

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE CIÊNCIAS AGRÁRIAS
PÓS-GRADUAÇÃO EM AGRONOMIA**

DANIEL BONIFÁCIO OLIVEIRA CARDOSO

**Inteligência computacional na predição de comportamento,
adaptabilidade e estabilidade de algodoeiro de fibra branca e
colorida**

UBERLÂNDIA-MG

2022

DANIEL BONIFÁCIO OLIVEIRA CARDOSO

**Inteligência computacional na predição de comportamento,
adaptabilidade e estabilidade de algodoeiro de fibra branca e
colorida**

Tese apresentada à Universidade Federal de Uberlândia,
como parte das exigências do Programa de Pós-graduação em
Agronomia – doutorado, área de concentração em Fitotecnia,
para obtenção do título de “Doutor”.

Prof.^a Dr.^a Larissa Barbosa de Sousa

UBERLÂNDIA-MG

2022

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

- C268i
2022 Cardoso, Daniel Bonifácio Oliveira, 1982-
Inteligência computacional na predição de comportamento,
adaptabilidade e estabilidade de algodoeiro de fibra branca e colorida
[recurso eletrônico] / Daniel Bonifácio Oliveira Cardoso. - 2022.
- Orientadora: Larissa Barbosa de Sousa.
Tese (Doutorado) - Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Agronomia.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.te.2022.5346>
Inclui bibliografia.
Inclui ilustrações.
- I. Agronomia. I. Sousa, Larissa Barbosa de, 1985-, (Orient.). II.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Agronomia. III. Título.

CDU: 631

Glória Aparecida
Bibliotecária - CRB-6/2047



Documento assinado eletronicamente por **João Paulo Ribeiro de Oliveira, Professor(a) Visitante do Magistério Superior**, em 30/08/2022, às 15:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ana Paula Oliveira Nogueira, Professor(a) do Magistério Superior**, em 31/08/2022, às 15:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Polianna Alves Silva Dias, Usuário Externo**, em 01/09/2022, às 10:04, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Leane Fialho de Melo, Usuário Externo**, em 01/09/2022, às 11:53, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3855351** e o código CRC **C793C959**.



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Secretaria da Coordenação do Programa de Pós-Graduação em Agronomia
 Rodovia BR 050, Km 78, Bloco 1CCG, Sala 206 - Bairro Glória, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 2512-6715/6716 - www.ppga.iciag.ufu.br - posagro@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agronomia				
Defesa de:	Tese, 05/2022, PPGAGRO				
Data:	Vinte e nove de agosto de dois mil e vinte e dois	Hora de início:	14:00	Hora de encerramento:	18:30
Matrícula do Discente:	11813AGR003				
Nome do Discente:	Daniel Bonifácio Oliveira Cardoso				
Título do Trabalho:	Inteligência Computacional na predição de comportamento, adaptabilidade e estabilidade de Algodoeiro de fibra branca e colorida				
Área de concentração:	Fitotecnia				
Linha de pesquisa:	Melhoramento de Plantas				

Reuniu-se no Anfiteatro 4K, Campus Umarama, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agronomia, assim composta: Professores Doutores: Ana Paula Oliveira Nogueira - UFU; João Paulo Ribeiro de Oliveira - UFU; Leane Fialho de Melo - Secretaria Municipal de Desenvolvimento Agrário e Recursos Hídricos; Polianna Alves Silva Dias - Instituto Federal Goiano - Campus Urutai; Larissa Barbosa de Sousa - UFU orientadora do candidato.

Iniciando os trabalhos o presidente da mesa, Dra. Larissa Barbosa de Sousa, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir a senhora presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Larissa Barbosa de Sousa, Professor(a) do Magistério Superior**, em 30/08/2022, às 14:59, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

DANIEL BONIFÁCIO OLIVEIRA CARDOSO

Inteligência computacional na predição de comportamento, adaptabilidade e estabilidade de algodoeiro de fibra branca e colorida

Tese apresentada à Universidade Federal de Uberlândia, como parte das exigências do Programa de Pós-graduação em Agronomia – doutorado, área de concentração em Fitotecnia, para obtenção do título de “Doutor”.

Prof.^a Dr.^a Larissa Barbosa de Sousa

Uberlândia APROVADA em 29 de agosto de 2022.

Prof.^a Dr.^a. Polianna Alves Silva Dias

IFGO

Prof.^a Dr.^a Ana Paula Oliveira Nogueira

UFU/INGEB

Prof. Dr. João Paulo Ribeiro Oliveira

UFU/ICIAG

Dr.^a Leane Fialho de Melo

Prof.^a Dr.^a Larissa Barbosa de Sousa

ICIAG-UFU

(Orientadora)

UBERLÂNDIA

MINAS GERAIS - BRASIL

2022

AGRADECIMENTOS

A Deus, por me dar forças, o dom da vida e a possibilidade de me tornar uma pessoa melhor. Ele é meu refúgio e tento O honrar em minhas atitudes e pensamentos.

Aos meus pais Nilo e Rosângela, pelo amor e apoio em todos os momentos de minha vida e por serem meus referenciais. Obrigado também por transmitirem valores, princípios nos quais me baseio e por me mostrarem o valor da família. Aos meus irmãos Filipe e Clarisse, por todos os momentos alegres e tristes, mas que sempre nos fazem crescer e nos tornam mais unidos.

À minha amada esposa Emilia, pelo amor que veio de Deus, por me apoiar incondicionalmente, por muitas vezes pensar mais em mim do que em si, pelo carinho e ombro amigo nos momentos difíceis dessa caminhada. Por me proporcionar ser pai, do Pedro e Maria Rosa, nossos filhos que mostram o quanto a vida é bonita em seus sorrisos e abraços, minhas razões.

À Prof.^a Dra. Larissa Barbosa de Sousa, pela orientação, amizade, dedicação, compreensão, por acreditar em mim e ter esse dom de se preocupar tanto com cada um. Levarei seus ensinamentos e carinho por toda vida. Eu não poderia ter terminado o curso, muito menos finalizar o mestrado, se não fosse por todo seu apoio acadêmico e amizade.

Agradeço aos membros do Programa de Melhoramento Genético do Algodoeiro da Universidade Federal de Uberlândia, com as amigas que levarei por toda a vida. Elvécio, Michel, Lucas, João Felipe, André, Matheus, Luiza, Cynthia, Vádio, Vinicius, Melissa, Morgana, Daniela, Guilherme, Leandro, Victor, Amaral, Rampelotte, Athos, Gustavos, Celso, PV, Lara, Larissa, Gabriela Xavier, Gabriela Santana, Gabriela Carvalho, Thati, Aragão, Bruna, Danilo, Guilherme, Leticia, Marley, Marianne, Muraoka, Pierre, Lirian, Zanqueta, Murilo, Airson e diversos outros, que nem poderia enumerar.

A todos os professores do Programa de Pós-Graduação em Agronomia da Universidade Federal de Uberlândia, por contribuírem para minha formação acadêmica e concederem a oportunidade de adquirir conhecimentos de grande valia e destacarei dois que me marcaram, Ana Paula por despertar em mim a paixão pelo melhoramento de plantas e a professora Denise, que me fez apaixonar pela estatística e docência. À Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos e Fundação de Amparo à Pesquisa do Estado de Minas Gerais pelo apoio financeiro. A todos aqueles que de alguma forma contribuíram com o planejamento, execução e conclusão desse trabalho.

RESUMO

Para entender melhor as variações de produtividade nas safras, a fim de poder prever o comportamento dos genótipos, o uso da inteligência computacional pode ser uma alternativa, principalmente por permitir inserir nos modelos variáveis ambientais. Pensando nisso, o objetivo deste trabalho foi avaliar o uso de métodos de inteligência computacional para predição de produtividade de algodoeiro utilizando variáveis temporais no estado de Minas Gerais. Os dados de produtividade são provenientes dos municípios mineiros com registro de produção contínua de algodão nos últimos dez anos: Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete e Unaí. Os dados climatológicos foram obtidos mês a mês, sendo dezembro, janeiro, fevereiro, março, abril, maio, maio e junho, em cada ano/safra entre 2010 a 2021 sendo estes: temperatura máxima (°C), temperatura mínima (°C), umidade relativa (%), umidade do solo, umidade na zona de raiz (%), precipitação acumulada (mm) e média da precipitação (mm) totalizando 58 variáveis avaliadas. Foram separados 80% dos dados de entrada para teste do modelo e 20% para testes de treinamento do modelo, utilizando os métodos *Random Forest*, *Regression Trees* e Regressão Linear em suas configurações padrões, com o auxílio dos softwares Genes e Matlab, além dos *software* Python. As variáveis demonstraram efeito significativo ao serem avaliadas segmentadas em meses. O modelo de *machine learning*, baseado em *Random Forest* fornece os melhores resultados de predição comparados aos dados reais, demonstrando serem promissores para estimar a produtividade no estado de Minas Gerais. O uso da inteligência computacional para predição de produtividade utilizando apenas dados climáticos pode inferir com boa precisão para estimar dados de produtividade. O método *machine learning*, *Random Forest* foi o que obteve melhores estimativas em todas as cidades mineiras avaliadas. É necessário um banco de dados mais robusto que contenha mais informações fenotípicas do algodoeiro para melhor precisão dos modelos visando prever a produtividade do algodoeiro em Minas Gerais.

Palavras-chave: Inteligência Computacional; *cotton*; algodão, *Random forest*

ABSTRACT

To better understand yield variations in crops, in order to predict the behavior of genotypes, the use of computational intelligence can be an alternative, mainly by allowing the insertion of environmental variables in the models. With this in mind, the objective of this work was to evaluate the use of computational intelligence methods for cotton yield prediction using temporal variables in the state of Minas Gerais. The data of productivity are from the municipalities of Minas Gerais with continuous production of cotton in the last ten years: Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete and Unaí. The climatological data were obtained month by month, being December, January, February, March, April, May and June, in each year/harvest from 2010 to 2021 being these: maximum temperature (°C), minimum temperature (°C), relative humidity (%), soil moisture, moisture in the root zone (%), accumulated precipitation (mm) and average precipitation (mm) totaling 58 variables evaluated. We separated 80% of the input data for model testing and 20% for model training tests, using the Random Forest, Regression Trees and Linear Regression methods in their standard configurations, with the aid of the software Genes and Matlab, as well as Python software. The variables showed significant effect when segmented into months. The machine learning model, based on Random Forest, provides the best prediction results compared to real data, showing promise for estimating productivity in the state of Minas Gerais. The use of computational intelligence for yield prediction using only climatic data can infer with good accuracy to estimate yield data. The machine learning method, Random Forest was the one that obtained the best estimates in all the evaluated cities of Minas Gerais. A more robust database containing more phenotypic information of the cotton plant is needed for better accuracy of the models aiming to predict cotton yields in Minas Gerais.

Palavras-chave: Inteligência Computacional; *cotton*; algodão, *Random forest*

LISTA DE ILUSTRAÇÕES

Figura 1. Detalhe da coloração da flor de <i>G. hirsutum</i> . Fonte: Promalg,2020.....	21
Figura 2. Detalhe da coloração da flor de <i>G. barbadense</i> , Fonte: Promalg, 2019.....	22
Figura 3. Organização de uma rede neurais de camadas. Camada de Entrada: variáveis de análise. Camadas Intermediárias: onde há o processamento, determinação de pesos sinápticos. Camada de Saída: Resultado apresentado pela rede. Adaptado de Cardoso (2018).	32
Figura 4. Topologia das árvores de decisão. A esquerda a topologia de Decision Tree e a direita a topologia de Random Forest. *= nós	34
Figura 5. Mapa dos municípios de Minas Gerais. Fonte: IBGE 2020.....	36
Figura 6. Correlação de Pearson em cores, para características abióticas, anos e produtividade.	42
Figura 7. Importância dos caracteres abióticas na produtividade de algodoeiro.	43
Figura 8. Correlação os fatores de temperatura, precipitações, umidades relativa e do solo mensais.	45
Figura 9. Síntese do Shapley, com os atributos mais classificados em ordem decrescente (parte superior para inferior). As cores mostram como os valores dos atributos afetam a produtividade	47
Figura 10. Predições comparativas entre os métodos e os valores reais (y_{teste})	48
Figura 11. Efeitos individuais das variáveis na predição de produtividade.	51
Figura 12. Dados meteorológicos no período de 12/2013 a 06/2014, 12/2014 a 06/2015, 12/2015 a 06/2016 e 12/2016 a 30/06/2017.	67
Figura 13. AMMI1 biplot dos efeitos principais da interação e produtividade de algodão em caroço ($kg\ ha^{-1}$) de 12 genótipos de algodoeiro de fibra colorida. A1=ambiente 1(safra 2013/2014, A2=ambiente 2(safra 2014/2015, A3=ambiente 3(safra 2015/2016, A4=ambiente 4(safra 2016/2017.	79

Lista de Tabelas

Tabela 1. Valores referência para as características intrínsecas da fibra.....	27
Tabela 2. Médias de produtividade de algodão em caroço (kg ha^{-1}) nas safras de 2010 a 2020, nas cidades mineiras de Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete e Unaí. Fonte: IBGE, 2022.....	40
Tabela 3. Médias de temperatura ($^{\circ}\text{C}$), Umidade (%) e precipitação (mm) nos municípios de Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete e Unaí, no estado de Minas Gerais entre os anos de 2010 a 2020.....	41
Tabela 4. Previsão da produtividade utilizando Random Forest, apenas com os dados de teste.....	49
Tabela 5. Previsão da produtividade utilizando Decision Tree, apenas com os dados de teste.....	50
Tabela 6. Previsão da produtividade utilizando Regressão Linear, apenas com os dados de teste.....	50
Tabela 7. Lógica fuzzy linguísticas implementadas nos controladores Fuzzy de Sugeno quanto ao comportamento dos genótipos, para adaptabilidade e estabilidade baseado no método de Eberhart e Russell (1966). Adaptado de Carneiro (2015).	71
Tabela 8. Significância dos quadrados médios e coeficientes percentuais da variação experimental para as nove características avaliadas, em 12 genótipos de algodoeiro nas safras 2013/14, 2014/15, 2015/16 e 2016/17.....	74
Tabela 9. Média de produtividade de algodão em caroço (kg ha^{-1}) de 12 genótipos de algodoeiros em quatro safras, na cidade de Uberlândia-MG.	75
Tabela 10. Estimativas dos parâmetros de estabilidade fenotípica geral (P_i), para ambientes favoráveis (P_i^+) e para ambientes desfavoráveis (P_i^-), para produtividade de algodão em caroço pelo método não paramétrico de Lin e Binns (1988), adaptado por Carneiro (1998).	77
Tabela 11. Proporção da SQGxA da interação para cada eixo principal da análise AMMI, para os quatro ambientes e 12 genótipos.....	77
Tabela 12. Entradas padronizadas e classificação quanto ao comportamento Geral, Pouco adaptado, Favorável e Desfavorável de 12 genótipos submetidas ao controlador fuzzy baseado no método de Eberhart e Russell (1966).....	80

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
IBGE	Instituto Brasileira de Geografia e Estatística
UFU	Universidade Federal de Uberlândia

SUMÁRIO

Capítulo 1	14
1. Introdução	15
2. A cultura e o melhoramento do algodoeiro	19
2.1. Importância histórica e econômica	19
2.2. Algodoeiro: Botânica e morfologia	20
2.3. O algodoeiro herbáceo (<i>Gossypium hirsutum</i> L. var. <i>latifolium</i> Hutch.).....	22
2.4. Qualidade da fibra.....	25
2.4.1. Índice de Consistência de fiação (SCI).....	25
2.4.2. Comprimento de Fibra (mm) (UHML).....	25
2.4.3. Uniformidade do Comprimento (UI)	26
2.4.4. Alongamento (ELG).....	26
2.4.5. Resistência (STR)	26
2.4.6. Maturidade (MAT)	26
2.4.7. Micronaire (MIC).....	26
2.4.8. Índice de Fibra Curta (%).....	27
2.4.9. Reflectância.....	27
2.4.10. Grau de Amarelecimento.....	27
2.5. Fatores abióticos no desenvolvimento do algodoeiro	28
2.6. Melhoramento do algodoeiro no Brasil	29
2.7. Inteligência computacional	30
2.8. Predição de produtividade.....	31
2.8.1. Aplicação de Redes Neurais artificiais	31
2.8.2. <i>Random Forest</i> e <i>Decision Tree</i>	33
2.8.3. Fuzzy.....	34
3. Material e métodos	36
3.1. Predição de produtividade nas regiões produtoras de Minas Gerais	36
3.2. Funções de Erro do modelo	37
4. Resultados e discussão	40
5. Conclusões	54
Referencias	Erro! Indicador não definido.
Capítulo 2	60
1. Introdução	64
2. Material e métodos	67
3. Resultados e discussão	74
4. Conclusões	83
Referências	84

Capítulo 1

**Machine learning para predição de produtividade de algodoeiro utilizando fatores
abióticos no estado de Minas Gerais**

1*Introdução*

1. INTRODUÇÃO

O algodoeiro (*Gossypium ssp*)- Malvaceae, há identificados 54 espécies pertencentes ao gênero, contudo apenas as que produzem fibras são de interesse comercial (BORÉM; FREIRE, 2014; HUANG et al., 2020).

Dentre as espécies mais cultivadas no mundo *G. hirsutum* L. e *G. barbadense* são responsáveis por 95% da produção mundial de fibras, sendo a espécie *G. hirsutum* responsáveis por quase toda a totalidade deste percentual de produção (GADELHA et al., 2014).

O algodão é a principal fibra têxtil natural, sendo responsável pela vestimenta de 50% da população do mundo (MORAIS et al., 2021) e o caroço com alto teor de óleo, ainda movimentava diversos setores, desde grandes produtores, agricultura familiar e até setores industriais (BORÉM; FREIRE, 2014).

No mundo, a produção para a safra 2021/2022 é estimada em 26 milhões de toneladas de algodão. Isso representa um aumento de produção de 5% em relação à safra anterior, muito influenciada negativamente pela pandemia de Covid-19 devido às restrições de contato, que afetou o consumo e produção mundial (INTERNATIONAL COTTON ADVISORY COMMITTEE -ICAC, 2022).

No Brasil a cultura se encontra em plena expansão com grande relevância econômica. A estimativa de área plantada é de 1,5 mil hectares, com expectativa de produção de 2,7 milhões toneladas de pluma, aumento de 12% com safra anterior (COMPANHIA NACIONAL DE ABASTECIMENTO-CONAB, 2022), justificado pelo alto preço do petróleo, condições ambientais favoráveis ao cultivo. Os estados de Mato Grosso e Bahia correspondem por mais de 85% da área cultivada, seguidos por Minas Gerais com área de 25 mil hectares na safra 2021/2022, aumento de 2% em relação à safra anterior (CONAB, 2022).

Contudo, mesmo com expansão das áreas agrícolas ainda é necessário maximizar a produção, pois mesmo que toda área agricultável seja utilizada, ainda não seria suficiente para atender a demanda da crescente população mundial em diversas frentes da agricultura (SAATH; FACHINELLO, 2018).

Outro contraponto na produção de plumas é o alto custo de produção, que envolvem principalmente dificuldades de manejo de patógenos e condições adversas do meio, e uma das estratégias mais econômicas e eficientes para resolver esses problemas é o melhoramento genético de plantas (IMEA, 2022).

O melhoramento genético é uma ferramenta que possibilita o desenvolvimento de cultivares com maior produtividade e melhor qualidade de fibra, por meio do acúmulo de alelos favoráveis para uma ou mais características de interesse, por meio de hibridações artificiais (CRUZ; CARNEIRO; REGAZZI, 2014). A inteligência artificial pode contribuir para a obtenção de genótipos superiores (CRUZ; NASCIMENTO, 2018).

Todavia mesmo que se obtenha genótipos com alto potencial produtivo, ainda é necessário entender sua resposta em diferentes ambientes. As condições do meio como temperatura, precipitações, umidade, solo e manejo são determinantes para a expressão gênica (CRUZ; CARNEIRO; REGAZZI, 2014).

Para entender as respostas dos genótipos frente as oscilações ambientais, o estudo da interação genótipos x ambientes (GxA) demonstra como o ambiente interfere na expressão fenotípica e a natureza desta interação (CRUZ; CARNEIRO; REGAZZI, 2014).

