

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

LUIZA AMARAL MEDEIROS

**QUALIDADE DE FIBRA DO ALGODOEIRO: INTEGRAÇÃO ENTRE  
INTELIGÊNCIA ARTIFICIAL E FENOTIPAGEM DIGITAL**

UBERLÂNDIA

2025

LUIZA AMARAL MEDEIROS

**QUALIDADE DE FIBRA DO ALGODOEIRO: INTEGRAÇÃO ENTRE  
INTELIGÊNCIA ARTIFICIAL E FENOTIPAGEM DIGITAL**

Tese apresentada ao Programa de Pós-graduação em  
Agronomia da Universidade Federal de Uberlândia,  
como exigência parcial para obtenção do título de  
Doutor em Produção Vegetal.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Larissa Barbosa de Sousa

UBERLÂNDIA

2025

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

---

M488q      Medeiros, Luiza Amaral, 1996-  
2025      Qualidade de fibra do algodoeiro [recurso eletrônico] : integração  
entre inteligência artificial e fenotipagem digital / Luiza Amaral Medeiros.  
- 2025.

Orientadora: Larissa Barbosa de Sousa.  
Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de  
Programa de Pós-graduação em Agronomia.  
Modo de acesso: Internet.  
Disponível em: <http://doi.org/10.14393/ufu.te.2025.5061>  
Inclui bibliografia.  
Inclui ilustrações.

1. Agronomia. I. Sousa, Larissa Barbosa de, 1985-, (Orient.). II.  
Universidade Federal de Uberlândia. Programa de Programa de Pós-  
graduação em Agronomia. III. Título.

---

CDU: 631

Nelson Marcos Ferreira  
Bibliotecário-Documentalista - CRB-6/3074



**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.ppgagro.iciag.ufu.br](http://www.ppgagro.iciag.ufu.br) - [posagro@ufu.br](mailto:posagro@ufu.br)



**ATA DE DEFESA - PÓS-GRADUAÇÃO**

Programa de Pós-Graduação em:	Agronomia				
Defesa de:	Tese, 006/2025, PPGAGRO				
Data:	Quinze de setembro de dois mil e vinte e cinco	Hora de início:	14:00	Hora de encerramento:	16:50
Matrícula do Discente:	12113AGR008				
Nome do Discente:	Luiza Amaral Medeiros				
Título do Trabalho:	Qualidade de fibra do algodoeiro: Integração entre inteligência artificial e fenotipagem digital				
Área de concentração:	Produção Vegetal				
Linha de pesquisa:	Melhoramento de Plantas				

Reuniu-se por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agronomia, assim composta: Professores Doutores: Douglas José Marques - UFU; Ana Carolina Silva Siquieroli - UFU; André Madeira Silveira França - Faculdade Anhanguera, Larissa Barbosa de Sousa - UFU orientadora da candidata e o Pesquisador Daniel Bonifácio Oliveira Cardoso - BASF.

Iniciando os trabalhos a presidente da mesa, Dra. Larissa Barbosa de Sousa, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu à Discente a palavra para a exposição do seu trabalho. A duração da apresentação da 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 a candidata. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando a candidata:

Aprovado(a).

Essa tese possui mérito para ser indicada como destaque do Programa? ( x ) SIM  
NÃO ( )

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 15/09/2025, às 16:48, 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 **Douglas José Marques, Professor(a) do Magistério Superior**, em 15/09/2025, às 16:49, 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 Carolina Silva Siquieroli, Professor(a) do Magistério Superior**, em 15/09/2025, às 16:49, 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 **DANIEL BONIFACIO OLIVEIRA CARDOSO, Usuário Externo**, em 15/09/2025, às 20:33, 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 **André Madeira Silveira França, Usuário Externo**, em 15/09/2025, às 21:22, 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](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **6677569** e o código CRC **F60342CA**.

## **BIOGRAFIA**

Luiza Amaral Medeiros, filha de Meire Amaral da Cruz e Divino Dantas de Medeiros nasceu no dia 02 de julho de 1996 em Uberlândia-MG.

Ingressou, em abril de 2014, no curso de Biotecnologia na Universidade Federal de Uberlândia, concluindo-o em janeiro de 2019.

Em fevereiro de 2019, iniciou o Curso de Mestrado em Agronomia (Linha de pesquisa: Melhoramento Genético de plantas) na Universidade Federal de Uberlândia, Minas Gerais, submetendo-se à defesa de dissertação em março de 2021.

Em março de 2021, iniciou o curso de Doutorado em Agronomia (Linha de pesquisa: Melhoramento Genético de plantas) na Universidade Federal de Uberlândia, Minas Gerais, submetendo-se à defesa de tese em setembro de 2025.

