILPF - Inovação com Integração lavoura, pecuária e floresta*. Brasília: Embrapa.

ZEIDE, B., 1989. Accuracy of equations describing diameter growth.. *Canadian Journal of Forest Research* , pp. 1283-1286.

“1.17. Neural network models (supervised) — scikit-learn 1.3.0 documentation.” *Scikit-learn*, https://scikit-learn.org/stable/modules/neural_networks_supervised.html. Accessed 27 August 2023