Os estudos de GxA, em grande parte, não leva em consideração dados meteorológicos e/ou de clima, ou quando existem esses dados são estudos de curto prazo, devido a celeridade que os programas de melhoramento exigem para o lançamento de cultivares, não considerando alterações abióticas inerentes do ambiente.

Essas variações no ambiente refletem em oscilações de produtividade e qualidade de fibra. Cardoso et al. (2021) encontraram variações em até 72% da produtividade entre os mesmos genótipos de algodoeiro de fibra colorida em diferentes anos safra, devido a variações abióticas.

Para entender melhor essas variações de produtividade nas safras, a fim de poder prever o comportamento dos genótipos, o uso da inteligência computacional pode ser uma alternativa, principalmente por permitir inserir variáveis ambientais nos modelos.

Um dos métodos para predição utilizando a inteligência computacional é o método de aprendizado de máquina (*Machine learning*), que permite que algoritmos façam o processamento de dados e imitem a forma como nós humanos aprendemos, em constante evolução, identificando tendências e emitindo respostas dessas variações com maior acurácia (GÉRON, 2019).

O *Machine learning* é muito utilizado para prever variações financeiras e realizar predições de clima, mas recentemente tem sido aplicado no melhoramento genético de plantas, auxiliando na predição de produtividade, índices germinativos, análises de preços e imagens (DE JABOTICABAL; DE AMARAL, 2021; DA SILVA, 2021; NOGUEIRA, 2021; SANTOS; SPANCERSKI, 2021).

Conceição et al. (2021), utilizou inteligência computacional, redes neurais artificiais, e para estimar produtividade de mamão papaia, ao utilizar caracteres reprodutivos, obtendo alta eficiência.

Silva (2021) analisando sementes de soja com o uso de aprendizado de máquinas profundas, utilizou imagens para prever a qualidade de sementes, obteve acurácia dos modelos propostos, acima de 87% de precisão.

Para avaliar a previsão de produtividade de soja, Santos (2020), utilizou redes neurais artificiais, baseado em informações climatológicas mensais, para diversos municípios da região do MATOPIBA, demonstrou que os modelos apresentam erros de até 100kg na maioria dos locais avaliados.

Pensando nisso, o objetivo deste trabalho foi avaliar o uso de métodos de inteligência computacional para previsão de produtividade de algodoeiro em fibra utilizando variáveis temporais no estado de Minas Gerais.

2*Levantamento bibliográfico*

REVISÃO BIBLIOGRÁFICA: CULTURA E
MELHORAMENTO DO ALGODOEIRO

2. A cultura e o melhoramento do algodoeiro

2.1. Importância histórica e econômica

A domesticação do algodoeiro se deu na Arábia há mais de 4 mil anos. Há oito séculos a.C., os egípcios conheciam e cultivavam o algodão, além dos Incas e outras civilizações antigas, que utilizavam o algodão por volta de 4.500 a.C. No Brasil, entre os séculos XIX e XX, o algodão era uma importante fonte de renda, principalmente no Nordeste (AMAPA, 2022).

No mundo, a produção para a safra 2021/2022 é em torno de 26 milhões de toneladas de algodão. Isso representa um aumento de produção de 5% em relação à safra anterior, muito prejudicada pela pandemia de Covid-19, que afetou negativamente o consumo mundial (ICAC, 2022). Essa produção gerará cifras de US\$ 12 bilhões em movimentações financeiras, envolvendo mais de 350 milhões de pessoas, desde as fazendas, logística, descaroçamento, processamento, indústria a embalagem.

Os maiores produtores de algodão no mundo são a China, Índia, Estados Unidos e o Brasil, que é o maior produtor de algodão em sequeiro do mundo, com 2,7 milhões de toneladas de pluma, um montante comercializado de 1.130,00 bilhões de dólares no ano. Os maiores consumidores mundiais são China, Índia, Paquistão e Turquia (CONAB, 2022).

O algodoeiro adaptou-se às condições climáticas do Brasil, principalmente no bioma Cerrado, que propiciou condições edafoclimáticas favoráveis ao seu cultivo, aliado a incentivos fiscais, alta tecnificação e melhoramento genético (BELTRÃO; AZEVEDO, 2008).

No Brasil a estimativa de produção algodão de pluma em 2021/2022, é de 2,7 mil toneladas, com demanda do mercado interno de 720 mil toneladas, sendo seu excedente exportando principalmente para a China, Vietnã, Paquistão e Turquia, gerando cifras acima de três bilhões de dólares em exportação (CONAB, 2022).

Os estados que mais cultivam são o Mato Grosso com 1140 mil ha cultivados e produção de pluma de 1617 mil toneladas, seguido por Bahia com 307 mil ha e produtividade de pluma de 506 mil toneladas de pluma. Minas Gerais situa-se em terceiro lugar com uma área de 25 mil ha e produção de 118,5 mil toneladas de algodão em caroço. Esses dados que confirmam uma alta participação no cultivo de algodão no país e no

estado mineiro, com faturamento previsto de aproximadamente 8 milhões de dólares (CONAB, 2022).

Um dos fatores responsáveis para o aumento da produção no estado mineiro, além das condições de mercado e ambientais favoráveis é a desoneração fiscal junto à Secretaria de Estado da Fazenda (SEF), com isenção de 41,66% de ICMS para a indústria têxtil, quando esta adquire algodão certificado dos produtores mineiros (AGENCIA MINAS, 2019).

O Noroeste de Minas representa 67,9% de participação na cotonicultura do estado, seguidos pelo Alto Paranaíba, Norte de Minas e Triângulo Mineiro. Esse último a produção é exportada para 34 países como o Vietnã, China, Bangladesh, Cingapura e Argentina (CONAB, 2022).

Os municípios que mais produzem no estado são: Unai, Coromandel, Presidente Olegário e Buritis e São Gonçalo do Abaeté, concentrados nas regiões Noroeste, Triângulo Mineiro (CONAB, 2022).

2.2. Algodoeiro: Botânica e morfologia

O algodoeiro é uma angiosperma da classe das dicotiledôneas, pertencente à ordem Malvales, família das Malvaceae, gênero *Gossypium*. Existem no mundo 52 espécies registradas, contudo, apenas algumas possuem interesse econômico (BORÉM; FREIRE, 2014).

Por essa grande diversidade de espécies, essas foram classificadas segundo seu centro de origem, por meio de estudos citogenéticos, foi possível determinar grandes grupos genômicos, que foram classificados por letras de A a G. Os principais grupos o C, com 11 espécies australianas, o grupo D com 12 espécies americanas e o grupo A com espécies africanas (BELTRÃO; AZEVEDO, 2008).

Mesmo com uma ampla variedade de espécies apenas quatro são exploradas comercialmente, que são: *Gossypium hirsutum* e *Gossypium barbadense*, *Gossypium herbaceum* e *Gossypium arboreum*, sendo a primeira responsável por 90% da produção mundial (BORÉM; FREIRE, 2014).

Gossypium hirsutum e *Gossypium barbadense* originaram há milhares de anos, no período cretáceo, através do cruzamento de duas espécies diploides de origem genômica AD (*Gossypium raimondii* (D) x *Gossypium herbaceum* (A)). A hipótese sugere que na hibridação entre essas espécies ocasionou a duplicação do número de cromossomos, que

produziu um alotetraploide ($DD \times AA = AD = AADD$), ou seja, espécies alotetraploides $2n=4x=52$, como centro de origem a América central (*G. hirsutum*) e a América do Sul (*G. barbadense*), respectivamente (HUANG et al., 2020).

O algodoeiro é considerado uma cultura trina, pois fornece fibras, óleo e energia. Suas fibras são a principal matéria prima da indústria têxtil. Do caroço é extraído o óleo, fonte para alimentação humana e de animais ruminantes (PENNA, 2005).

O caroço de algodão é uma importante fonte proteica para animais ruminantes, com valores de proteínas entre 22 a 25% e também fornece lipídeos entre 16 a 26%, que a torna interessante para produção de óleo para alimentação humana, e para produção de biodiesel (BELTRÃO; AZEVEDO, 2008).

Suas plumas são utilizadas pelos homens para confecções de fios para produção de vestimentas há pelo menos quatro mil anos na Índia e também evidências de seu uso por nativos nas américas. É a principal fibra natural utilizada no mundo (AMAPA, 2022).

O *G. hirsutum* se destaca por possuir boa qualidade de fibra e características morfológicas favoráveis ao cultivo em larga escala. Possuir altura entre 0,6 m a 1,0 m, com ramificações curtas, folhas largas tri ou pentalobadas. Possuem flores de coloração amarelo pálido, com média de 11 sementes por lóculo, de onde se originam fibras de comprimento longo através da epiderme, sendo responsável por 90% da cotonicultura mundial (BORÉM; FREIRE, 2014).



Figura 1. Detalhe da coloração da flor de *G. hirsutum*. Fonte: Promalg,2020.

A segunda espécie em importância é o *G. barbadense* (5% da produção mundial), se caracterizam por plantas de até 2,70 m de altura e ramos ascendentes. Possuem folhas espessas tri ou pentálobadas com suas flores amareladas envoltas por brácteas largas. Suas fibras são longas e brilhantes com a presença de línter verde ou marrom (BORÉM; FREIRE, 2014).



Figura 2. Detalhe da coloração da flor de *G. barbadense*, Fonte: Promalg, 2019.

2.3. O algodoeiro herbáceo (*Gossypium hirsutum* L. var. *latifolium* Hutch.)

O ciclo do algodoeiro oscila de acordo com as condições ambientais, entre 160 a 180 dias, dependendo principalmente da temperatura, graus-dia, que tem como valores ótimos temperaturas entre 20 a 30°C. Temperaturas mais elevadas, até os 30°C são favoráveis para a precocidade do ciclo (IMAMT, 2022).

$$\text{Graus-dia} = \left(\frac{\text{Temperatura Máxima} + \text{Temperatura Mínima}}{2} \right) - 15$$

A germinação das sementes é do tipo epigea, com os cotilédones expostos acima do nível do solo. Sua germinação ocorre de três a 12 dias após a sementeira, a depender principalmente da temperatura do solo e da umidade.

O algodoeiro apresenta glândulas de gossipol por toda a planta. Estas glândulas secretam o gossipol que é um composto polifenólico tóxicas que protege a planta de

herbivoria, contudo, este composto também é tóxico para animais e causa esterilidade em ruminantes (BORÉM; FREIRE, 2014).

Seu sistema radicular é do tipo pivotante alcançando profundidades de até 2,5m com raízes laterais nos primeiros 30cm de solo e tem seu crescimento cessado com o surgimento dos primeiros frutos. É sensível a falta de oxigênio no solo e a baixas temperaturas. Possuem alta capacidade de regulação osmótica, podendo ser adaptável a estresses hídricos (BORÉM; FREIRE, 2014; IMAMT, 2022).

As espécies possuem hábito de crescimento indeterminado e porte subarborescente, no entanto, as espécies comerciais são conduzidas como culturas anuais, por meio do manejo, possuindo caule ascendente. Possuem ramos que se desenvolvem em forma espiralada, o que evita a sobreposição das folhas do baixeiro (IMAMT, 2022).

Há dois tipos de ramos, os reprodutivos e os vegetativos. Os vegetativos são os primeiros ramos do caule e seu meristema apical forma folhas, enquanto os ramos reprodutivos os meristemas apicais formam uma folha e uma flor (BORÉM; FREIRE, 2014).

O algodoeiro possui folhas verdadeiras, simples, incompletas e tipo heliotrópicas. Tem como principal função a realização da fotossíntese e é muito importante no resfriamento da folha, usando 95% da água absorvida para tal. As folhas têm longevidade de até 70 dias, atingindo seu pico fotossintético entre 25 a 30 dias. São do tipo glabras com estômatos nas duas faces e glândulas de gossipol em toda sua superfície (BELTRÃO et al., 2008).

As folhas podem ser de dois tipos. As reprodutivas que originam do lado oposto de cada botão floral e possuem menor área foliar, com filotaxia 2/5, ou seja, em cada 2 voltas no eixo principal tem-se 5 folhas. O outro tipo de folhas são as vegetativas que formam a partir do caule e possuem o dobro da área foliar das folhas reprodutivas e têm filotaxia 3/8 do algodoeiro, responsáveis por 70% do enchimento dos dois primeiros frutos do ramo (BELTRÃO; AZEVEDO, 2008; BORÉM; FREIRE, 2014).

Possuem flores incompletas e hermafroditas, com ovário súpero, com três a cinco carpelos e três a cinco lóculos com óvulos de placentação marginal-central, apresentando pétalas cremes de diversas tonalidades. Seu sistema reprodutivo é do tipo indeterminado, pois na ausência de polinizadores realiza autofecundação, contudo, havendo insetos polinizadores na área, a polinização cruzada pode atingir altos valores, acima de 50%. O pico de floração por volta dos 70 dias após a emergência (BORÉM; FREIRE, 2014).

Seu fruto é denominado maçã, possuindo de três a cinco lóculos, com 8 a 12 sementes por lóculo. Após a fecundação o fruto se desenvolver por aproximadamente 40 dias até sua abertura que expõe as fibras do algodão e o fruto passa a ser denominado de capulho. Nesta fase há uma competição por fotoassimilados pelo alto dreno dos frutos, cessando o crescimento vegetativo (*Cut-out*) (BORÉM; FREIRE, 2014).

As sementes do algodoeiro são piriformes e tem coloração que varia de marrom a preta. Sua epiderme possui células esclerificadas, que são modificadas e originam as fibras, que podem ser curtas, denominadas línter ou fibras longas. Outra importante característica das sementes do algodoeiro é sua composição físico-química, rica em lipídios (25%) e proteínas (28%) (OLIVEIRA, 2020).

A fibra é não clorofilada, sendo uma célula viva até sua exposição. Possui uma membrana plasmática com duas paredes, uma externa ou primária coberta por uma cutícula e outra interna ou secundária que possui três camadas, sendo a camada média composta por celulose (BELTRÃO; AZEVEDO, 2008).

A fibra é formada antes da antese e após cinco dias desta, tem até 10 mil fibras que crescem por cerca de 20 dias e após este período há a deposição de camadas de celulose que constitui de 88 a 96% de cada fibra. Cada fibra é proveniente de uma única célula, que se desenvolvem por aproximadamente 40 dias, oriunda da epiderme e tem comprimento que pode chegar a 33mm (OGTR, 2016).

O conjunto de fibras é denominado de pluma e são a principal matéria prima da indústria têxtil, podendo ser de coloração branca, bege, esverdeada, creme e vermelha, cores oriundas de flavonoides. As características tecnológicas das fibras são condicionadas por fatores genéticos e sofrem grande influência de fatores ambientais como pragas, solo, precipitações, incidência de raios solares, dentre outros. Sua qualidade é essencial para sua comercialização e sua análise da qualidade é fundamental para estipular seu valor comercial. (BORÉM; FREIRE, 2014).

O desenvolvimento da cultura pode ser dividida em quadro estádios fenológicos (MARUR; RUANO, 2001): Fase vegetativa (V), de formação de botões (B), abertura de flores (F) e abertura de capulhos (C).

A fase vegetativa se dá da emergência da plântula (V_0) e a cada folha verdadeira com comprimento acima de 2,5 cm esta muda de estádio ($V_1, V_2... V_n$). No momento que aparecer o primeiro botão floral o estádio muda para B e a cada botão formada mudará para $B_1, B_2... B_n$. Ao surgimento da primeira flor passará para o estádio F e no primeiro capulho estádio C.

2.4. Qualidade da fibra

A qualidade da fibra se refere à aplicação de procedimentos padronizados desenvolvidos pelo Departamento de Agricultura dos Estados Unidos da América do Norte – USDA, para avaliar as qualidades físicas da pluma levando em consideração o tipo, a cor e o grau de folha por parâmetros físicos universais (EMBRAPA, 2006).

Os parâmetros avaliados são divididos em características intrínsecas e extrínsecas. Características intrínsecas envolvem o manejo no campo e da genética do cultivar. Já a característica extrínseca depende da colheita, armazenamento e descaroçamento. Ambas classifica a pluma segundo parâmetros do mercado, lei nº 9.972/2000 (EMBRAPA, 2006).

Atualmente a classificação das características intrínsecas da fibra são determinadas pelo sistema HVI (*High Volume Instruments*), teste exigido como padrão para que a pluma seja comercializada no exterior (AMPA, 2018).

O HVI analisa as seguintes características: comprimento da fibra (UHML), índice de consistência a fiação (SCI), uniformidade da fibra (UI), índice de micronaire (MIC), resistência (STR), alongamento (ELG), índice de fibras curtas (SFI), maturidade da fibra (MAT), grau de amarelo (GA) e grau de reflectância (RE) (EMBRAPA, 2006), e serão descritas abaixo:

2.4.1. Índice de Consistência de fiação (SCI)

Característica que indica resistência dos fios em especial de fios a rotor. É a propriedade que a fibra tem de se transformar em fio, determinada por uma equação de regressão múltipla correlacionando com as características físicas estimadas pelo *HVI*, como a resistência, micronaire, comprimento de fibra, uniformidade de comprimento, reflectância e grau de amarelecimento, sendo ideal os maiores valores.

2.4.2. Comprimento de Fibra (mm) (UHML)

É levado em consideração o comprimento médio de 50% das fibras mais longas. É um parâmetro utilizado para estipular o preço de comercialização.

2.4.3. Uniformidade do Comprimento (UI)

Relação entre o comprimento médio de todas as fibras com o comprimento médio da metade mais longa do feixe de fibras.

2.4.4. Alongamento (ELG)

Máximo de comprimento longitudinal obtido por uma amostra de fibra durante uma carga de esforço até seu rompimento. É importante para o preço e qual a destinação da fibra.

2.4.5. Resistência (STR)

Capacidade que a fibra tem de suportar uma carga até se romper. A resistência à ruptura é expressa em g tex^{-1} (universal) e gf tex^{-1} (Brasil), sendo que este parâmetro de qualidade representa a força máxima necessária para romper um feixe de fibras. É importante para o preço e qual a destinação da fibra.

2.4.6. Maturidade (MAT)

Grau de desenvolvimento da parede da fibra ou da camada de celulose das paredes da fibra. Para duas fibras de mesmo diâmetro, a mais madura será aquela que tiver parede mais espessa na sua seção transversal. É importante sua mensuração para determinar o tipo de corante a ser utilizado e sua fixação.

2.4.7. Micronaire (MIC)

É a razão entre a finura da fibra e sua maturação. É indicador da resistência de uma determinada massa de fibras a um fluxo de ar, à pressão constante, em câmara de volume definido. Este índice, é intimamente influenciado pelo conteúdo de celulose presente na parede secundária da fibra e permite estimar a quantidade de fibras que irão compor a seção transversal do fio e sua resistência e regularidade em função de comprimento.

2.4.8. Índice de Fibra Curta (%)

Porcentagem de fibras menores que 12,7 mm. É obtido através do HVI, pela proporção em porcentagem de fibras curtas em uma amostra com comprimento inferior a 12,7 mm. Altos valores de fibras curtas aumenta a pilosidade do fio assim como este fica mais suscetível a ruptura.

2.4.9. Reflectância

A reflectância (Rd %) representa uma escala que varia do branco ao cinza. Quanto maior a reflectância da fibra, menor será o seu acinzentamento e, portanto, maior o interesse da indústria têxtil.

2.4.10. Grau de Amarelecimento

Valor correspondente ao amarelecimento das fibras com a ajuda de um filtro amarelo.

Os valores são classificados e comparados a índices pré-estabelecidos pelo mercado e são enumerados na tabela 1 (EMBRAPA, 2006).

Tabela 1. Valores referência para as características intrínsecas da fibra. (Continua)

UHML(mm)		UI (%)		ELG (%)		STR (gf tex ⁻¹)	
Curta 23,5 - 25,15	Muito Irregular	< 77	Muito Baixo	< 5,0	Baixa	21,0-23,0	
	Irregular	77-79	Baixo	5,0-5,9	Média	24,0-27,0	
Média	25,16 - 27,94	Média	80-82	Médio	5,9-6,7	Elevada	27,0-29,0
Longa 27,94 - 32,00	Uniforme	83-85	Alto	6,8-7,6	Muito Forte	> 30,0	
	Muito Uniforme	> 85	Muito Alto	> 7,6			

UHML=Comprimento de fibra; UI= Uniformidade de comprimento; ELG= Elongamento; STR= Resistência.