## AGRADECIMENTOS

Primeiramente, agradeço a Deus pela vida, pelas oportunidades e por todas as bênçãos a mim concedidas e à Nossa Senhora Desatadora dos nós, por iluminar e abençoar meu caminho.

Meu agradecimento mais sincero aos meus pais Meire e Divino, por todo o amor e apoio incondicional em meus estudos e em cada uma das minhas decisões; pelo incentivo diário para que eu persistisse e continuasse em busca de meus sonhos e planos. Ao meu marido José Alvim, por todo amor, companheirismo e motivação. Obrigada por me incentivar sempre e me acompanhar em todos os momentos. A toda minha família e amigos pelos incentivos e palavras de apoio durante toda minha trajetória.

À minha orientadora Prof<sup>a</sup>. Dr<sup>a</sup>. Larissa Barbosa de Sousa pelo incentivo, confiança e apoio em todos os aspectos possíveis. Agradeço-lhe pela amizade, pelo tempo disponibilizado e por todos os ensinamentos que foram primordiais para a execução deste trabalho e para o meu crescimento pessoal e profissional. Ao amigo Daniel Bonifácio, por todo o suporte desde o princípio. Pelo otimismo, torcida, conselhos e auxílio durante o processo. Agradeço-lhe por estar sempre disposto a ajudar e a ensinar.

À Minas Cotton e AMIPA e ao parceiro de longa data do PROMALG, Anicésio Resende, meu mais sincero agradecimento pela parceria que tornou possível a realização deste trabalho. À EMBRAPA e ao pesquisador Dr. Francisco Farias, agradeço a parceria e cordialidade em todos os momentos.

Aos colegas e amigos da Pós-Graduação pelo apoio e ensinamentos ao longo do caminho. Ao Programa de Melhoramento Genético do Algodoeiro da UFU pela oportunidade e suporte. Aos membros da banca examinadora Ana Carolina S. Siquieroli, Daniel Bonifácio O. Cardoso, Douglas José Marques e André Madeira S. França pela gentileza e disponibilidade para participar e contribuir na melhoria deste trabalho.

Ao Programa de Pós-Graduação em Agronomia e à Universidade Federal de Uberlândia pela oportunidade, suporte, infraestrutura e serviços disponibilizados. Aos professores do Programa de Pós-Graduação em Agronomia pelos ensinamentos. Aos funcionários da Fazenda Capim Branco pelo apoio necessário para a instalação e condução dos ensaios.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de estudos que possibilitou a realização desta pesquisa.

A todos vocês, o meu muito obrigada!

## LISTA DE ILUSTRAÇÕES

FIGURA 1 - Eventos fenológicos no ciclo do algodoeiro.....	7
FIGURA 2 - Representação esquemática da estrutura da fibra de algodão .....	9
FIGURA 3 - Representação esquemática do micronaire com base na maturidade e finura da fibra.....	12
FIGURA 4 - Representação esquemática de uma árvore de decisão .....	22
FIGURA 5 - Mapa dos municípios de Minas Gerais produtores de algodão empregados no presente estudo .....	34
FIGURA 6 - Correlação de Pearson para características abióticas e características tecnológicas de fibra.....	39
FIGURA 7 - Análise de componentes principais na interação cultivares no espaço fibra e cultivares no espaço climático.....	42
FIGURA 8 - Biplot genótipo x ambiente por k-means, com dispersão das 32 cultivares de algodão semeadas em município de Minas Gerais durante o período de 2020 a 2024 .....	43
FIGURA 9 - Comparação de poder preditivo baseado em coeficiente de determinação, por modelo e característica tecnológica de fibra.....	47
FIGURA 10 - Importância por permutação das variáveis climáticas mensais no modelo preditivo RF para a característica SCI.....	49
FIGURA 11 - Síntese do Shapley para a característica Índice de Fibras curtas (SFI).....	51
FIGURA 12 - Montagem Experimental: (i) aquisição e calibração da imagem, (ii) Color Threshold, (iii) remoção do fundo, (iv) cálculo dos índices e (v) análise estatística .....	65
FIGURA 13 - Variação na cor e tonalidade da fibra de diferentes genótipos de algodão. A - BRS Rubi; B - UFU-18; C - UFU-13; D - UFU-10; E - UFU-11; F - UFU-15; G - BRS Jade; H - BRS Verde; I - SG 821. Uberlândia-MG, 2024 .....	70
FIGURA 14 - Matriz de correlação para o índice de brilho (BI), saturação de inclinação espectral (SI) e diferença normalizada vermelho-verde (NGRDI) em relação às características tecnológicas da fibra.....	72
FIGURA 15 - Mapa de calor resultante da análise de cluster de 17 genótipos de algodão obtidos pelo método hierárquico do vizinho mais próximo, com a distância euclidiana utilizada como medida de dissimilaridade. Uberlândia-MG, 2024.....	73
FIGURA 16 - Análise de regressão linear para as características de uniformidade de comprimento (UI) (A), resistência da fibra (STR) (B) e comprimento da fibra (UHML) (C) dos genótipos de algodão com fibras marrons naturalmente coloridas em função do índice de brilho (BI) obtido de imagens RGB.....	74