Tabela 2. Valores referência para as características intrínsecas da fibra. (Conclusão)

MAT		MIC		SFI (%)	
Inadequado	< 0,70	Muito fina	< 3,0	Muito Baixa	< 6,0

Imaturo	0,70-0,80	Fina	3,0-3,9	Baixa	6,0-9,0
Inferior ao médio	0,80-0,85	Regular	4,0-4,9	Média	10,0-13,0
Maduros	0,85-0,95	Grossa	5,0-5,9	Alta	14,0-17,0
Superior ao médio	0,95-1	Muito Grossa	> 6,0	Muito Alta	> 17,0

MAT=Maturação; MIC= Micronaire; SFI= Índice de Fibras Curtas

2.5. Fatores abióticos no desenvolvimento do algodoeiro

O algodoeiro é uma cultura que possui ampla disseminação no mundo, podendo ser cultivada a 30° norte à 45° sul de latitude, conferindo alta plasticidade, ou seja, tem a capacidade de se adaptar em diferentes condições de meio (BELTRÃO; AZEVEDO, 2008).

São plantas que possuem mecanismo fotossintético do tipo C3, com elevadas taxas de fotorrespiração, acima de 40%, a depender das condições do meio. Isso significa que sob condições adversas de temperatura e luminosidade a planta fotorrespira gastando energia e carbono provenientes da fotossíntese (IMAMT, 2022).

Temperaturas ótimas de desenvolvimento da cultura várias entre 20 a 30°C. Temperaturas acima de 35°C ocasiona aumento da fotorrespiração, tendo eficiência 50% inferior à da fotossíntese na produção de energia (IMAMT, 2022).

A temperatura do solo exerce forte influência na germinação, pois mesmo com umidade ideal, baixa temperatura pode impedir o início do processo germinativo. Sob altas temperaturas, acima de 37 °C, a semente absorve 60% de umidade em aproximadamente 8 horas, enquanto a 15,5 °C a mesma umidade só seria atingida em aproximadamente 28 horas (IMAMT, 2022).

É uma planta que depende diretamente da temperatura. Para completar seu ciclo é necessário um acúmulo de unidades de calor que variam em cada estágio, com média de 1450 graus-dias em Patos de Minas- MG (IMAMT, 2022).

A luminosidade também é relevante ao seu desenvolvimento, pois afeta diretamente a fotossíntese. A maior influência da incidência de luz ocorre nos estádios reprodutivos, acarretando na diminuição da produtividade, sendo de extrema importância o manejo adequado afim de evitar o autossombreamento (IMAMT, 2022).

O estresse hídrico ocasiona o fechamento dos estômatos, o que irá prejudicar consideravelmente o resfriamento das folhas, sem contar o fato de diminuir a fotossíntese. Contudo, a falta de água pode ser benéfica, principalmente nos estádios iniciais (IMAMT, 2022).

Escassez no período vegetativo estimula o crescimento radicular, em contrapartida falta de água, no período reprodutivo até o *cut-out*, diminui consideravelmente a produtividade. No final do ciclo quando os capulhos estiverem no campo, chuvas causam depreciação da qualidade da fibra (BORÉM; FREIRE, 2014). O excesso de água também é prejudicial a cultura, uma vez que reduz a disponibilidade de oxigênio para o sistema radicular, podendo reduzir em até 40% a produtividade (IMAMT, 2022).

O tipo de solo é determinante para o desenvolvimento da cultura. Solos precisam ser bem arejados e com bons níveis de drenagem, sem compactação, alto teor de matéria orgânica, sem impedimentos físicos ou químicos, com possíveis deficiências nutricionais em solos arenosos. Deficiências nutricionais de elementos essenciais prejudicam o desenvolvimento fisiológico das plantas (BORÉM; FREIRE, 2014).

2.6. Melhoramento do algodoeiro no Brasil

Os programas de melhoramento genético convencional de algodoeiro no Brasil começaram em 1921. Neste ano a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) iniciou projetos de pesquisa voltados para a cultura, visando obter cultivares adaptadas para as regiões Norte, Nordeste e Centro-Oeste (PENNA, 2005).

O programa de melhoramento genético em algodoeiro da Universidade Federal de Uberlândia começou no ano de 1995, idealizado pelo professor Dr. Júlio César Viglioni Penna, com o intuito de desenvolver genótipos de algodoeiro de fibra colorida visando suprir a demanda de trabalhos sociais da região voltados a tecelagem. A princípio realizaram-se cruzamentos e retrocruzamento entre *Gossypium barbadense* - uma variedade de fibra escura avermelhada com porte elevado, desenvolvimento tardio, com baixa produtividade - e *G. hirsutum* comerciais, com objetivo de melhorar o porte da planta, qualidade de fibra e produtividade.

Hoje o programa é coordenado pela Professora Dr. Larissa Barbosa de Sousa e visa aprimorar as tecnologias de produção do algodoeiro na região de Uberlândia, almejando o desenvolvimento de novas cultivares brancas e coloridas, com alta produtividade, resistentes aos estresses bióticos e abióticos. Para tanto, utilizam-se métodos de melhoramento clássico e molecular.

De modo geral, nos programas de melhoramento de algodoeiro, utiliza-se o método bulk, genealógico ou retrocruzamento. O primeiro método de seleção é utilizado

para melhoramento de grandes populações visando à seleção natural, o segundo para controle parental e o terceiro para incorporação de poucos genes específicos. Seleção massal, seleção genealógica, seleção pedigree-massal, seleção recorrente, hibridação, retrocruzamento e uso do vigor híbrido, também são bastante utilizados (BOREM; MIRANDA; FRITSCHÉ-NETO, 2021).

O algodoeiro é uma planta intermediária, ou seja, realiza autofecundação, na ausência de polinizadores. A polinização cruzada pode ultrapassar 80%. Este fato se deve a polinizações por abelhas *Aphis mellifera* L. No programa de melhoramento de algodoeiro é de extrema importância tomar o cuidado de proteger as flores para evitar fecundação cruzada em genótipos que são de interesse (NETO; FREIRE, 2013).

Nesse sentido, o melhoramento genético do algodoeiro tem como objetivo atender a demanda de maior produtividade, porte, maturação uniformes dos capulhos, resistência às principais pragas e doenças, além de plumas que atendam às exigências da indústria têxtil. As características mais visadas para as fibras, segundo Neto (2013), são: comprimento da fibra (UHML), resistência (STR), maturidade (MAT) e índice de micronaire (MIC).

O melhoramento de fibras coloridas é pouco explorado pelo fato de possuírem qualidades de fibras inferiores quando comparadas ao algodão de fibra branca, além de menores produtividades (CARDOSO et al., 2021).

2.7. Inteligência computacional

A Inteligência Computacional (IC) é um conjunto de métodos capazes de mimetizar o raciocínio humano, que muitas vezes baseiam em pilares como o aprendizado, tomada de decisão e otimização. Essas etapas são racionalizadas e introduzidas em algoritmos capazes de extrair informações de conjunto de dados (CRUZ; NASCIMENTO, 2018).

Na IC existem vários ramos de pesquisa, segmentados em métodos com características diversas, como mimetizar o funcionamento biológico dos neurônios para tomada de decisão e métodos que aprendem com os dados (CRUZ; NASCIMENTO, 2018; GÉRON, 2019).

Uma vantagem do uso da IC é que são tolerantes a conhecimento incompleto, impreciso, incerto, não necessita de informações a priori dos dados, e sendo assim facilita

o encontro de soluções que são aproximações, viáveis e robustas ao mesmo tempo (CRUZ; NASCIMENTO, 2018).

Dentre os métodos mais utilizados no mundo estão a aprendizagem de máquinas (*machine learning*) as Redes Neurais Artificiais, Lógica Fuzzy, e aprendizagem profunda (*Deep Learning*).

O aprendizado de máquina (*Machine learning*) permite que algoritmos façam o processamento de dados de maneira análoga ao aprendizado biológico, com relevância para o aprendizado baseado na experiência, identificando comportamentos e capturando nuances das respostas com maior acurácia (GÉRON, 2019).

O *Machine learning* é muito utilizado para prever variações financeiras, realizar previsões de clima e mais recentemente tem sido aplicado no melhoramento genético de plantas, auxiliando na previsão de produtividade, índices germinativos, análises de preços e de imagens (DE JABOTICABAL; DE AMARAL, 2021; DA SILVA, 2021; NOGUEIRA, 2021; SANTOS; SPANCERSKI, 2021)

Um segmento dos *Machine learning* são as redes neurais artificiais (RNA's) que simula os neurônios biológicos e sua forma de pensar, adquirindo conhecimento através da experiência, prevendo, reconhecendo padrões ou estabelecendo agrupamentos (CRUZ; NASCIMENTO, 2018; BARROSO et al., 2013). As camadas e os neurônios desse método pode caracteriza-la como *Deep Learning*.

Outro segmento da IC é a lógica fuzzy, uma modelagem matemática que simula aproximações e incertezas da lógica humana e atribuir graus de pertinência aos elementos. A lógica fuzzy tem sido usada para selecionar cultivares de feijão e algodoeiro quanto a classificações de dissimilaridade e agrupamentos (CARDOSO et al., 2021; CARNEIRO et al., 2018a, 2018b).

2.8 Predição de produtividade

As técnicas de ML utilizados foram as redes neurais *Multilayer Perceptron*, *Random Forest*, *Decision Tree* e regressão linear.

2.8.1 Aplicação de Redes Neurais artificiais

Os primeiros estudos realizados com inteligência computacional foram realizados por McCulloch e Pitts (1943), Hebb (1949), e Rosenblatt (1958), teorizando o conceito de simular o pensamento humano em equações matemáticas (CRUZ; NASCIMENTO, 2018).

As principais características desse método é que possui unidades de processamento (“neurônios”), que estão conectados e determinam peso para as variáveis de entrada e a depender do método, ainda serem subdivida em camadas que podem conter número variado de neurônios (Figura 3).

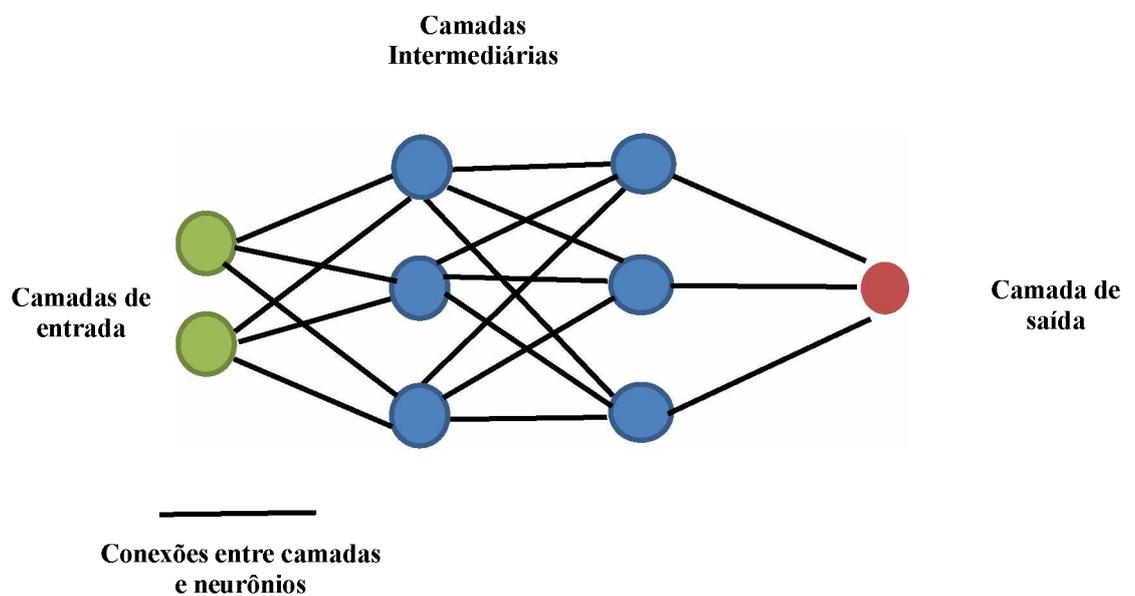


Figura 3. Organização da rede neurais de camadas. **Camada de Entrada:** variáveis de análise. **Camadas Intermediárias:** onde há o processamento, determinação de pesos sinápticos. **Camada de Saída:** Resultado apresentado pela rede. Adaptado de Cardoso (2018).

Os neurônios se conectam para determinar os pesos. Cada entrada é inserida na rede que multiplica por um peso, que indica a sua influência na saída do neurônio, e a partir daí são ajustados aos padrões, por uma regra de treinamento, portanto, aprendem com os exemplos (CARDOSO et al., 2018; CEMEAI, 2022). As redes Multilayer Perceptron são preditivos da estrutura variáveis de entrada, camadas e saída predizendo uma ou mais variáveis.

Para entrada X_1, X_2, \dots, X_p e pesos w_1, w_2, \dots, w_p e limitador t ; com sinais assumindo valores booleanos (0 ou 1) e pesos valores reais (CEMEAI, 2022; CRUZ; NASCIMENTO, 2018).

$$a = w_1X_1 + w_2X_2 + \dots + w_pX_p$$

A saída y é dada por

$$y = 1, \text{ se } a \geq t$$

ou

$$y = 0, \text{ se } a < t.$$

Existem diversas topologias de uma rede neural, e são baseadas em processos de aprendizado, que ajustam os pesos das entradas para o treinamento da rede. O treinamento é finalizando quando encontra uma solução para os problemas, pois se informa à rede a resposta desejada baseado nas variáveis de entrada. Caso não seja apropriado as respostas são feitos novos ajustes para reduzir a distância entre o desejado e a saída, e essa fase é denominada de Regra Delta (CEMEAI, 2022; CRUZ; NASCIMENTO, 2018).

$$\text{Atualizar pesos: } W_{\text{novo}} := W_{\text{anterior}} + E X$$

2.8.2 *Random Forest e Decision Tree*

O *Random Forest* ou floresta aleatória as análises são estruturadas “árvore”. Cada segmento da estrutura decide o resultado final. *Decision Trees* ou Árvores de Decisão, utiliza regras em “arvore”, que possui uma ramificação que verifica a condição, e isto determinará o fluxo dos ramos (Figura 4).

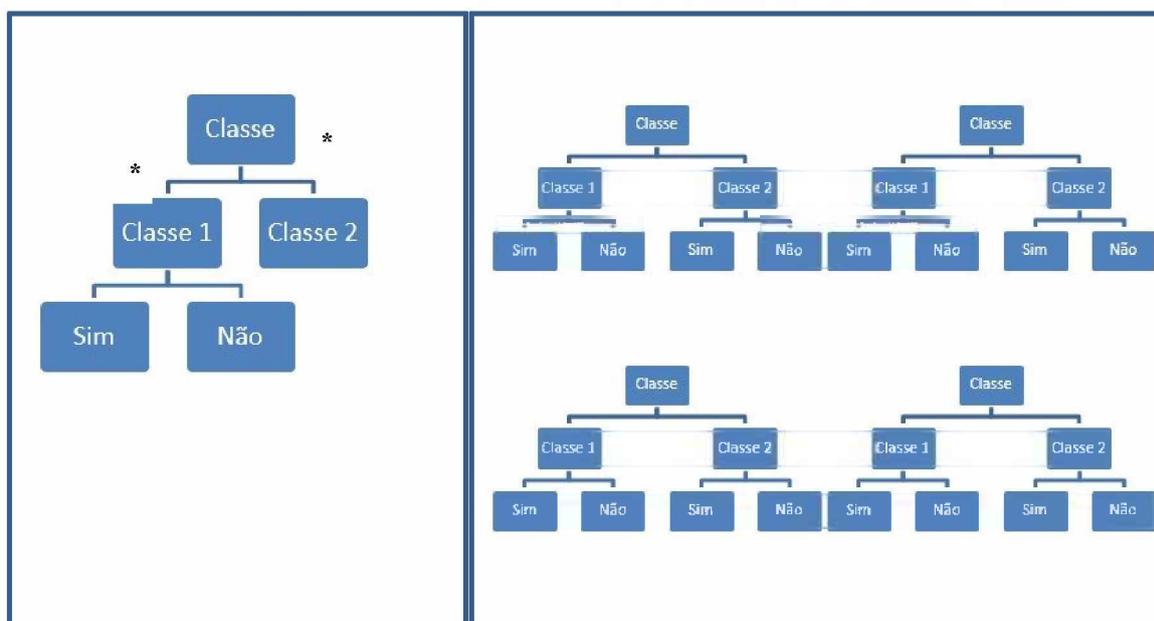


Figura 4. Topologia das árvores de decisão. A esquerda a topologia de *Decision Tree* e à direita a topologia de *Random Forest*. *= nós

Árvores são formadas por nós, que armazenam informação/perguntas. O nó raiz é o nó que possui maior nível hierárquico e, a partir dele, ramificam-se os nós filhos. O nó que não possui filhos é conhecido como nó terminal (GÉRON, 2019).

2.8.3 Fuzzy

No método utilizando o controlador Fuzzy – Eberhart e Russell (1966) baseado no sistema de inferência fuzzy proposto por Sugeno (1988) utiliza os parâmetros da média geral (β_0), coeficiente de regressão (β_1) e coeficiente de determinação (R^2) e p processo de fuzzificação classifica cada genótipo quanto a variável de entrada.

A média geral (β_0) pode ser classificada como "Baixa" ou "Alta", em função das distribuições normais das entradas, no valor da média geral (μ) e do desvio padrão (σ). (CARNEIRO, 2015).

3***MATERIAL E MÉTODOS***

3. Material e métodos

3.1 Predição de produtividade nas regiões produtoras de Minas Gerais

Os dados de produtividade de fibra são provenientes das cidades mineiras com registro de produção contínua de algodão nos últimos dez anos. Foram coletados dados de produtividade (kg ha^{-1}) de Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete e Unaí, baseados nas médias de cada local (IBGE, 2022).

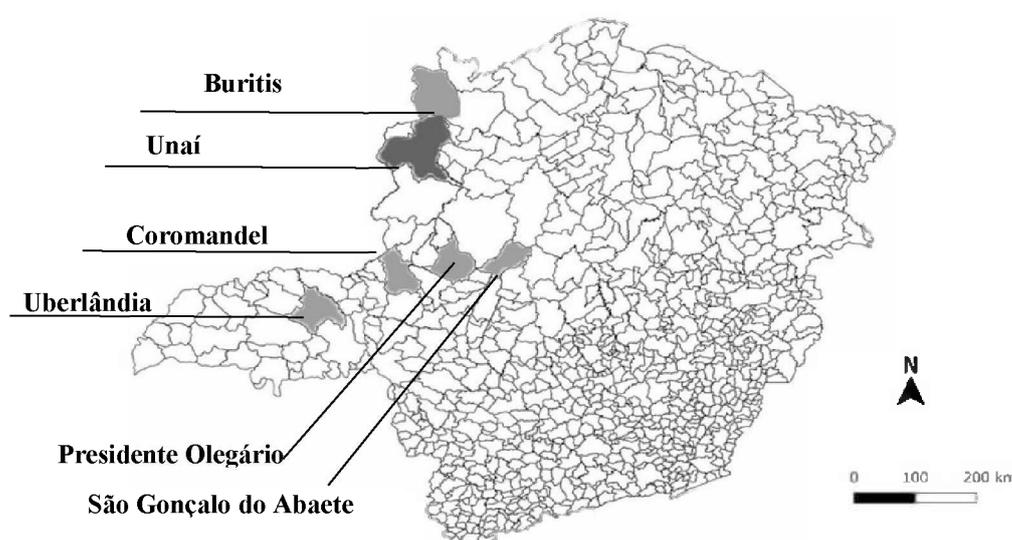


Figura 5. Mapa dos municípios de Minas Gerais. Fonte: IBGE 2020.

Os dados climatológicos foram obtidos mês a mês, sendo dezembro, janeiro, fevereiro, março, abril, maio e junho, em cada ano/safra entre 2010 à 2021 (NASA/POWER, 2022) sendo estes: temperatura máxima ($^{\circ}\text{C}$), temperatura mínima ($^{\circ}\text{C}$), umidade relativa (%), umidade do solo, umidade na zona de raiz (%), precipitação acumulada (mm) e média da precipitação (mm) totalizando 58 variáveis avaliadas.

Os dados são estimados baseados em satélites e modelos de alta precisão. Os parâmetros meteorológicos são apamparados em modelo de assimilação MERRA-2, estimando a incerteza associado a parâmetros solares e meteorológicos (NASA/POWER, 2022).

Após a coleta dos dados, realizou-se o pré-processamento dos mesmos, estatística descritiva, correlação de Pearson, importância dos caracteres, validação e teste dos modelos de previsão e estimativa dos erros.

Correlação de Pearson (r):

$$r = \frac{1}{n-1} \sum \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right)$$

N=amostras; \bar{x} =média; s=valor-média, x=valor a; y=valor b.

Importância dos caracteres:

$$(D)it^2 = \sum_{j=1}^n \sum_{j=1}^n w_{jj} d_j d_j'$$

w_{jj} = elemento da j-ésima coluna da inversa da matriz de variância e covariâncias residuais.

Foram separados 80% dos dados de entrada para teste do modelo e 20% para testes de treinamento do modelo, utilizando os metodos *Random Forest* (RF), *Regression Trees* (RT) e Regressão Linear (RL) em sua configurações padrões. Também foi calculado o SHAP (*Shapley Additive exPlanations*) para explicar as decisões dos modelos de *machine learning* avaliando o peso das variáveis no modelo. Todos as avaliações foram rodadas com o auxílio dos softwares Genes e Matlab (CRUZ, 2016), além dos *software* Python (pacote Scikit-learn) (SILVA et al., 2017).

3.2 Funções de Erro do modelo

As função de erro são utilizadas para estimar a distância entre o valor predito e o observado, a fim de comparar modelos distintos pela maior ou menor distância. Foi utilizado o Erro Médio Absoluto, o Desvio Padrão e o Coeficiente de Determinação.

No erro médio absoluto expressa o erro de previsão médio absoluto do modelo. Valores proximos de 0, seriam o ideal, mas não existem valores limites para essa métrica. Essa medida não é capaz de mensurar a qualidade do modelo. Quando se compara dois, o que tiver a menor pontuação será o melhor (HARRISON, 2019).

Erro Médio Absoluto:

$$EMA = \frac{1}{n} \sum_{i=1}^n |e_i|$$

Sendo: $|e_i|=|y_i-x_i|$; y_i o valor predito; x_i = valor real;n=total

Desvio Padrão:

$$DP = \sqrt{\frac{\sum_{i=1}^n (x_i - X)^2}{n}}$$

Somatória de x = número total; X = média dos valores; n = número de observações

4***RESULTADOS E DISCUSSÃO***

4. Resultados e discussão

As cinco cidades são apresentadas com o histórico de produtividade dos últimos dez anos, com suas respectivas médias de produtividade em quilos por hectare (Tabela2).

Tabela 2. Médias de produtividade de algodão em caroço (kg ha^{-1}) nas safras de 2010 a 2020, nas cidades mineiras de Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete e Unai. Fonte: IBGE, 2022.

Cidades	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Buritis	3900	3900	3900	3576	3366	3585	3500	4200	3900	4300	4800
Coromandel	4199	3900	3154	3785	3960	4050	3500	3660	4091	4852	4900
Pr. Olegário	4200	4350	4340	4050	4300	4160	3900	3900	4200	4200	4500
S. G. do Abaeté	4200	4350	4350	3900	4326	3975	4000	4050	4560	4300	4200
Unai	3899	3900	3900	3900	3600	3780	2700	3270	4090	4300	4500
Média Geral	4079	4080	3928	3842	3910	3910	3520	3816	4168	4390	4580
Média Brasil	3555	3609	3596	3621	3751	3880	3477	4141	4310	4236	4329

Pr-Presidente; S.G.= São Gonçalo

As médias de produtividade de algodão em caroço, dos maiores produtores mineiros, oscilaram ao longo dos anos em até 17%. Quando comparados as médias brasileira, demonstra que o estado possui alta competitividade e conhecimento técnico, pois em grande parte, possui médias superiores de produtividade (CONAB, 2022).

O desempenho produtivo é reflexo do manejo tecnificado e de incentivos fiscais cedidos pelo governo de Minas Gerais, que incentivam a produção do algodoeiro no estado, e conseqüentemente proporciona possibilidade de investimentos, tecnificação e conhecimento (AMIPA, 2021).

As oscilações entre os anos safra estão relacionados com variações das cultivares e suas interações com os ambientes, principalmente relacionados a fatores como as temperaturas, umidade relativa e as precipitações (IMAMT, 2022).

Na Tabela 3 é possível identificar o quanto as variações dos fatores abióticos interferiram na produtividade de cada ano, sem levar em consideração a distribuição desses fatores ao longo de cada ano-safra.

Tabela 3. Médias de temperatura (°C), Umidade (%) e precipitação (mm) nos municípios de Buritis, Coromandel, Presidente Olegário, São Gonçalo do Abaete e Unai, no estado de Minas Gerais entre os anos de 2010 a 2020.

Ano/Safra	Produtividade	UR	USolo	TMx	TMm	Uraiz	Mmm	Acumm
2010	4079	66,7	0,58	36,5	8,9	0,61	14,91	1048
2011	4080	72,8	0,67	35,5	9,5	0,68	18,89	1336
2012	3928	68,5	0,62	39,1	9,7	0,64	13,18	917
2013	3842	70,3	0,62	36,2	10,3	0,63	16,62	1183
2014	3910	63,0	0,52	39,6	10,0	0,58	10,70	730
2015	3910	62,6	0,53	39,6	11,3	0,58	10,83	738
2016	3520	62,8	0,53	37,6	10,3	0,59	13,62	949
2017	3816	62,5	0,52	38,3	9,0	0,58	12,28	839
2018	4168	67,0	0,58	37,3	7,9	0,61	16,12	1124
2019	4390	65,0	0,56	38,4	8,9	0,61	12,85	886
2020	4580	69,8	0,61	41,0	8,2	0,63	15,51	1100

UR= Umidade Relativa (%), USolo=Umidade no solo (%), TMx= Temperatura Máxima °C, TMm= Temperatura Mínima °C, Uraiz= Umidade na zona de raiz (%), Mmm= Média de precipitação e Acumm= Acumulo de precipitação (mm). Fonte (NASA, 2022).

Por se tratar de uma característica quantitativa, onde o meio tem atuação determinante para sua expressão, a produtividade demonstra correlação, mesma que baixa, com as características de temperatura, umidade e precipitações. A temperatura mínima apresentou correlação negativa, coerente com a cultura, pois os graus dias são determinantes para completar seu desenvolvimento, e a temperatura interfere diretamente no ciclo e produtividade (Figura 6).

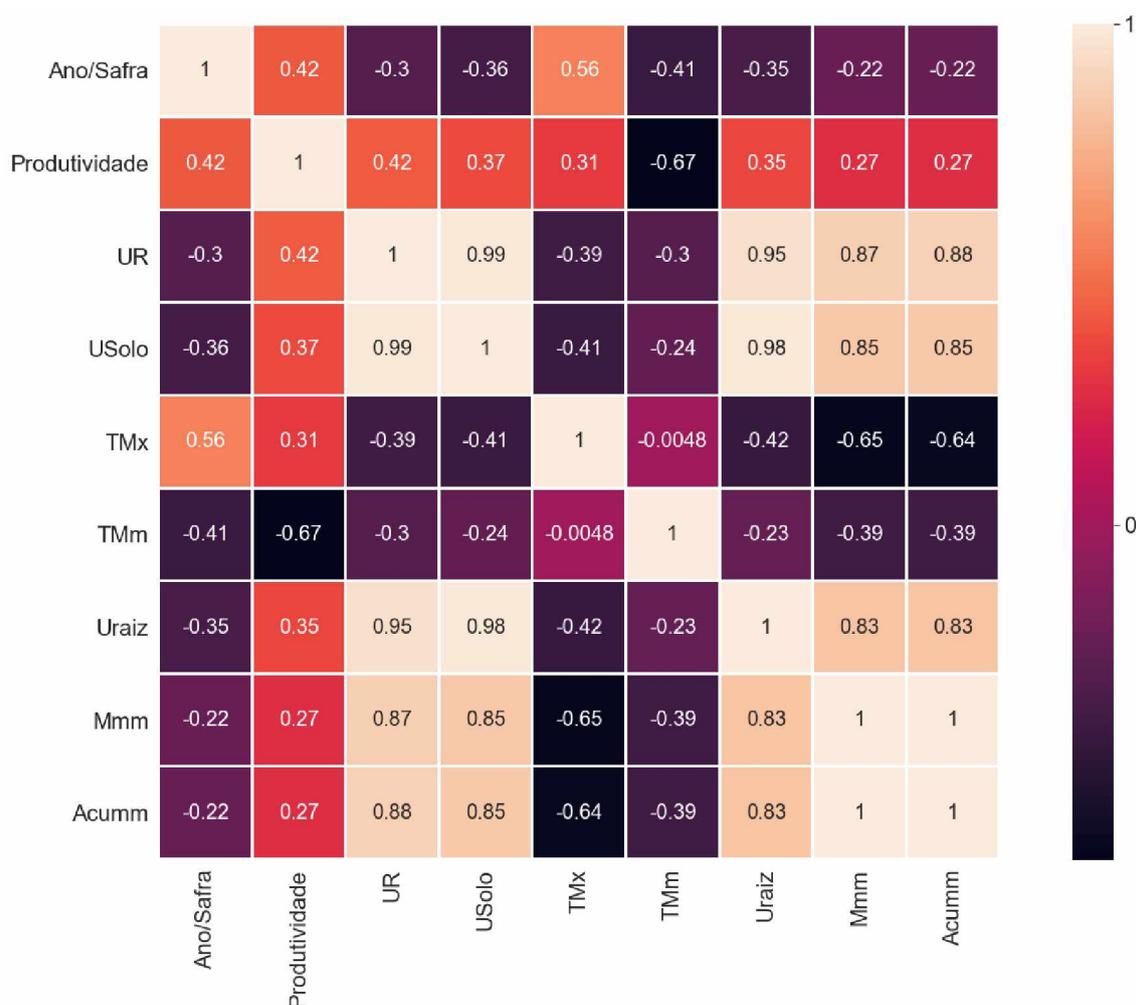


Figura 6. Correlação de Pearson em cores, para características abióticas, anos e produtividade.

UR= Umidade Relativa (%), USolo=Umidade no solo (%), TMx= Temperatura Máxima (°C), TMm= Temperatura Mínima (°C), Uraiz= Umidade na zona de raiz (°C), Mmm= Média de precipitação (mm) e Acumm= Acúmulo de precipitação (mm).

Baixas temperaturas prejudicam o desenvolvimento das maçãs e das fibras, além de prejudicar o ciclo da planta, pela diminuição da soma térmica (graus dias), ocasionando assim, o atraso da colheita (IMAMT, 2022).

Os valores de correlação corroboram com a importância dos caracteres para analisar a produtividade. A temperatura mínima foi a mais importante (36%), seguido de temperatura máxima, o que evidencia a complexidade que compõe a produtividade (Figura 7).

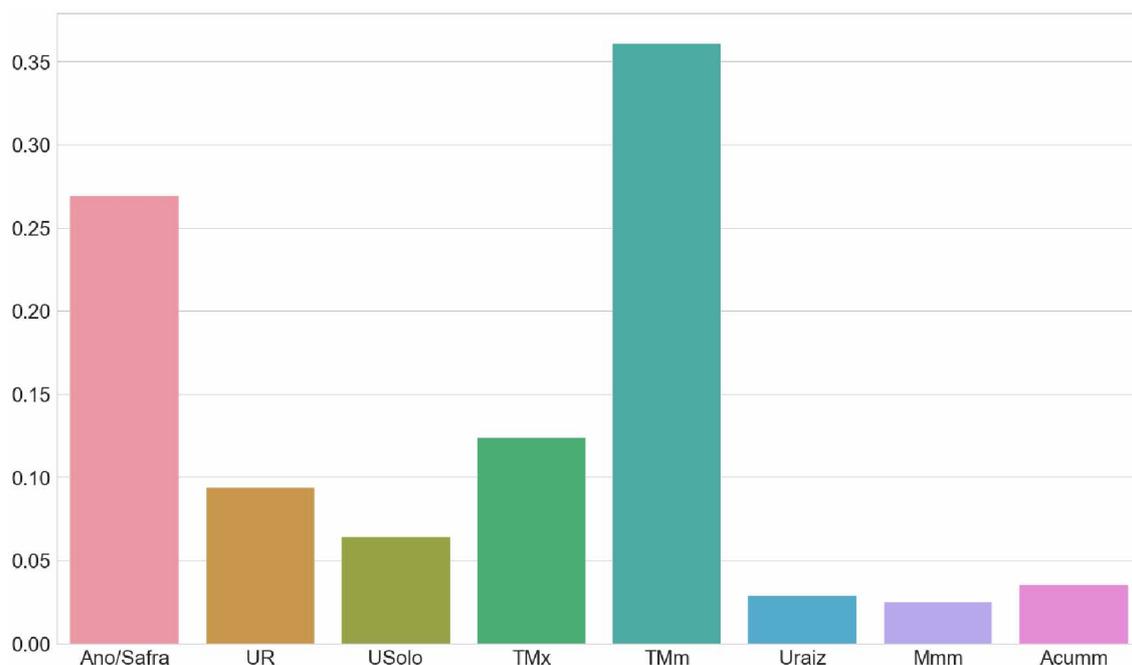


Figura 7. Importância dos caracteres abióticos na produtividade de algodoeiro.

UR= Umidade Relativa (%), USolo=Umidade no solo (%), TMx= Temperatura Máxima (°C), TMm= Temperatura Mínima (°C), Uraiz= Umidade na zona de raiz (°C), Mmm= Média de precipitação (mm) e Acumm= Acumulo de precipitação (mm).

A temperatura máxima foi o segundo fator em importância (13%). Isso possivelmente se deve ao fato do algodoeiro ser sensível a alta temperatura, interferindo seu ciclo, e conseqüentemente em seu potencial produtivo, pois tem via metabólica C3, e por isso, temperaturas acima da temperatura ótima (32°C), afetam a fotossíntese negativamente (BELTRÃO et al., 2011; BORÉM; FREIRE, 2014; IMAMT, 2022). Altas temperatura afetam todas as reações bioquímicas da fotossíntese, a integridade de membranas nos cloroplastos, atividade da rubisco e disponibilidade de CO₂ nas folhas (IMAMT, 2022; TAIZ; ZEIGER, 2013).

Por sua vez, a umidade relativa foi o terceiro em importância (9%). Esta influência diretamente a perda de água e disponibilidade de água no solo e podem reduzir a resposta fotossintética. Baixa umidade relativa interfere no gradiente de pressão de vapor, pode levar a um déficit mesmo com água disponível no sistema (IMAMT, 2022; TAIZ; ZEIGER, 2013).

A precipitação demonstra ter menor relevância para compor a produtividade. Mas isso pode ser devido a ausência das variações dentro de cada período, mas apenas o acumulado demonstrando que é necessário avaliar as precipitações acumuladas de forma segmentada. Além de ser veículo de nutrientes, a água também é importante no

esfriamento da superfície foliar, pela perda de calor evaporativo, que mantem a temperatura ótima de atividade enzimática. Estresses hídricos também ocasionam fechamento estomático, aumentando temperatura foliar, reduz a entrada de CO₂, afetando diretamente a produção de fotoassimilados (IMAMT, 2022; TAIZ; ZEIGER, 2013).

Conhecer a influencia dos fatores abióticos dão indícios sobre o desempenho fenotipico de cada cultivar. Contudo, é necessário utilizar esses dados para criar mecanismos seguros para, no caso, predizer a produtividade.

A inteligência computacional demonstra resultados promissores em diversas áreas, e sua utilização na agricultura se faz necessária, uma vez que é preciso aumentar o potencial produtivo sem aumentar área, e frente ao desafios impostos pela alteração climática, devido o aquecimento global.

Guimarães (2019), ao predizer a produtividade de soja utilizando fatores de tempo e *machine learning*, encontrou boa precisão dos valores preditos, em comparação aos valores reais de produtividade em 27 municipios do Mato Grosso.

Para milho, Souza (2021), encontrou resultado satisfatório para predizer a produtividade do milho, utilizando redes neurais artificiais, baseado em variaveis climaticas.

Conceição et al.(2021) demonstraram eficiência na predição pelas Redes Neurais Artificiais para a produtividade ao analisar mamão papaia com a utilização de caracteres morfologicos, assim como determinaram quais as características de maior importância para o desenvolvimento da rede.

Foi realizado a correlação de Pearson para estimar o efeito das variaveis segmentadas em meses que o algodoeiro ficou a campo, totalizando 58 variaveis, e suas relações com a produtividade (Figura 8) .

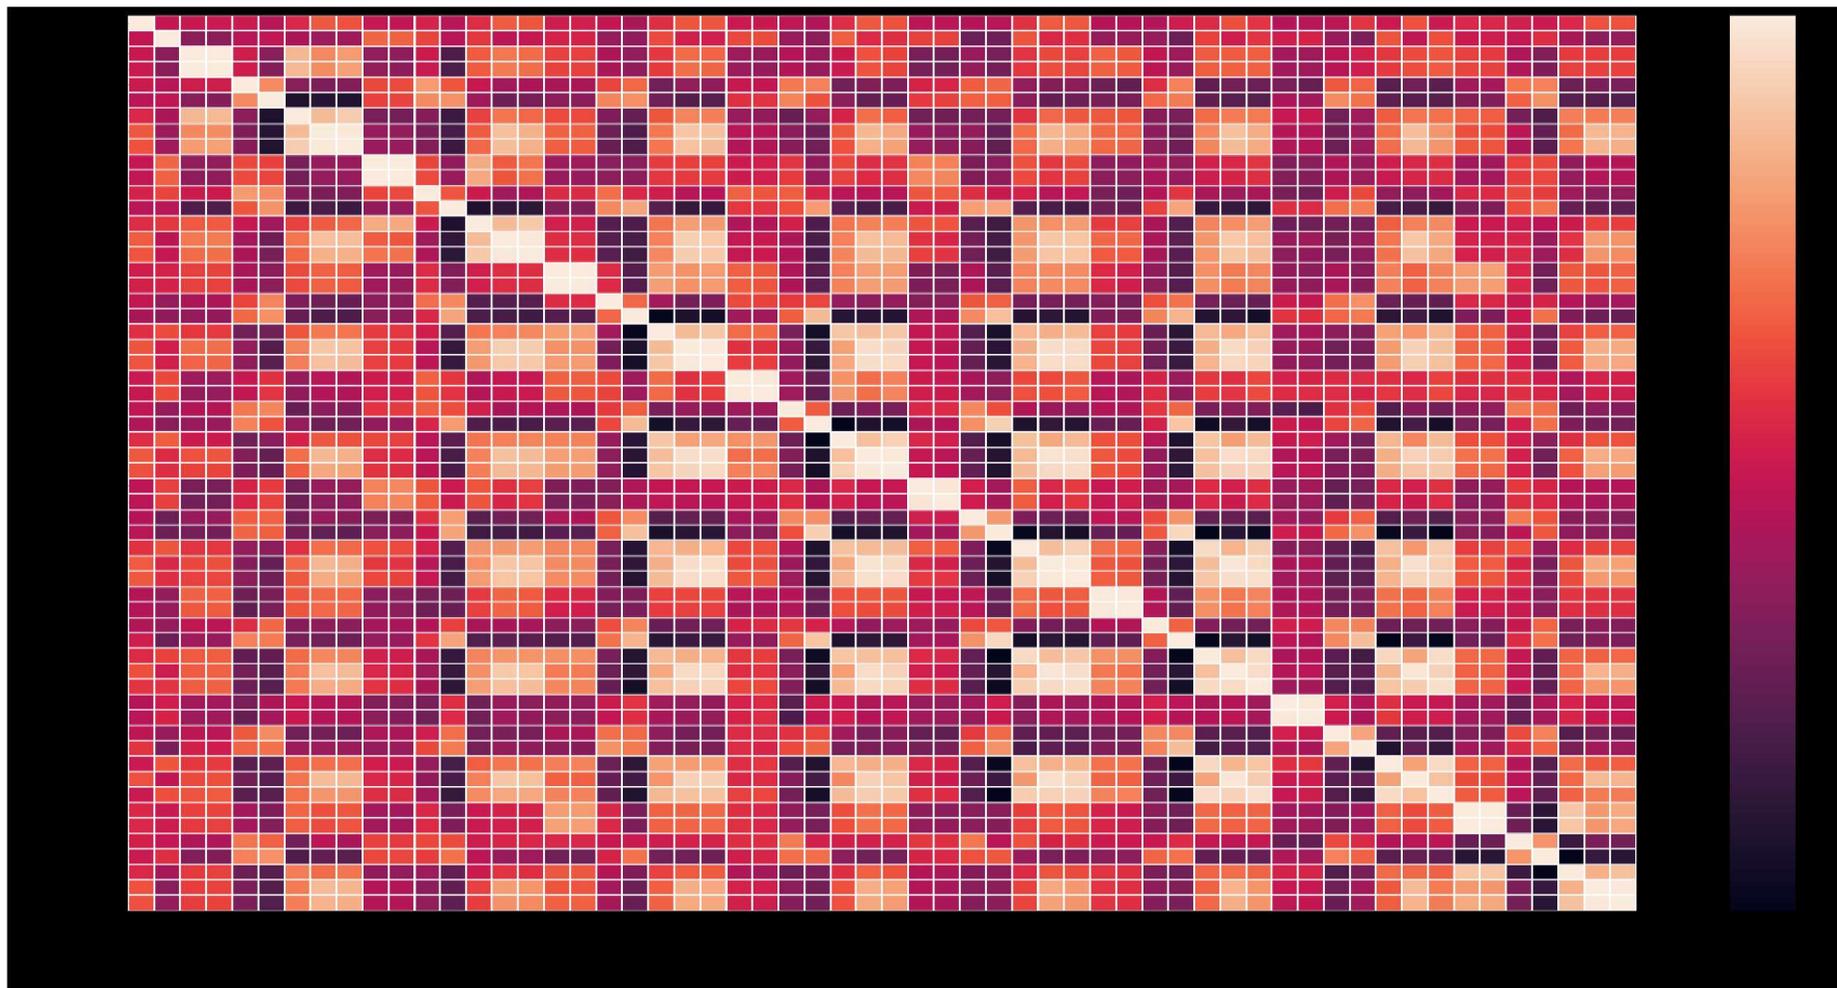


Figura 8. Correlação os fatores de temperatura, precipitações, umidades relativa e do solo mensais.