## LISTA DE TABELAS

TABELA 1 - Cultivares analisadas e número de dados por cultivar de algodão utilizado no presente estudo .....	35
TABELA 2 - Definição e interpretação das características tecnológicas da fibra de algodão segundo classificação proposta pela EMBRAPA (Fonseca; Santana, 2002) .....	36
TABELA 3 - Agrupamento de cultivares de algodão por K-means com base em atributos de fibra e clima de cultivo em Minas Gerais.....	45
TABELA 4 - Análise de variância conjunta de genótipos de algodão de fibra colorida e branca em relação ao uso de fotos via color card, de acordo com os índices avaliados nos terços superior, médio e inferior do desenvolvimento da planta. Uberlândia-MG.....	67
TABELA 5 - Análise de variância de genótipos de algodão de fibra colorida e branca em relação aos índices avaliados nos terços superior, médio e inferior do desenvolvimento da planta.....	68
TABELA 6 - Médias do índice de brilho (BI), índice de saturação de inclinação espectral (SI) e índice de diferença normalizada vermelho-verde (NGRDI) de diferentes genótipos de algodão naturalmente colorido e branco .....	69
TABELA 7 - Médias do índice de brilho (BI), índice de saturação de inclinação espectral (SI) e índice de diferença normalizada vermelho-verde (NGRDI) de acordo com a calibração de imagem via Colorcard .....	71

## SUMÁRIO

<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>2</b>
1.1. Algodão: cultura, importância socioeconômica e história .....	1
1.2. Aspectos agronômicos e morfologia .....	4
1.3. A fibra do algodão e suas características tecnológicas .....	8
1.4. Fatores agrometeorológicos e qualidade da fibra.....	13
1.5. Domesticação e melhoramento genético.....	15
1.6. Inteligência computacional no melhoramento genético.....	18
1.7. Algoritmos de árvores de decisão .....	21
1.8. Fenotipagem digital.....	23
REFERÊNCIAS .....	24
<b>Capítulo 1 .....</b>	<b>29</b>
RESUMO .....	30
ABSTRACT .....	31
1. INTRODUÇÃO.....	32
2. MATERIAL E MÉTODOS.....	34
2.1. Ensaio - Municípios e Cultivares.....	34
2.2. Características avaliadas .....	36
2.3. Análise estatística.....	37
3. RESULTADOS E DISCUSSÃO .....	39
4. CONCLUSÕES .....	53
REFERÊNCIAS .....	54
<b>Capítulo 2 .....</b>	<b>58</b>
RESUMO .....	59
ABSTRACT .....	60
1. INTRODUÇÃO.....	61
1.1. Material vegetal e ensaios a campo.....	63
1.2. Aquisição de imagens e análise.....	63
1.3. Avaliação das características tecnológicas da fibra .....	65
1.4. Análise estatística.....	66
2. RESULTADOS E DISCUSSÃO .....	67
3. CONCLUSÃO.....	76
REFERÊNCIAS .....	77

## RESUMO

O melhoramento genético do algodão (*Gossypium hirsutum* L.) é fundamental para aprimorar a qualidade e a produtividade da principal fibra têxtil do mundo, especialmente diante de desafios como as mudanças climáticas e o aumento da demanda. A integração de tecnologias avançadas, como a inteligência artificial (IA) e a fenotipagem digital, está revolucionando esse processo. Este trabalho teve como objetivo principal demonstrar o potencial de duas abordagens inovadoras para a caracterização da qualidade da fibra de algodão. Primeiramente, explorou-se o uso de modelos de *machine learning* para prever características da fibra a partir de variáveis climáticas. O modelo Random Forest demonstrou maior acurácia, com a precipitação e a temperatura mínima em meses específicos sendo as variáveis mais influentes. Concluiu-se que, apesar do potencial, a inclusão de dados de manejo pode aumentar significativamente a acurácia dos modelos, tornando-os mais robustos. Em seguida, avaliou-se a fenotipagem digital baseada em imagens para quantificar a intensidade da coloração da fibra. A análise de imagens permitiu a distinção de genótipos pela saturação da cor. Verificou-se que o terço superior da planta produziu fibras com menor intensidade de coloração. Além disso, índices derivados da análise de imagens, como o BI (índice de brilho) mostraram correlação positiva com importantes características da fibra, como uniformidade, resistência e comprimento. Em suma, a pesquisa destaca o valor da integração de métodos preditivos e ferramentas de fenotipagem digital para acelerar o melhoramento genético do algodão, fornecendo informações precisas e eficientes para a tomada de decisões.