UR= Umidade Relativa (%), USolo=Umidade no solo (%), TMx= Temperatura Máxima (°C), TMm= Temperatura Mínima (°C), URaiz= Umidade na zona de raiz (°C), Mmm= Média de precipitação (mm) e Acumm= Acumulo de precipitação (mm), Dez=dezembro, Jan=janeiro; Fev=fevereiro, Mar=março; Abr=abril, Jun=junho; Jul=julho.

Quando há a segmentação mensal é possível observar que há variáveis com maior impacto na produção a depender do mês. A maior correlação positiva com produtividade foi de precipitação acumulada em fevereiro com 0,38 de correlação, seguido da umidade relativa no mês de julho (0,31), umidade do solo em julho com 0,29 e temperatura máxima em dezembro com 0,15.

Ao levar em consideração a semeadura em dezembro, o algodoeiro tem crescente aumento do aporte de água entre o florescimento e desenvolvimento das maçãs, que se inicia em fevereiro, e a falta de água nesse período afetará drasticamente a produtividade (BOREM; FREIRE, 2014; IMAMT, 2022).

No final do ciclo a umidade relativa e umidade do solo no mês de julho, têm alta correlação com produtividade, pois favorecem o desenvolvimento de maior peso de capulho, principalmente no terço superior, que garantem uma melhor produtividade (IMAMT, 2022; WANJURA et al., 2002).

Altas temperaturas no período de semeadura, possuem alta correlação com produtividade, ao comparar com as outras características. Possivelmente devido a efeito positivo de altas temperaturas (até 35°C) beneficiarem a germinação e o vigor, e conseqüentemente favorecer o estabelecimento do estande (NASCIMENTO et al., 2018; IMAMT, 2022).

As maiores correlações negativas foram para a precipitação acumulado em janeiro (-0,25), umidade na zona de raiz em dezembro (-0,24), umidade do solo em dezembro (-0,20). Alta umidade e precipitação no plantio e desenvolvimento inicial, favorecem o aparecimento de fungos e diminuem a respiração das raízes, prejudicando seu desenvolvimento (IMAMT, 2022).

Apesar das 58 variáveis demonstrarem correlações baixas, todas foram mantidas para realizar a predição. A retirada de variáveis de correlação menores impactou negativamente a precisão dos modelos.

Para verificar o impacto das relações positivas e negativas das variáveis na predição de produtividade foi realizado a análise gráfica *SHAP*. É importante ressaltar que os valores de *SHAP* não fornecem causalidade (HARRISON, 2020).

São demonstradas em escala decrescente, sendo a diferença entre o resultado predito com todas as variáveis e o resultado quando há a ausência de uma variável, medindo as contribuições para o resultado final separadamente (Figura 9) (HARRISON, 2020).

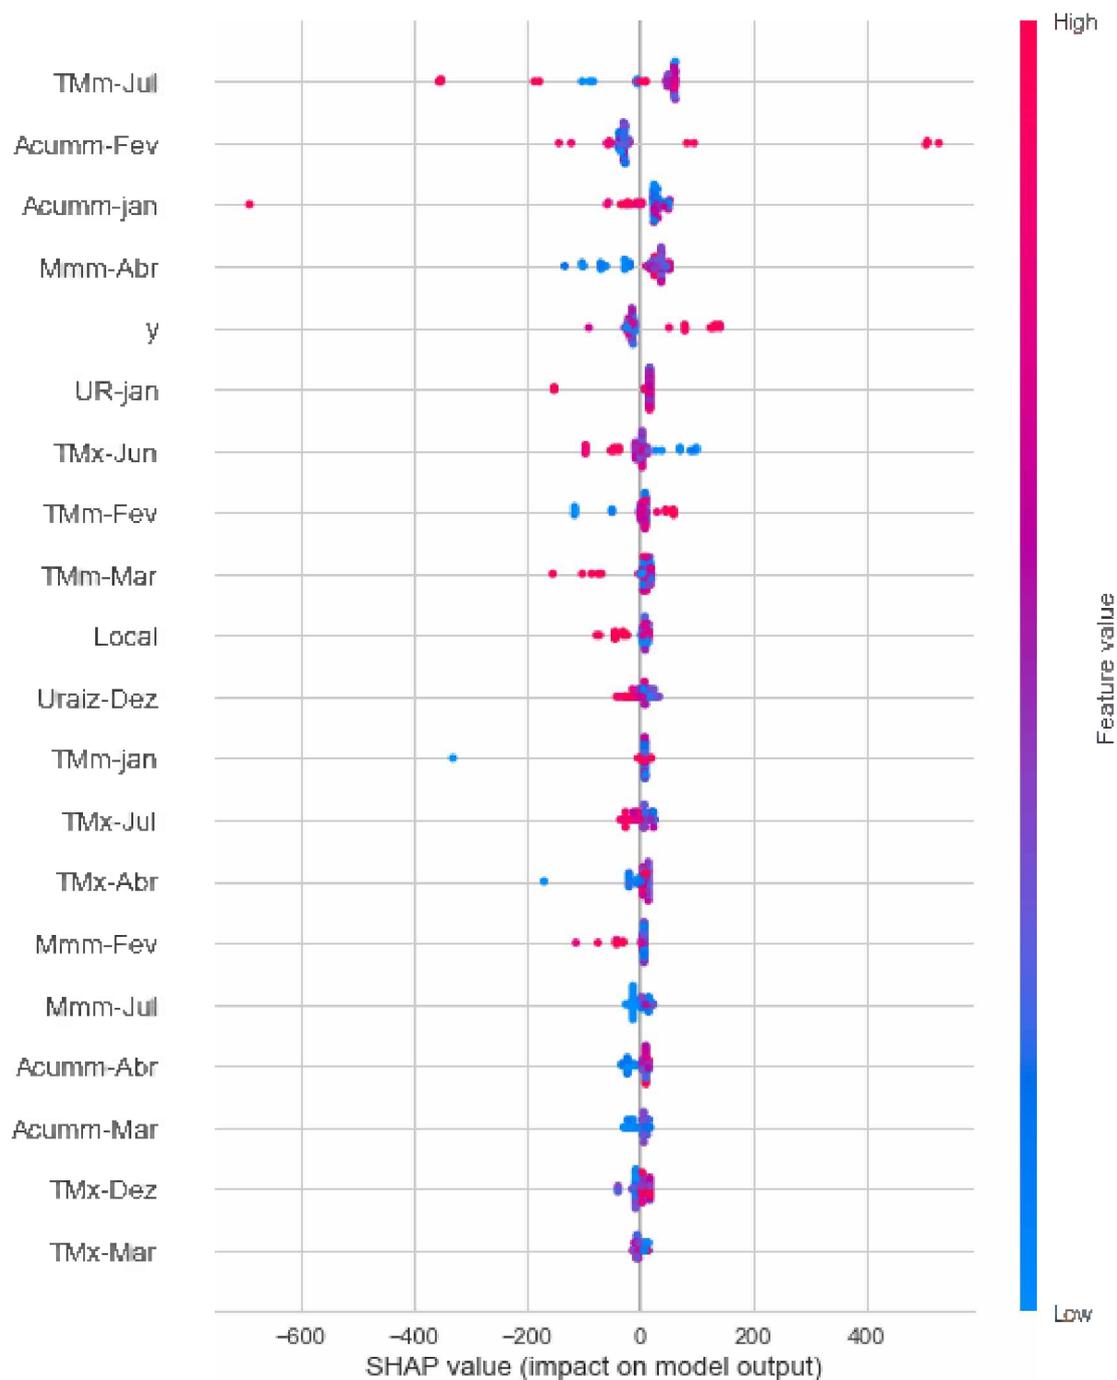


Figura 9. Síntese do Shapley, com os atributos classificados em ordem decrescente (parte superior para inferior). As cores mostram como os valores dos atributos afetam a produtividade

UR= Umidade Relativa (%), USolo=Umidade no solo (%), TMx= Temperatura Máxima (°C), Tm= Temperatura Mínima (°C), Uraiz= Umidade na zona de raiz (°C), Mmm= Média de precipitação (mm) e Acumm= Acumulo de precipitação (mm), Dez=dezembro, Jan=janeiro; Fev=fevereiro, Mar=março; Abr=abril, Jun=junho; Jul=julho.

Na parte superior as características que mais impactam o modelo segundo sua relevância, são temperatura mínima em julho e acumulado de precipitação em

fevereiro e janeiro. Entretanto, temperatura mínima em julho e acumulado de precipitação em fevereiro têm impacto de correlação negativa, uma vez que as cores em vermelho exercem alta pressão para alta produtividade, ao contrário de acumulado de precipitação em janeiro com correlação positiva.

Comparando os métodos quanto a precisão da previsão, verifica-se que o modelo de *Random Forest (RF)* e o de *Decision Tree (DT)* foram os mais adequados, pois mesmo não sendo precisos acompanharam as tendências de queda e subida da produtividade, ao contrário do modelo de RL, que demonstrou ausência de coerência (Figura 10).

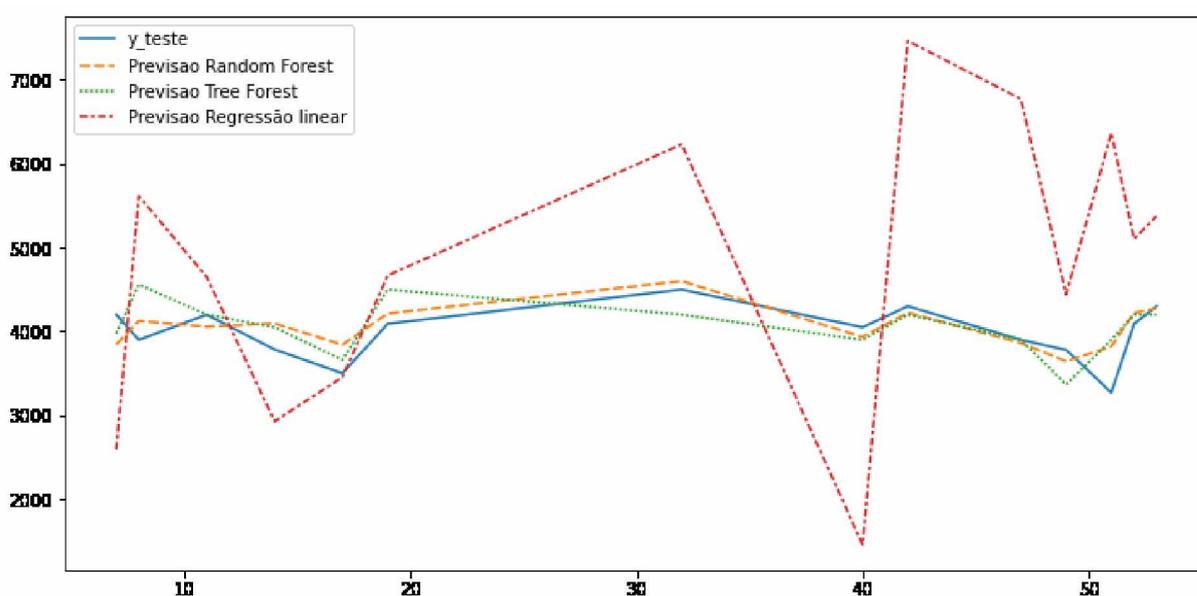


Figura 10. Previsões comparativas de produtividade entre os métodos e os valores observados (y_{teste})

Rehbein (2019) ao analisar a comparação entre *Deep Learning* e Regressão Linear, verificou que as RL não foram capazes de realizar a previsão com base na integração de Guaraná. Também Cordeiro (2020) encontrou superioridade em modelos de RF em comparação ao modelo de RL em *default* em empresas, corroborando com o presente trabalho.

Os modelos baseados em RL são melhores quando os dados possuem distribuição normal e ou linearidade dos dados de entrada (HARRISON, 2020), diferentemente dos modelos em árvore que não requerem normalidade e linearidade das entradas.

Os valores de RF quando comparados os valores preditos e os observados são apresentados na Tabela 4.

Tabela 4. Previsão da produtividade (kg ha⁻¹) utilizando *Random Forest*, com os dados de teste.

Local	Ano-Safra	Real	RF	Diferença
São Gonçalo do Abaeté (MG)	2017	4050,00	4020,31	29,69
Buritis (MG)	2015	3585,00	3914,39	-329,39
Buritis (MG)	2014	3366,00	3984,11	-618,11
São Gonçalo do Abaeté (MG)	2010	4200,00	3999,65	200,35
Presidente Olegário (MG)	2014	4300,00	4143,36	156,64
Unai (MG)	2014	3600,00	4001,51	-401,51
Buritis (MG)	2019	4300,00	4235,30	64,70
Unai (MG)	2013	3900,00	3778,92	121,08
Presidente Olegário (MG)	2017	3900,00	4023,99	-123,99
Presidente Olegário (MG)	2011	4350,00	4079,87	270,13
Buritis (MG)	2016	3500,00	3607,39	-107,39
Buritis (MG)	2018	3900,00	4200,73	-300,73
Coromandel (MG)	2016	3500,00	3845,87	-345,87
Unai (MG)	2020	4500,00	4420,62	79,38

RF= *Random Forest*. R²=40%.

O modelo obteve precisão de R²= 40%, que apesar de ser baixo, por ser uma característica quantitativa (VASCONCELOS et al., 2012). O desvio padrão foi de 186,88 (kg ha⁻¹). Ao analisar a raiz do erro quadrático (EQM), que avalia o erro do modelo em termos de precisão, obteve 145kg. Essa medida não é capaz de informar quão ruim é um modelo, mas pode ser usada para comparar dois modelos.

O modelo de TF obteve R² de 47,9%, Raiz (EQM) = 2,18 e desvio padrão de 163 (kg ha⁻¹). Houve maior diferença em escala comparativa ao RF, contudo, também houve maior assertividade ao predizer com exatidão a produtividade sendo elas, São Gonçalo do Abaete (2010), Buritis (2019) e Unai (2013) (Tabela 5).

Tabela 5. Previsão da produtividade (kg ha⁻¹) utilizando *Decision Tree*, apenas com os dados de teste.

Local	Ano-Safra	Real	DT	Diferença
São Gonçalo do Abaeté (MG)	2017	4050,00	3975,00	75,00
Buritis (MG)	2015	3585,00	3780,00	-195,00
Buritis (MG)	2014	3366,00	4200,00	-834,00
São Gonçalo do Abaeté (MG)	2010	4200,00	4200,00	0,00
Presidente Olegário (MG)	2014	4300,00	3960,00	340,00
Unaí (MG)	2014	3600,00	3780,00	-180,00
Buritis (MG)	2019	4300,00	4300,00	0,00
Unaí (MG)	2013	3900,00	3900,00	0,00
Presidente Olegário (MG)	2017	3900,00	3660,00	240,00
Presidente Olegário (MG)	2011	4350,00	3900,00	450,00
Buritis (MG)	2016	3500,00	2700,00	800,00
Buritis (MG)	2018	3900,00	4300,00	-400,00
Coromandel (MG)	2016	3500,00	3899,00	-399,00
Unaí (MG)	2020	4500,00	4852,00	-352,00

DT= *Decision Tree*; R² de 47,9%.

Já na RL houve o menor valor de R²=1% e erro de 1524 (kg ha⁻¹) e desvio padrão de 399,41 (kg ha⁻¹), demonstrando baixa precisão para predizer produtividade considerando apenas dados de tempo (Tabela 6). Os modelos baseando em RL são dependentes de linearidade entre as variáveis dependente e independente (HARRISON, 2020),

Tabela 6. Previsão da produtividade (kg ha⁻¹) utilizando Regressão Linear, apenas com os dados de teste.

Local	Ano-Safra	Real	RL	Diferença
São Gonçalo do Abaeté (MG)	2017	4050,00	1579,54	2440,77
Buritis (MG)	2015	3585,00	2557,35	1357,04
Buritis (MG)	2014	3366,00	5954,60	-1970,49
São Gonçalo do Abaeté (MG)	2010	4200,00	965,32	3034,33
Presidente Olegário (MG)	2014	4300,00	4641,71	-498,35
Unaí (MG)	2014	3600,00	5707,79	-1706,28
Buritis (MG)	2019	4300,00	2370,31	1864,99
Unaí (MG)	2013	3900,00	2756,64	1022,28
Presidente Olegário (MG)	2017	3900,00	3440,74	583,25
Presidente Olegário (MG)	2011	4350,00	3825,61	254,26

Buritis (MG)	2016	3500,00	5432,65	-1825,26
Buritis (MG)	2018	3900,00	4238,06	-37,33
Coromandel (MG)	2016	3500,00	2761,03	1084,84
Unai (MG)	2020	4500,00	2634,40	1786,22

RL= Regressão Linear; $R^2=1\%$

Guimarães (2019) ao prever a produtividade de soja com dados de clima e solo encontrou acurácia acima de 95% para o modelo *Random Forest* e erro médio de 41 kg ha⁻¹.

Santos (2020) ao analisar a produtividade de soja na região de Maranhão, Tocantins, Piauí e Bahia –MATOPIBA, encontrou erro de aproximadamente 167 kg ha⁻¹, corroborando com os dados desse trabalho para os métodos de *Random Forest* e *Decision Tree*.

A tendência geral do impacto das variáveis, pode ser visualizada de forma a conhecer como as variáveis contribuem para as previsões individuais, sendo a soma da predição à resposta (HARRISON, 2020). Para o modelo de RF é possível comprovar que temperatura máxima e umidade do solo têm os maiores impactos positivos em produtividade. Ao contrário, temperatura mínima em julho tem maior efeito negativo sobre a produtividade (Figura 11).



Figura 11. Efeitos individuais das variáveis na predição de produtividade (kg ha⁻¹).

UR= Umidade Relativa (%), USolo=Umidade no solo (%), TMx= Temperatura Máxima (°C), TMm= Temperatura Mínima (°C), Uraiz= Umidade na zona de raiz (°C), Mmm= Média de precipitação (mm) e Acumm= Acumulo de precipitação (mm), Dez=dezembro, Jan=janeiro; Fev=fevereiro, Mar=março; Abr=abril, Jun=junho; Jul=julho

Baixas temperaturas prejudicam a formação das maçãs, acarretando em menor peso de capulho e conseqüentemente menores produtividades. Umidade do solo alta em dezembro favorece a germinação e vigor, favorecendo a formação de estande. Temperaturas altas em dezembro podem prejudicar a germinação, contudo, no modelo o efeito da temperatura a 35°C pode contribuir para o aumento da produtividade (IMAMT, 2022).

A predição da produtividade pode contribuir com a tomada de decisão no manejo e planejamento, baseado em fatores climáticos. Saber que os fatores abióticos serão desfavoráveis e que diminuirá a produtividade em porcentagens significativas, podem evitar perdas financeiras, em especial no algodoeiro que possui produtos, como os reguladores de crescimento, maturadores e desfolhadores, que podem contornar efeitos adversos minimizando perdas de produção.

A falta de precisão dos modelos apresentados pode ser devido a quantidade de dados ser insuficiente para a predição, ou seja, acredita-se que seja necessária uma maior quantidade de localidades e anos para melhor acurácia do modelo.

Outro ponto que pode ter impactado o modelo pode ser a ausência de informações morfológicas das cultivares, como altura, área foliar, número de nós e posições de maçãs, fatores preponderantes para estimar a produtividade.

5

CONCLUSÕES

5. CONCLUSÕES

O uso da inteligência computacional para predição de produtividade utilizando apenas dados climáticos pode inferir com precisão para estimar dados de produtividade de algodão em fibra.

Os dados mensais têm impacto na qualidade do modelo de predição, sendo precipitação acumulada em fevereiro, umidade relativa em julho, umidade do solo em julho e temperatura máxima em dezembro os caracteres mais importantes.

O método *machine learning*, *Random Forest* fornece resultados superiores para predizer a produtividade de algodoeiro, com base nas variáveis do tempo, comparativamente aos métodos de regressão linear e *Decision Tree*, nos municípios mineiros.

É necessário um banco de dados mais robustos que contenham mais informações fenotípicas do algodoeiro para melhor precisão dos modelos visando predizer a produtividade do algodoeiro em Minas Gerais.

REFERÊNCIAS

- AGENCIA MINAS. Bons preços favorecem a produção mineira de algodão. **AMVAP**. Uberlândia. Disponível em: <https://www.amvapmg.org.br/1/bons-precos-favorecem-a-producao-mineira-de-algodao>. Acesso em: 29 jul. 2022.
- AMARAL, L. de O. Redes neurais artificiais aplicadas na predição de valores genéticos e classificação de genótipos de soja de diferentes grupos de maturidade relativa. 2021. Tese (Doutorado) – Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal: Unesp, 2021. Disponível em: <http://hdl.handle.net/11449/214447>. Acesso em: 15 jan. 2022
- ASSOCIAÇÃO MARANHENSE DOS PRODUTORES DE ALGODÃO-AMPA. História do Algodão. **AMAPA**. Maranhão. Disponível em: <https://amapa-ma.com.br/historia-do-algodao/>. Acesso em: 29 jul. 2022.
- ASSOCIAÇÃO MINEIRA DE PRODUTORES DE ALGODÃO-AMIPA . Programa Mineiro de Incentivo à Cultura do Algodão. Disponível em: <https://amipa.com.br/proalminas>. Acesso em: 5 ago. 2022.
- BARROSO, L. M. A. N.; NASCIMENTO, M.; SILVA, A. C. C.; FERREIRA, F. F.; PAULA de, R. Uso do método de eberhart e russell como informação a priori para aplicação de redes neurais artificiais e análise discriminante visando a classificação de genótipos de alfafa quanto à adaptabilidade e estabilidade fenotípica. **Revista Brasileira Biomedicina**, São Paulo, v. 31, n. 2, p. 176-188, 2013.
- BELTRÃO, N. E. de M.; OLIVEIRA, M. I. P. de.; SOUSA JÚNIOR, S. P. de.; BRITO, G. G. de.; CARDOSO, G. D. **Ecofisiologia do algodoeiro (*G. hirsutum*)**. 1 ed. Brasília-DF: Embrapa Informação Tecnológica. 2011.
- BELTRÃO, N. E. de M.; AZEVEDO, D. M. P. O Agronegócio do Algodão no Brasil. **Editora Embrapa**, Campina Verde, ed. Campina Verde: 2008 1v.
- BOREM, A.; FREIRE, E. C. **Algodão do Plantio à Colheita**. Viçosa: Editora UFV, 2014.
- BOREM, A.; MIRANDA, G. V.; FRITSCHÉ-NETO, R. **Melhoramento de Plantas**. Viçosa: Editora UFV, 2021.
- CARDOSO, D. B. O. OLIVEIRA, L. F.; SOUZA, G.D.de.; GARCIA, M. F.; MEDEIROS, L. A.; FARIA, P. N.; CRUZ, C. D.; SOUSA, L. B. de. Using fuzzy logic to select coloured-fibre cotton genotypes based on adaptability and yield stability. **Acta Scientiarum. Agronomy**, Maringá, v. 43, 2021. DOI: <https://orcid.org/0000-0003-0421-0905> . Disponível em: <https://periodicos.uem.br/ojs/index.php/ActaSciAgron/article/view/50530>. Acesso em: 15 jan. 2022
- CARNEIRO, V. Q. **Rede neural e lógica fuzzy aplicadas no melhoramento do feijoeiro**. 2015. 91 f. Dissertação. (Mestrado) – Universidade Federal de Viçosa,

Viçosa, 2015. Disponível em: <http://www.locus.ufv.br/handle/123456789/6785>. Acesso em: 15 jan. 2022

CARNEIRO, V. Q. *et al.* Sistemas de controle fuzzy para tomada de decisão na recomendação de cultivares. **Acta Scientiarum. Agronomy**, Maringá, v. 40, 2018.

CARVALHO, A.C.P. de L. F. de. CEMEAI. Redes Neurais Artificiais. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em: 31 jul. 2022.

COMPANHIA NACIONAL DE ABASTECIMENTO. CONAB. **Acompanhamento da safra brasileira de grãos 2022**. Brasília, DF, 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 15 jan 2022

CONCEIÇÃO, L. V. da; NEPOMUCENO, C. F.; GUIMARÃES, B. V. C.; SILVA, S. de O. Predição de produtividade do mamoeiro (*Carica Papaya L.*) por redes neurais artificiais. **Research, Society and Development**, [s. l.], v. 10, n. 12, 2021. DOI: <http://dx.doi.org/10.33448/rsd-v10i12.20692>. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/20692/18577>. Acesso em: 5 ago. 2022.

CORDEIRO, T. V. B. **Predição de default de empresas: técnicas de machine learning em dados desbalanceados**. São Paulo, SP: FGV EESP - Escola de Economia de São Paulo, 2020. Disponível em: https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/29873/Disserta_o_Tiago_%20-%202020-11-27T201019.927.pdf?sequence=1&isAllowed=y. Acesso em: 15 jan 2022

GADELHA, I. C. N.; FONSECA, N. B. S.; OLORIS, S. C. S.; MELO, M. M.; SOTO-BLANCO, B. Gossypol Toxicity from Cottonseed Products. **The Scientific World Journal**, [s. l.], maio 2014. DOI: <https://doi.org/10.1155/2014/231635>. Disponível em: <https://www.hindawi.com/journals/tswj/2014/231635/>. Acesso em: 15 jan 2022

NASCIMENTO, I. C. M.; REIS, J. J. DA S.; SILVA, O. R. R. F. DA.; FRANÇA, P. R. C. DE.; ARAÚJO, B. M. N. Avaliação da temperatura na germinação de sementes de algodão colorido. EMBRAPA. Brasília, DF: EMBRAPA, 2018. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1107143/avaliacao-da-temperatura-na-germinacao-de-sementes-de-algodao-colorido>. Acesso em: 15 jan 2022

CRUZ, C. D. Programa Genes - Ampliado e integrado aos aplicativos R, Matlab e Selegen. **Acta Scientiarum. Agronomy**, Maringá, v. 38, n. 4, p. 547–552, dez. 2016. DOI: <https://doi.org/10.4025/actasciagron.v38i4.32629>. Disponível em: <https://www.scielo.br/j/asagr/a/sLvDYF5MYv9kWR5MKgxb6sL/abstract/?lang=en>. Acesso em: 15 jan 2022

CRUZ, C. D.; CARNEIRO, P. C. S.; REGAZZI, A. J. **Modelos Biométricos Aplicados ao Melhoramento Genético**. 3. ed. Viçosa: Editora UFV, 2014.

CRUZ, C. D.; NASCIMENTO, M. **Inteligência computacional aplicada ao melhoramento Genético de plantas**. 1. ed. Viçosa: Editora UFV, 2018.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Padrões Universais para Classificação do Algodão**. EMBRAPA. Brasília, DF: Embrapa Algodão, 2006. Disponível em: <http://www.cnpa.embrapa.br/>. Acesso em: 15 jan 2022

GÉRON, A. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow**. Conceitos, Ferramentas e Técnicas para a Construção de Sistemas Inteligentes. 1. ed. Rio de Janeiro: Editora Alta Book, 2019.

GUIMARÃES, S. E. **Aprendizado de Máquina aplicado à predição da produtividade da cultura da soja utilizando dados de clima e solo**. 2020. Dissertação (Mestrado) – Instituto de Ciências Matemáticas e de Computação Matemática, Estatística e Computação, Universidade de São Paulo, São Carlos, 2019. Disponível em: <https://www.teses.usp.br/teses/disponiveis/55/55137/tde-09062020-123106/pt-br.php>. Acesso em: 15 jan 2022

HARRISON, M. **Machine Learning Pocket Reference**. 1. ed. U.S.A.: O'Reilly Media, 2019.

HUANG, G.; Wu, Z.; PERCY, R. G.; BAI, M.; LI, Y.; FRELICHOWSKI, J. E.; HU, J.; WANG, K.; YU, J. Z.; ZHU, Y. Genome sequence of *Gossypium herbaceum* and genome updates of *Gossypium arboreum* and *Gossypium hirsutum* provide insights into cotton A-genome evolution. **Nature Genetics**, London, v. 52, n. 5, p. 516–524, 2020. Disponível em: <https://www.nature.com/articles/s41588-020-0607-4>. Acesso em: 01 fev. 2022.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. IBGE. Sistema IBGE de Recuperação Automática - **SIDRA**. Brasil: IBGE, 2022. Disponível em: <https://sidra.ibge.gov.br/home/pimpfbr/brasil>. Acesso em: 2 ago. 2022.

INTERNATIONAL COTTON ADVISORY COMMITTEE-ICAC. **Production of cotton lint in '000 metric tonnes**. 2021. Disponível em: <https://icac.org/DataPortal/DataPortal?MenuId=23>. Acesso em: 10 fev. 2022.

INSTITUTO MATO-GROSSENSE DO ALGODÃO-IMAMT. **Fisiologia aplicada ao manejo do algodoeiro**. MATO GROSSO, MT: IMANT, 2022. Disponível em: https://imamt.org.br/wp-content/uploads/2022/02/boletim_fisiologia_2022_VF_WEB.pdf. Acesso em: 29 jul. 2022.

INSTITUTO MATO-GROSSENSE DE ECONOMIA AGROPECUÁRIA-IMEA. **Custo de produção do algodão – Safra 2020/2021**. MATO GROSSO, MT: IMEA, 2020. Disponível em: <https://www.imea.com.br/imea-site/relatorios-mercado-detalle?c=1&s=696277432068079616>. Acesso em: 29 jul. 2022.

MORAIS, J. P. S.; FARIAS, F. J. C.; BELOT, J. L.; MARTINS, R. S. A.; MIZOGUCHI, E. T. Interpretação das características avaliadas no SITC para qualidade de fibra de algodão: Uma abordagem prática. *In*: Empresa Brasileira de Agropecuária. **EMBRAPA ALGODÃO**. Brasília, DF: EMBRAPA, 2021. Disponível em: <https://www.embrapa.br/algodao/busca-de-publicacoes/>

[/publicacao/1134241/interpretacao-das-caracteristicas-avaliadas-no-sitc-para-qualidade-de-fibra-de-algodao-uma-abordagem-pratica](#). Acesso em: 15 jan. 2022

NETO, F. DAS C. V.; FREIRE, E. C. Melhoramento genético do algodoeiro. *In*: ACESSO LIVRE À INFORMAÇÃO DA EMBRAPA. ALICE. Brasília, DF: EMBRAPA, 2013. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/983837>. Acesso em: 15/01/2022

NOGUEIRA, L. C. A. **Machine learning para detecção de *Pratylenchus brachyurus* na cultura da soja utilizando imagens MSI/SENTINEL-2**. 2020. 60 f. Dissertação (Mestrado) – Instituto Federal de Educação, Ciência e Tecnologia Goiano, Campus Rio Verde, 2020. Disponível em: <https://repositorio.ifgoiano.edu.br/handle/prefix/1827#:~:text=para%20este%20item%3A-,https%3A/repositorio.ifgoiano.edu.br/handle/prefix/1827,-Tipo%3A%C2%A0>. Acesso em: 02 abr. 2022

OLIVEIRA, L. F. **Ausência de gossipol (glandless) afeta a produtividade e rendimento do algodoeiro?** 2020. Trabalho de Conclusão de Curso (Graduação em agronomia) – Universidade Federal de Uberlândia, Uberlândia, 2020. Disponível em: <https://repositorio.ufu.br/handle/123456789/31058>. Acesso em: 30 jul. 2022.

PENNA, J. **Melhoramento de espécies cultivadas**. ed. Viçosa, ed. Viçosa, MG: [s.n.]. v. 2, 2001

NASA/POWER | Data Access Viewer. Disponível em: <https://power.larc.nasa.gov/data-access-viewer/>. Acesso em: 2 ago. 2022.

REHBEIN, M. H. **Estudo comparativo de deep learning e regressão linear na predição de mensagens processadas pela plataforma de integração guaraná**. 2019. Trabalho de Conclusão de Curso (Graduação) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2019. Disponível em: <https://bibliodigital.unijui.edu.br:8443/xmlui/handle/123456789/6705>. Acesso em: 15 jan. 2022

SAATH, K. C. de O.; FACHINELLO, A. L. Crescimento da Demanda Mundial de Alimentos e Restrições do Fator Terra no Brasil. **Revista de Economia e Sociologia Rural**, Brasília, abr/jun 2018. DOI: <https://doi.org/10.1590/1234-56781806-94790560201>. Disponível em: <https://www.scielo.br/j/resr/a/DdPXZbMzxy89xBDg3XCTgr/?lang=pt>. Acesso em: 15 jan. 2022

SANTOS, J. A. A. dos; SPANCERSKI, J. S. Redes neurais aplicadas na predição do preço da soja no estado do Paraná. **Perspectivas Online**, Campos dos Goytacazes, v. 11, n. 32, p. 19–32, jun. 2021. DOI: <https://doi.org/10.25242/885X113220212282>. Disponível em: https://ojs3.perspectivasonline.com.br/exatas_e_engenharia/article/view/2282. Acesso em: 03 jan. 2022.

SANTOS, V. B. dos. **Estimação e previsão de produtividade de soja por redes neurais no MATOPIBA**. 2020. Dissertação (Mestrado) – Faculdade de Ciências

Agrárias e Veterinárias, Pós- Graduação em Agronomia, Jaboticabal, 2020. Disponível em: <http://hdl.handle.net/11449/191987>. Acesso em: 15 jan. 2022

SILVA, L. C. de. A.; RICHETTI, J.; BECKER, W.R.; PALUDO, A.; VERICA, W.R.; JOHANN, J.A. Algoritmos de Aprendizado de Máquina para classificação de soja em imagens Landsat-8. **Acta Iguazu**, Cascavel, v.6, n. 3, p. 65–78, 2017. DOI: <https://doi.org/10.48075/actaiguaz.v6i3.17477>. Disponível em: <https://saber.unioeste.br/index.php/actaiguazu/article/view/17477>. Acesso em: 15 jan. 2022.

SILVA, W. L. B. da. **Predição da germinação de sementes de soja usando aprendizado de máquina profundo**. 2021. Trabalho de Conclusão de Curso (Graduação) de tecnologia e análises de sistemas. 2021. – Universidade Federal do Rio Grande do Norte, Macaíba, 2021. Disponível em: <https://repositorio.ufrn.br/handle/123456789/37916>. Acesso em: 15 jan. 2022.

SOUZA, P. V. D. de. **Rede Neural Artificial para Predição da Produtividade da Cultura do Milho**. 2021. Trabalho de Conclusão de Curso (Graduação). – Universidade Tecnológica do Paraná, Santa Helena, 2021. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/26421>. Acesso em: 15 jan. 2022

SUGENO, M.; KANG, G. Structure identification of fuzzy model. **Fuzzy Sets and Systems**, [s. l.], v. 28, n. 1, p. 15-33, out. 1988. DOI: [https://doi.org/10.1016/0165-0114\(88\)90113-3](https://doi.org/10.1016/0165-0114(88)90113-3). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/0165011488901133#!>. Acesso em: 15 jan. 2022.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. Porto Alegre: Artmed, 2013.

WANJURA, D. F.; UPCHURCH, D. R.; MAHAN, J. R.; BURKE, J. J. Cotton yield and applied water relationships under drip irrigation. **Agricultural Water Management**, [s. l.], v. 55, n. 3, p. 217–237, jun. 2002. DOI: [https://doi.org/10.1016/S0378-3774\(01\)00175-5](https://doi.org/10.1016/S0378-3774(01)00175-5). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0378377401001755>. Acesso em: 15 jan. 2022

Capítulo 2

Utilização de Lógica Fuzzy na recomendação de adaptabilidade e estabilidade de genótipos de algodoeiro de fibra colorida quanto a produtividade

RESUMO

O algodoeiro (*Gossypium hirsutum* L.) é a principal fibra têxtil natural utilizada no mundo sendo cultivado em mais de 60 países. No Brasil é considerada um importante *commoditie* agrícola, tendo uma área cultivada de aproximadamente um milhão de hectares. No país, devido sua importância, o algodoeiro vem se expandindo para todas as regiões, estabelecendo-se principalmente no bioma Cerrado. Em decorrência dessa expansão se faz necessário analisar a influência dos ambientes sobre o comportamento dos genótipos, a fim de garantir seu máximo potencial produtivo. Com base no exposto, o objetivo deste trabalho foi avaliar a utilização da Lógica Fuzzy pelo método de Eberhart e Russel (1966) comparado a métodos tradicionais na seleção de genótipos de algodoeiro de fibra colorida com alta adaptabilidade e estabilidade produtiva. O experimento foi conduzido em uma área experimental localizada na Fazenda Capim Branco (18°52'S; 48°20'W e 805m de altitude), pertencente à Universidade Federal de Uberlândia, no município de Uberlândia, Minas Gerais, nas safras 2013/2014, 2014/2015, 2015/2016 e 2016/2017. Foi utilizado os métodos de Lin e Binns (1988), *Additive Mean Effects and Multiplicative Interaction Analysis* (AMMI) e Lógica Fuzzy com controlador Sugeno, para recomendação de genótipos quanto a adaptabilidade e estabilidade. Houve interação Genótipos x Ambientes para produtividade. O ambiente 4 (safra 2016/2017) foi o que menos contribuiu para a interação Genótipos x Ambientes. A inteligência computacional Lógica Fuzzy demonstrou concordância com os métodos AMMI e o método não paramétrico Lin e Binns (1988). A Lógica fuzzy linguísticas implementadas nos controladores Fuzzy de Sugeno demonstrou potencial para recomendações de genótipos de algodoeiro em programas de melhoramento genético de plantas. Os genótipos UFUJP-16 e UFUPJ-17 demonstraram serem adaptados, estáveis e promissores para produtividade nos ambientes testados. O método utilizando lógica Fuzzy demonstrou alto potencial na estimativa de adaptabilidade e estabilidade.

Palavras-Chave: AMMI; *Gossypium hirsutum*; Melhoramento de plantas

Introdução

1. INTRODUÇÃO

O algodoeiro (*Gossypium hirsutum* L.) é a principal fibra têxtil natural utilizada no mundo, sendo cultivado em mais de 60 países. No Brasil é considerada um importante *commoditie* agrícola, cultivada em mais de um milhão de hectares (CONAB 2019).

Devido sua importância econômica-social, o algodoeiro vem se expandindo para todas as regiões do país, estabelecendo-se principalmente no bioma Cerrado. Em decorrência deste crescimento se faz necessário analisar a influência dos ambientes sobre o comportamento dos genótipos, afim de garantir seu máximo potencial produtivo (CONAB, 2018; CRUZ; REGAZZI; CARNEIRO, 2014).

O comportamento do genótipo pode ser determinado pela interação genótipos x ambientes. Existindo a interação é necessário realizar o estudo da adaptabilidade e estabilidade como forma de prever a dos genótipos frente aos estímulos ambientais assim como sua previsibilidade de comportamento (QUEIROZ et al., 2014).

Existem várias metodologias empregadas para analisar a adaptabilidade e estabilidade, variando quanto a estatística empregada, de acordo com a necessidade da precisão, números de ambientes e das informações que se desejam obter.

Entre os métodos mais utilizados se destacam os baseados na análise de variância, como o método de Plaisted e Peterson (1959), os baseados em regressão linear simples a exemplo do Eberhart e Russell (1966), os que utilizam o método não paramétrico como o Centróide (ROCHA et al, 2005) modificado por Nascimento et al. (2009) e os multivariados como a *Interação de Modelos Multiplicativos Aditivos* (AMMI) (DUARTE; VENCOSKY, 1999).

O método de Eberhart e Russell (1966) se destaca pela facilidade de interpretação dos resultados, sendo muito utilizado no melhoramento. Contudo há um viés em sua utilização quando o número de ambientes é menor que 10, prejudicando a precisão das estimativas de classificação dos genótipos, além de causar a não rejeição de hipóteses nulas falsas (NASCIMENTO et al., 2013).

Para contornar esta limitação do método, a inteligência computacional surge como uma alternativa, utilizando da modelagem matemática para simular a lógica humana com suas aproximações e incertezas (CARNEIRO, 2015; CARNEIRO, 2016), atribuindo

graus de pertinências aos elementos. Carneiro (2015) utilizou inteligência artificial lógica Fuzzy como ferramenta para recomendação de cultivares de feijoeiro, assim como Carneiro (2016) para a recomendação de cultivares de feijoeiro quanto a adaptabilidade e estabilidade.

Com base no exposto, o objetivo deste trabalho foi avaliar a utilização da Lógica Fuzzy pelo método de Eberhart e Russel (1966) comparado aos métodos tradicionais na seleção de genótipos de algodoeiro de fibra colorida com alta adaptabilidade e estabilidade.

2***Material e Métodos***

2. MATERIAL E MÉTODOS

O experimento foi conduzido em uma área experimental localizada na Fazenda Capim Branco (18°52'S; 48°20'W e 805m de altitude), pertencente à Universidade Federal de Uberlândia, no município de Uberlândia, Minas Gerais, nas safras 2013/2014 (ambiente 1), 2014/2015 (ambiente 2), 2015/2016 (ambiente 3) e 2016/2017 (ambiente 4).

Segundo os dados climáticos (1981 a 2008) fornecidos pelo Instituto de Geografia da Universidade Federal de Uberlândia, a cidade apresenta temperatura média do ar de 22,4° C, umidade relativa do ar média de 70% e precipitação pluvial anual média de 1.584 mm por ano.

As condições meteorológicas durante a condução do experimento foram monitoradas via uma estação meteorológica automática Davis Vantage Pro 2 que apresenta sensores de temperatura e precipitação pluviométrica (Figura 12).



Figura 12. Dados meteorológicos no período de 12/2013 a 06/2014, 12/2014 a 06/2015, 12/2015 a 06/2016 e 12/2016 a 30/06/2017.

MAX (°C) – Temperatura máxima; MIN (°C) – Temperatura mínima; Prec (mm) – Precipitação

Foram avaliados doze genótipos de algodoeiro de fibra colorida, sendo 10 proveniente do Programa de Melhoramento Genético do Algodoeiro (PROMALG-UFU): UFUJP-01, UFUJP-02, UFUJP-05, UFUJP-08, UFUJP-09, UFUJP-10, UFUJP-11, UFUJP-13, UFUJP-16, UFUJP-17, e duas cultivares comerciais: BRS Rubi (RC) e BRS Topázio (TC).

O delineamento experimental utilizado foi o de blocos completos casualizados (DBC) com três repetições. A parcela experimental constituiu de quatro linhas de cinco metros espaçadas de um metro, sendo a área útil composta pelas duas linhas centrais desprezando 0,5 m de cada extremidade da linha.

A área em que foi realizado o experimento situa-se em Latossolo Vermelho Escuro distrófico, de textura argilosa. Para o preparo do solo realizou-se aração e gradagem, seguido de calagem e adubação, segundo recomendações para a cultura.

O experimento foi semeado na última semana de cada mês de dezembro, com 16 sementes por metro linear a 2 cm de profundidade. Aos 30 dias após emergência, realizou-se o desbaste, mantendo oito plantas por metro linear.

Foram feitas diversas aplicações com produtos fitossanitários, visando o manejo integrado de pragas. As principais pragas encontradas e controladas foram: mosca branca (*Bemisia tabaci*), pulgão (*Aphis gossypii*), bicudo do algodoeiro (*Anthonomus grandis*), trips (*Frankliniella spp.*), curuquerê (*Alabama argilacea*) e ácaro rajado (*Tetranychus urticae*). Durante todo o ciclo da cultura, foram feitas aplicações sequenciais com regulador de crescimento cloreto de mepiquat (1,1-dimethylpiperidinium chloride).

As avaliações foram realizadas na maturação plena (MARUR; RUANO, 2003), avaliando cinco plantas aleatórias na área útil, sendo:

Produtividade de algodão em caroço: coleta e pesagem de todos os capulhos abertos da área útil de cada parcela (kg ha^{-1}).

Para as análises de adaptabilidade e estabilidade, utilizou-se o método de Eberhart e Russell (1966), que se utiliza a regressão linear simples dos genótipos, para determinar os parâmetros de estabilidade e adaptabilidade sendo definido pelo modelo estatístico a seguir:

$$Y_{ij} = \beta_{0i} + \beta_{1i}I_j + \delta_{ij} + \bar{\varepsilon}_{ij}$$

Em que:

Y_{ij} : média do genótipo i no ambiente j ;

β_{0i} : média geral do genótipo;

β_{1i} : coeficiente de regressão linear, que mede a resposta do i -ésimo genótipo à variação do ambiente;

I_j : índice ambiental codificado ($\sum I_{ji} = 0$);

δ_{ij} : desvio da regressão

$\bar{\varepsilon}_{ij}$: erro experimental médio

$$\sigma^2_{di} = \sum_j \widehat{\delta}_{ij} / (a - 2)$$

$$B_{1i} = \frac{\sum_j Y_{ij} I_j}{\sum_j I_j^2}$$

Pelo método de Lin e Binns modificado (Carneiro, 1998) estima-se a adaptabilidade e estabilidade, baseando na identificação dos genótipos com maior média, mais responsivos em cada ambiente, em relação a proximidade com os demais genótipos, classificando-os com o quadrado médio geral (P_i), sendo auxiliada pela decomposição deste associados as medias de desempenho em ambientes favoráveis (P_{if}) e em desfavoráveis (P_{id}). Por este método o genótipo ideal é aquele que apresenta menor valor de P_i vinculados aos menores valores para ambientes favoráveis ou desfavoráveis, P_{if} e P_{id} , respectivamente.

$$P_{if} = \frac{\sum_{j=1}^n (Y_{ij} - M_j)^2}{2f}$$

$$P_{id} = \frac{\sum_{j=1}^n (Y_{ij} - M_j)^2}{2f}$$

Em que:

P_{if} : estimativa do parâmetro medida de adaptabilidade e estabilidade da cultivar i para ambientes favoráveis;

P_{id} : estimativa do parâmetro medida de adaptabilidade e estabilidade da cultivar i para ambientes desfavoráveis;

Y_{ij} : produtividade da i -ésima cultivar no j -ésimo ambiente;

M_j : resposta máxima observada entre todas as cultivares no ambiente j ;

f : número de ambientes favoráveis

d: número de ambientes desfavoráveis

No método utilizando o controlador Fuzzy – Eberhart e Russell (1966) baseado no sistema de inferência fuzzy proposto por Sugeno (Takagi; Sugeno, 1985; Sugeno; Kang, 1988a; b; Sugeno; Tanaka, 1991; Sugeno; Yasukawa, 1993) utilizou os parâmetros média geral (β_0), coeficiente de regressão (β_1) e coeficiente de determinação (R^2) que são componentes do método de Eberhart e Russell (1966). Cada variável alocada pelo processo de fuzzificação classificou cada genótipo quanto a variável em questão. A média geral foi classificada como "Baixa" e "Alta", pelas funções de pertinência forma de Z ("zmf") e forma de S ("smf"), respectivamente, delimitadas de 0 a 100, em função das distribuições normais das entradas, no valor da média geral (μ) e do desvio padrão (σ). Valores associados a $\mu - 3\sigma$ foram atribuídos o valor 0 e a os valores associados a $\mu + 3\sigma$ foram atribuídos o valor de 100 (CARNEIRO, 2015).

O outro parâmetro avaliado pelo método de Eberhart e Russell (1966) (β_1) variaram de "Menor que 1", "Igual a 1" e "Maior que 1", pelas funções de pertinência forma de Z ("zmf"), forma 75 de " π " ("pimf") e forma de S ("smf"), respectivamente. Os genótipos com pertinência superior a 50% no conjunto —Igual a 1 foram classificados como β_1 estatisticamente iguais a 1 pelo teste t de Student. Os valores de β_1 originais de cada genótipo ao serem submetidos ao controlador foram padronizadas para uma escala de -5 a 7, uma vez que o valor 1 está equidistante aos extremos desta escala. Esta padronização baseou-se no intervalo de confiança do teste t baseado na distribuição t. Ao limite inferior do intervalo de confiança foi atribuído o valor -2 e ao limite superior foi atribuído o valor 4 (CARNEIRO, 2015).

Para o controlador fuzzy baseado no sistema de inferência proposto por Sugeno (Takagi and Sugeno, 1985; Sugeno and Kang, 1988b; Sugeno and Tanaka, 1991; Sugeno and Yasukawa, 1993). Foi gerada uma variável fuzzy linguística denominada “Comportamento Sugeno” variando de 0 a 100, alocando-as em quatro conjuntos específicos denominados “*singletons*” descritas pelas funções constantes: pouco adaptado ($f(x) = 25$), desfavorável ($f(x) = 50$), favorável ($f(x) = 75$) e geral ($f(x) = 100$) (CARNEIRO, 2015).

Na Tabela 7 estão representadas as regras aplicadas nos controladores e adaptados ao método de Eberhart e Russell (1966) estimando os parâmetros (β_0 , β_1 e R^2). O coeficiente de determinação (R^2) não foi padronizado, uma vez que este parâmetro

apresenta uma escala comum a qualquer tipo de característica agrônômica (CARNEIRO, 2015).

Tabela 3. Lógica fuzzy linguísticas implementadas nos controladores Fuzzy de Sugeno quanto ao comportamento dos genótipos, para adaptabilidade e estabilidade baseado no método de Eberhart e Russell (1966). Adaptado de Carneiro (2015).

Médias	Entradas	R²	Saída
(β₀)	β₁		Comportamento Sugeno
Baixa	Menor que 1	Baixo	Pouco Adaptado
Baixa	Menor que 1	Alto	Pouco Adaptado
Baixa	Igual a 1	Baixo	Pouco Adaptado
Baixa	Igual a 1	Alto	Pouco Adaptado
Baixa	Maior que 1	Baixo	Pouco Adaptado
Baixa	Maior que 1	Alto	Pouco Adaptado
Alta	Menor que 1	Baixo	Pouco Adaptado
Alta	Menor que 1	Alto	Desfavoráveis
Alta	Igual a 1	Baixo	Pouco Adaptado
Alta	Igual a 1	Alto	Geral
Alta	Maior que 1	Baixo	Pouco Adaptado
Alta	Maior que 1	Alto	Favorável

O método do modelo *Additive Mean Effects and Multiplicative Interaction Analysis* (AMMI) combina componentes aditivos para os efeitos principais dos genótipos e ambientes e componentes multiplicativos para o efeito da interação, e através do modelo é dado a resposta do genótipo no ambiente (DUARTE; VENCOSVSKY, 1999):

$$Y_{ij} = \mu + g_i + e_j + \sum_{k=1}^n \lambda_k \gamma_{ik} \alpha_{jk} + \rho_{ij} + \varepsilon_{ij}$$

$$\text{Com (ge)}_{ij}: \sum_{k=1}^n \lambda_k \gamma_{ik} \alpha_{jk} + \rho_{ij}$$

Y_{ij} = Valor médio observado do i-ésimo genótipo no j-ésimo ambiente.

μ = Média geral dos experimentos

g_i = efeitos principais dos genótipos

e_j = efeitos principais dos ambientes

g_e = componentes multiplicativos da interação

λ_k = k-ésimo valor singular de g_e

α_{jk} = Vetores singulares associados ao λ_k

ρ_{ij} = Resíduo adicional

Os efeitos dos desvios da interação se baseiam na avaliação dos componentes principais pela análise multivariada e pela decomposição dos valores singulares. Os componentes significativos refletem os padrões das variações e os não significativos englobam os “ruídos” (FILHO, 2008).

O gráfico biplot que representará o estudo da interação utiliza o AMMI1, em que o eixo das abscissas é representado pelos efeitos principais das médias de produtividade dos genótipos nos ambientes e no eixo das ordenadas os escores do primeiro eixo de interação (HONGYU et al., 2015).

Todas as análises foram realizadas pelo *software* Genes (CRUZ, 2016). Para as análises da lógica Fuzzy e controladores fuzzy proposto por Sugeno, utilizou-se o software MATLAB (MATHWORKS, 2017) e implementados na rotina integração do software GENES (Cruz, 2016).

3***Resultados e discussão***

3. RESULTADOS E DISCUSSÃO

Foi verificada interação genótipos x ambientes (GxA), evidência a resposta diferenciada dos fenótipos e conseqüentemente dos genótipos, para a característica produtividade em relação as variações nos ambientes testados, justificando o estudo de adaptabilidade e estabilidade para conhecer as particularidades do comportamento dos genótipos nos ambientes (Tabela 8).

Tabela 4. Significância dos quadrados médios e coeficientes percentuais da variação experimental para as nove características avaliadas, em 12 genótipos de algodoeiro nas safras 2013/14, 2014/15, 2015/16 e 2016/17.

		1. Quadrados médios	
FV	GL	2.	PRODUTIVIDADE (kg ha ⁻¹)
BLOCO X AMBIENTE	6	3.	150786,68
GENÓTIPOS	11	4.	1550103,94**
AMBIENTES	3	5.	47800085,49**
GENÓTIPOS X AMBIENTES	33	6.	902470,83**
IPCA 1	13	7.	1538025,7**
IPCA 2	11	8.	646768,8*
IPCA 3	9	9.	296972,3 ^{ns}
RESÍDUOS	88	10.	294720,7
CV (%)		11.	23,63
Médias		12.	2258,84
(MQMR ₁)/MQMR ₂		13.	4,08

14. **, *Significativo a 1 e 5% de probabilidade, respectivamente pelo teste F; FV = Fontes de variação; GL = Graus de liberdade; CV= Coeficiente de variação; MQMR₁/MQMR₂= Razão do quadrado médio maior sob o quadrado médio menor.

15.

A homogeneidade do quadrado médio do resíduo (QMR) ficou abaixo de sete, atendendo a pressuposição da homogeneidade das variâncias para realizar a análise conjunta. A média de produtividade foi de 2258 kg ha⁻¹, acima do encontrado pela

Embrapa (2015) com média de 1848 kg ha⁻¹ de algodão em caroço para a cultivar BRS-Rubi.

O coeficiente de variação (CV) para produtividade foi de 23,63%. Reis et al. (2017), encontraram para produtividade CV de 46%, superior ao encontrado neste trabalho, ao analisarem correlação e análise de trilha em genótipos de algodoeiro. Segundo Santos et al. (1998), valores entre 12,20 a 28,54% são considerados valores médios e, portanto, aceitável para esta característica, por ser um caráter quantitativo muito influenciado por fatores ambientais. Na avaliação dos ambientes, a baixa produtividade no ambiente 2 (safra 2014/2015), (Tabela 9), pode ser explicado em partes, por ataques de *Alabama argilacea*, no período de formação e enchimento de maçãs, por volta de 110 dias após a emergência (ROSOLEN, 2001), que acarretou em menor área foliar, diminuição da produção de fotoassimilados e menor dreno para as maçãs (ZHAO et al., 2005; SNIDER et al., 2009; YEATES et al., 2010).

Tabela 5. Média de produtividade de algodão em caroço (kg ha⁻¹) de 12 genótipos de algodoeiros em quatro safras, na cidade de Uberlândia-MG.

Genótipos	Safra 2013/2014	Safra 2014/2015	Safra 2015/2016	Safra 2016/2017
UFUJP-01	2501,66 Ac	131,26 Ba	2157,08 Aa	2628,56 Ac
UFUJP-02	3478,12 Ab	687,08 Ca	3135,62 Aa	2069,73 Bc
UFUJP-05	1972,50 Ad	647,71 Ba	2266,04 Aa	2496,26 Ac
UFUJP-08	2681,25 Ac	409,38 Ba	2743,96 Aa	2295,79 Ac
UFUJP-09	3630,00 Ab	381,04 Ca	2342,91 Ba	2778,33 Bc
UFUJP-10	2983,33 Ac	332,76 Ba	2969,17 Aa	2231,53 Ac
UFUJP-11	2841,87 Ac	1050,62 Ba	2572,08 Aa	2350,44 Ac
UFUJP-13	1687,50 Bd	486,88 Ca	2664,79 Aa	2499,31 Ac
UFUJP-16	3229,16 Ac	616,87 Ba	2642,50 Aa	2969,48 Ac
UFUJP-17	3689,58 Ab	449,37 Ca	2529,79 Ba	3310,48 Ab
BRS-Rubi	4670,00 Aa	387,92 Ca	2300,00 Ba	4275,93 Aa
BRS-Topázio	4665,00 Aa	1303,33 Ca	2401,46 Ba	2946,81 Bc

Médias seguidas pelas mesmas letras maiúsculas na horizontal e minúsculas na vertical constituem grupo estatisticamente homogêneo pelo teste de Scott-Knott a 0,05% de

significância, Ambiente 1= Safra 2013/14, Ambiente 2= Safra 2014/15, Ambiente 3 = Safra 2015/16 e Ambiente 4= Safra 2016/17.

Outro fato relevante ao baixo desempenho do ambiente 2 foi a baixa precipitação no período da safra, com 679mm durante seu ciclo, caracterizando estresse hídrico, uma vez que a cultura exige valores de precipitação próximos a 740mm, para que complete seu ciclo de forma plena (SOBRINHO et al., 2007).

O resultado inferior no ambiente 2 também foi confirmado pelo método AMMI1, pois pela análise gráfica este ambiente apresentou maior distância dos genótipos, demonstrando não ser favorável para produtividade. Ainda é possível destacar UFUJP-11 e BRS-Topázio como cultivares que demonstram média produtiva superiores neste ambiente desfavorável, ou seja, mesmo em condições adversas do meio se caracterizam como promissores em produtividade.

O ambiente 1 (safra 2013/2014) foi o ambiente que melhor favoreceu a expressão da produtividade. Durante seu ciclo houve condições ideais de temperaturas e precipitações acumuladas acima do mínimo exigido e bem distribuídas, pois houve aumento gradativo das precipitações no início de botões florais e na fase de enchimento de maçãs, período que a cultura é mais sensível a estresse hídrico, refletindo em condições propícias para obtenção de altas produtividades (BORÉM; FREIRE, 2014).

O ambiente 4 (safra 2016/2017) foi o que menos contribuiu para a interação GxA, e obteve a segunda maior média de produtividade. Apesar da distribuição uniforme das chuvas, o acumulado no período foi de 555mm, valor 20% menor que o recomendado para a cultura que acarretou em menor produtividade. O estresse hídrico induz a planta a priorizar o crescimento das maçãs e capulhos maiores, resultando em maior abortamento de estruturas reprodutivas, além de reduzir a taxa fotossintética. Outro fator determinante para o resultado desta produtividade foi o baixo acumulo de graus dia (1622°) inferior ao mínimo necessário para o ciclo da cultura, que é de 1970° dia⁻¹ (ROSOLEM, 2011; LOKA et al., 2011; ECHER 2014).

No estudo da adaptabilidade e estabilidade pelo método de Lin e Binns (1988), as estimativas dos parâmetros são decompostos em Pi geral, Pi de ambientes favoráveis e desfavoráveis, utilizados para distinguir os genótipos frente as oscilações ambientais. De acordo com a Tabela 03, os genótipos que obtiveram as maiores médias de

produtividade (BRS-Rubi, BRS-Topázio e UFUJP-17), também foram classificados com adaptabilidade geral e previsíveis, com base no parâmetro P_i (Tabela 10).

Tabela 6. Estimativas dos parâmetros de estabilidade fenotípica geral (P_i), para ambientes favoráveis (P_i+) e para ambientes desfavoráveis (P_i-), para produtividade de algodão em caroço pelo método não paramétrico de Lin e Binns (1988), adaptado por Carneiro (1998).

Genótipos	Média	P_i geral	$P_i (+)$	$P_i (-)$
BRS-Rubi	2908.46	192031.75	116377.73	418993.84
BRS-Topázio	2829.15	288197.60	384263.46	.
UFUJP-17	2494.81	373697.72	376722.35	364623.84
UFUJP-16	2364.51	562150.19	670995.70	235613.67
UFUJP-09	2283.07	600426.24	658797.49	425312.50
UFUJP-02	2342.64	833453.73	1047977.63	189882.03
UFUJP-11	2203.76	928872.16	1227852.49	31931.17
UFUJP-10	2129.20	999267.03	1175353.94	471006.30
UFUJP-08	2032.60	1103578.64	1338245.09	399579.26
UFUJP-01	1842.88	1238007.36	1421717.17	686877.95
UFUJP-05	1845.63	1453719.13	1866651.12	214923.16
UFUJP-13	1829.41	1626806.52	2057976.93	333295.30

Para análise dos genótipos em ambientes favoráveis, os genótipos BRS-Rubi, BRS-Topázio e UFUJP-17 demonstraram serem mais responsivos as melhorias do ambiente e com alta estabilidade. Ao analisarmos o desempenho em ambientes desfavoráveis, os mais estáveis foram os genótipos UFUJP-11 e UFUJP-02, que pode evidenciar genótipos promissores quando inseridos em ambientes com condições edafoclimáticas adversas.

Pelo método AMMI, observa-se que os componentes principais CP1 e CP2 foram significativos (Tabela 11), com alta explicação do padrão das proporções das somas de quadrados da interação. Os dois primeiros componentes captaram 91% da $SQ_{G \times A}$ e 73% dos graus de liberdade da interação, com 27% para a SQ associada a ruídos. Para Gauch (1998), valores de SQ próximos a 70% aumentam a precisão e predição dos resultados.

Tabela 7. Proporção da $SQ_{G \times A}$ da interação para cada eixo principal da análise AMMI, para os quatro ambientes e 12 genótipos.

Componente Principal	Explicação (%)	Explicação Acumulada (%)
CP1**	67.1	67.1

CP2*	23.9	91.0
CP3^{ns}	9.0	100.0

*, **. Significativos pelo teste de F a 0,05 e a,01 respectivamente. ^{ns}= não significativo pelo teste F. Componente principal= Eixo principal.

Contudo como o CP1 explicou grande parte da SQ_{GXA} , e ficou próximo aos 70% de explicação, optou-se por utilizar o modelo AMMI1, para evitar que os ruídos não prejudiquem a representação do modelo. Segundo Duarte e Vencosvsky (1999) valores do primeiro componente próximos a 70% concentra alta proporção das médias diferenciadas dos genótipos frente as oscilações ambientais. Maleia et al., (2017) encontraram valores abaixo deste trabalho, com 80% da interação nos dois primeiros eixos principais, em seu estudo de adaptabilidade e estabilidade em algodoeiro baseado na análise AMMI.

Os genótipos mais estáveis e adaptados (Figura 13), estão próximo a origem das interseções dos eixos (IPCA1), significando que contribuem pouco para a interação (DUARTE; VENCOVSKY, 1999). Com base neste parâmetro os genótipos UFUJP-01, UFUJP02, UFUJP-08, UFUJP-09, UFUJP-11 UFUJP16, UFUJP-17 são os mais estáveis.

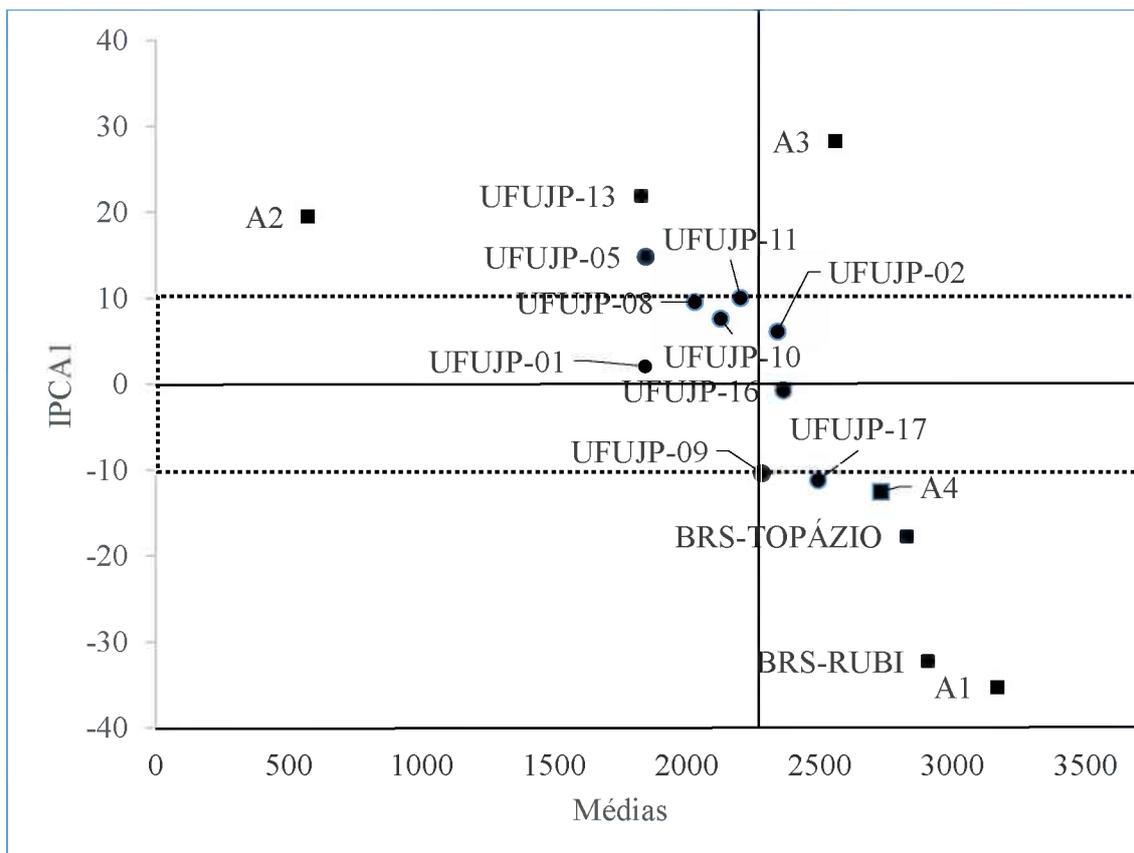


Figura 13. AMMI1 biplot dos efeitos principais da interação e produtividade de algodão em caroço (kg ha^{-1}) de 12 genótipos de algodoeiro de fibra colorida. A1=ambiente 1(safra 2013/2014, A2=ambiente 2(safra 2014/2015, A3=ambiente 3(safra 2015/2016, A4=ambiente 4(safra 2016/2017).

Contudo para fins de recomendação, genótipos mais estáveis devem expressar alta produtividade. Obtiveram desempenhos superiores UFUJP-02, UFUJP-16, UFUJP-17, dando maior confiança em sua recomendação, ou seja, alta adaptabilidade e estabilidade com melhor performance produtiva.

Em geral os genótipos mais estáveis apresentaram produtividades abaixo da média dos genótipos (UFUJP-01, UFUJP-08, UFUJP-09, UFUJP-11), evidencia que produtividades elevadas podem estar associadas a adaptações específicas favoráveis, tendo em vista que os genótipos comerciais (BRS-Rubi e BRS-Topázio) foram mais produtivos e interagiram positivamente com o ambiente 1 (safra 2013/2014), safra que proporcionou as maiores médias de produtividade, pois proporcionou condições ideais à cultura de forma geral.

Levando em conta a estabilidade no ambiente, o ambiente 4 (safra 2016/2017) apresentou melhor responsividade e previsibilidade. Esta informação possibilita obter maior confiança na recomendação dos genótipos neste ambiente, pois os valores de

produtividade serão determinados principalmente pelos efeitos genotípicos, uma vez que neste ambiente houve menor interação GxA. O ambiente 2 (safra 2014/2015) foi a mais instável e ao observar as médias de produtividade foi o ambiente que obteve as menores produtividades, decorrente de menores precipitações e estresses bióticos.

Pela abordagem que utilizou a inteligência computacional com base no controlador Fuzzy, baseado no método de Eberhart e Russell (1966) (Tabela 12), os genótipos UFUJP-02, UFUJP-09, UFUJP-16, UFUJP-17 e BRS-Topázio, apresentaram adaptabilidade ampla e alta estabilidade, com destaque aos genótipos UFUJP-16, UFUJP-17 e BRS-Topázio que também registraram produtividade superior em comparação aos demais genótipos.

Tabela 8. Entradas padronizadas e classificação quanto ao comportamento Geral, Pouco adaptado, Favorável e Desfavorável de 12 genótipos submetidas ao controlador fuzzy baseado no método de Eberhart e Russell (1966).

Genótipos	Média	β_1	R²	Saídas
UFUJP-01	1842,88	0.8634	96.6614	Pouco adaptado
UFUJP-02	2342,64	0.8762	82.0617	Adaptabilidade Ampla
UFUJP-05	1845,63	-2.5157	80.7667	Pouco adaptado
UFUJP-08	2032,60	0.2089	92.8704	Pouco adaptado
UFUJP-09	2283,07	2.7405	96.9471	Adaptabilidade Ampla
UFUJP-10	2129,20	1.3059	90.6026	Pouco adaptado
UFUJP-11	2203,76	-2.1781	96.9527	Pouco adaptado
UFUJP-13	1829,41	-2.2088	61.859	Pouco adaptado
UFUJP-16	2364,51	1.296	99.5205	Adaptabilidade Ampla
UFUJP-17	2494,81	3.3554	97.2347	Adaptabilidade Ampla
BRS-Rubi	2908,46	6.7949	85.5862	Adaptabilidade Favorável
BRS-Topázio	2829,15	1.4614	74.0192	Adaptabilidade Ampla

Por esse método também é possível aferir que os genótipos que obtiveram adaptabilidade ampla, corroboram com os resultados apresentados nos métodos AMMI e Lin e Binns, evidencia de confiabilidade dos resultados quando utilizado a lógica Fuzzy. Todavia pela inteligência computacional 50% dos genótipos foram classificados como pouco adaptados, índice 17% maior quando comparado ao método AMMI1.

Uma possível explicação para a diferença nos resultados está na metodologia Fuzzy que simula a psicologia humana, ou seja, tem a capacidade de tomar decisões

baseados em fatores pré-estabelecidos fazendo sua recomendação, pelo conceito de especialistas (BAUCHSPIESS, 2008).

É possível observar que o genótipo BRS-Rubi apresentou adaptabilidade favorável, ou seja, possui boa produtividade se o meio propiciar condições ideais para seu desenvolvimento. Este resultado coincide com os resultados do método AMMI com adaptabilidade específica ao ambiente 1 e ao método não paramétrico de Lin e Binns (1988), onde foi classificado como o mais adaptado a ambientes favoráveis.

4

Conclusões

4. CONCLUSÕES

A lógica fuzzy linguísticas implementadas nos controladores Fuzzy de Sugeno demonstrou alto potencial para recomendações de genótipos de algodoeiro, quanto a adaptabilidade e estabilidade em programas de melhoramento genético de plantas.

Os genótipos UFUJP-16 e UFUPJ-17 demonstraram serem promissores quanto a produtividade nos ambientes testados.

REFERÊNCIAS

BAUCHSPIESS, A. Introdução aos Sistemas Inteligentes. Aplicações em Engenharia de Redes Neurais Artificiais, Lógica Fuzzy e Sistemas Neuro-Fuzzy, 2004.

BEALE, M. H.; HAGAN, M.; DEMUTH, H. B. Neural network performance-MATLAB cross entropy-the MathWorks United Kingdom. Mathworks. Com, 2017.

BORÉM, A.; FREIRE, E. C. Algodão: do plantio a colheita. Minas Gerais: ed.: Viçosa-UFV, 2014.

CARNEIRO, P. C. S. Novas metodologias de análise da adaptabilidade e estabilidade de comportamento. (Tese de doutorado em agronomia). Universidade Federal de Viçosa, Viçosa 1998.

CARNEIRO, V. Q. Rede neural e lógica fuzzy aplicadas no melhoramento do feijoeiro. (Dissertação de mestrado em agronomia). Universidade Federal de Viçosa, Viçosa, 2015.

COMPANHIA NACIONAL DE ABASTECIMENTO- CONAB. Acompanhamento da safra brasileira de grãos. v. 5, n. 3 , SAFRA 2017/18, Terceiro levantamento, dezembro 2017. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_12_12_17_59_52_dezembro.pdf>. Acesso em: 01 jan. 2018

CRUZ, C. D. Programa genes: diversidade genética. Viçosa: UFV, 2006. 278 p.

CRUZ, C. D.; REGAZZI, A. J.; CARNEIRO, P. C. S. Modelos biométricos aplicados ao melhoramento genético. 3. ed. Viçosa: Editora UFV, 2014.

DOS SANTOS, J. W.; MOREIRA, J. D. A. N.; FARIAS, F. J. C.; FREIRE, E. C. Avaliação dos coeficientes de variação de algumas características da cultura do algodão: uma proposta de classificação. Revista Brasileira de Oleaginosas e Fibras, Campina Grande, PB, v. 2, n. 1, 1998.

DUARTE, J. B.; VENCOVSKY, R. Interação Genótipos x Ambientes: Uma Introdução à Análise AMMI., Sociedade Brasileira de Genética. Série Monografias. Ribeirão Preto, p. 60, 1999.

EBERHART, S. A.; RUSSELL, W. A. Stability parameters for comparing varieties. *Crop Science*, Madison, WI, v.6, p.36-40, 1966.
<https://doi.org/10.2135/cropsci1966.0011183X000600010011x>

ECHER, F. R. O algodoeiro e os estresses abióticos: temperatura, luz, água e nutrientes. Cuiabá: Embrapa Agropecuária Oeste-Outras publicações científicas (ALICE), 2014

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Relatório de avaliação dos impactos das tecnologias geradas. Embrapa Algodão, Campina Grande-PB 2015.

GAUCH, H.G. Model selection and validation for yield trials with interaction. *Biometrics*. v.44, p. 705-715, 1998.
<https://doi.org/10.2307/2531585>

HONGYU, K., GARCÍA-PEÑA, M., DE ARAÚJO, L. B., & DOS SANTOS DIAS, C. T. Statistical analysis of yield trials by AMMI analysis of genotype× environment interaction. *Biometrical letters*, 51(2), 89-102 2014.
<https://doi.org/10.2478/bile-2014-0007>

MARUR, C. J.; RUANO, O. Escala do algodão. Informe da Pesquisa IAPAR, v. 105, n. 1, p. 1-4, 2003.

SILVA FILHO, J. L.; MORELLO, C. L.; FARIAS, F. J. C.; LAMAS, F. M.; PEDROSA, M. B.; RIBEIRO, J. L. Comparação de métodos para avaliar a adaptabilidade e estabilidade produtiva em algodoeiro. *Pesquisa agropecuária Brasileira*, Brasília, v.43, n.3, p.349-355, mar. 2008
<https://doi.org/10.1590/S0100-204X2008000300009>

MALEIA, M. P.; RAIMUNDO, A.; MOIANA, L. D.; TECA, J. O.; CHALE, F.; JAMAL, E., ADAMUGY, B. A. Stability and adaptability of cotton (*Gossypium hirsutum* L.) genotypes based on AMMI analysis. *Australian Journal of Crop Science*, v.

11, n. 4, p. 367, 2017.

<https://doi.org/10.21475/ajcs.17.11.04.pne60>

NASCIMENTO, M.; PETERNELLI, L. A.; CRUZ, C. D.; NASCIMENTO, A. C. C.; FERREIRA, R. D. P.; BHERING, L. L.; SALGADO, C. C. Artificial neural networks for adaptability and stability evaluation in alfalfa genotypes. *Crop Breeding and Applied Biotechnology*, Viçosa, MG - Brasil, v. 13, n. 2, p. 152-156, 2013.

<https://doi.org/10.1590/S1984-70332013000200008>

REIS, M.C., CARDOSO D.B.O., SILVA JÚNIOR E.G., GOMES B.C., PEREIRA L.T.G., GOMES D.A. AND SOUSA L.B. Correlation among traits as criterion of cotton genotypes indirect selection. *Genetics and Molecular Research*, v.40, 2017.

<https://doi.org/10.4238/gmr16039805>

ROSOLEM, C A. Ecofisiologia e manejo da cultura do algodoeiro. *Informações Agrônomicas*, Georgia, USA, v. 95, p. 1-9, 2001.

DA SILVA QUEIROZ, J. P.; da COSTA J. M.; NEVES, L. G.; SEABRA JUNIOR, S.; APARECIDO BARELLI, M. A. Estabilidade fenotípica de alfaves em diferentes épocas e ambientes de cultivo. *Revista Ciência Agronômica*, v. 45, n. 2, 2014

<https://doi.org/10.1590/S1806-66902014000200007>

SNIDER, J. L.; OOSTERHUIS, D. M.; SKULMAN, B. W.; KAWAKAMI, E. M. Heat stress-induced limitations to reproductive success in *Gossypium hirsutum*. *Physiology Plant*, Lund Sweden, v.137, p. 125-138, 2009.

<https://doi.org/10.1111/j.1399-3054.2009.01266.x>

SOBRINHO, F.P.C et al. Crescimento e rendimento do algodoeiro BRS-200 com aplicações de cloreto de mepiquat e lâminas de irrigação. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 11, p. 284 -292, 2007.

<https://doi.org/10.1590/S1415-43662007000300007>

SUGENO, M., & KANG, G. Structure identification of fuzzy model. *Fuzzy Sets and Systems*. [http://doi.org/10.1016/0165-0114\(88\)90113-3](http://doi.org/10.1016/0165-0114(88)90113-3), 1988.

[https://doi.org/10.1016/0165-0114\(88\)90113-3](https://doi.org/10.1016/0165-0114(88)90113-3)

SUGENO, M., & KANG, G. T. Fuzzy modelling and control of multilayer incinerator. Fuzzy Sets and Systems. [http://doi.org/10.1016/0165-0114\(88\)90192-3](http://doi.org/10.1016/0165-0114(88)90192-3) 1988.
[https://doi.org/10.1016/0165-0114\(88\)90192-3](https://doi.org/10.1016/0165-0114(88)90192-3)

SUGENO, M., & TANAKA, K. Successive identification of a fuzzy model and its applications to prediction of a complex system. Fuzzy Sets and Systems. [http://doi.org/10.1016/0165-0114\(91\)90110-C](http://doi.org/10.1016/0165-0114(91)90110-C), 1991.

SUGENO, M., & YASUKAWA, T. Fuzzy-logic-based approach to qualitative modeling. IEEE Transactions on Fuzzy Systems, 1(1), 7-31.
<http://doi.org/10.1109/TFUZZ.1993.390281>, 1993
<https://doi.org/10.1109/TFUZZ.1993.390281>

YEATES, S. J.; CONSTABLE, G. A.; MCCUMSTIE, T. Irrigated cotton in the tropical dry season. In: Yield, its components and crop development. Field Crops Research, v. 116, n. 3, p. 278-289, 2010.
<https://doi.org/10.1016/j.fcr.2010.01.005>

ZHAO, D.; REDDY, K. R.; KAKANI, V. G.; KOTI, S.; GAO, W. Physiological causes of cotton fruit abscission under conditions of high temperature and enhanced ultraviolet-B radiation. Physiology Plant, Lund, Sweden, v. 124, p. 189-199, 2005.
<https://doi.org/10.1111/j.1399-3054.2005.00491.x>