**PALAVRAS-CHAVE:** *Gossypium hirsutum* L; fenotipagem digital; *machine learning*; melhoramento genético.

## ABSTRACT

The genetic breeding of cotton (*Gossypium hirsutum* L.) is fundamental for improving the quality and productivity of the world's leading textile fiber, especially in the face of challenges like climate change and increasing demand. The integration of advanced technologies, such as artificial intelligence (AI) and digital phenotyping, is revolutionizing this process by optimizing the selection of desirable traits. This study aimed to demonstrate the potential of two innovative approaches for characterizing cotton fiber quality. First, we explored the use of machine learning models to predict fiber characteristics (such as micronaire, strength, and uniformity) from climatic variables. The Random Forest model showed higher accuracy, with precipitation and minimum temperature in specific months being the most influential variables. We concluded that, despite their potential, including management data could significantly increase the accuracy of the models, making them more robust. Next, we evaluated digital phenotyping based on images to quantify the intensity of fiber coloration. Image analysis allowed for the distinction of genotypes by color saturation. We found that the upper third of the plant produced fibers with lower color intensity. Furthermore, indices derived from image analysis (such as the BI index) showed a positive correlation with important fiber characteristics like uniformity, strength, and length. In summary, this research highlights the value of integrating predictive methods and digital phenotyping tools to accelerate cotton genetic breeding, providing precise and efficient information for decision-making.

**Key-words:** *Gossypium hirsutum* L.; digital phenotyping; machine learning; genetic breeding.

## REVISÃO BIBLIOGRÁFICA

### 1.1. Algodão: cultura, importância socioeconômica e história

O algodão é a principal fibra natural cultivada globalmente. Apesar de sua vasta importância econômica, a cotonicultura enfrenta intensa competição com outras fontes de fibras sintéticas. Essa concorrência impulsiona produtores, indústrias e pesquisadores a buscarem alternativas competitivas para atenuar o impacto econômico significativo no mercado de fibras naturais (ABRAPA, 2025).

Consequentemente, a implementação de cultivares e técnicas de manejo avançadas têm resultado em melhorias na produtividade e qualidade da fibra. Atualmente, o Brasil é um importante produtor de fibra de algodão, capaz de suprir a demanda interna e exportar o excedente (Barros *et al.*, 2020). O cultivo do algodão é realizado em praticamente todos os continentes do globo, somando mais de 60 países. Destes, China, Índia, Estados Unidos, Brasil e Paquistão destacam-se como os maiores produtores, detendo cerca de 87% da produção mundial (ABRAPA, 2025).

Além de ser a principal fonte de fibra natural, o algodão é uma cultura versátil, da qual todas as partes podem ser aproveitadas individualmente para subprodutos. Fornece matéria-prima para a indústria têxtil, óleo de semente para a produção de biodiesel e para a indústria alimentícia e de cosméticos, além de resíduos ricos em proteínas e óleo para alimentação animal. O algodão é um produto de extrema importância socioeconômica para o Brasil, considerando que toda a sua cadeia produtiva é uma importante geradora de fonte de renda e empregos (Ahmad; Hasanuzzaman, 2020; ABRAPA, 2025).

Além disso, a fibra de algodão é singular na sua capacidade de gerar uma variedade de produtos que sustentam e melhoram a qualidade de vida, tornando-a mais confortável e esteticamente agradável. Embora seja uma das culturas mais antigas, muitos aspectos de sua produção e processamento ainda são objeto de pesquisa. O ciclo da cultura é marcado pela intensa necessidade de aplicações de defensivos agrícolas para controle de pragas, com foco no controle do *Anthonomus grandis*, também conhecido como bicudo-do-algodoeiro. Estima-se que o cultivo de algodão seja responsável por 25% do uso global de inseticidas e 10% do uso de pesticidas (Ahmad; Hasanuzzaman, 2020).

Dessa forma, nas últimas décadas, inúmeras pesquisas têm sido conduzidas para desenvolver abordagens de manejo integrado de pragas e desenvolvimento de tecnologias

transgênicas para o manejo por meio da resistência genética das principais pragas e doenças da cultura.

Além disso, no contexto das mudanças climáticas, o algodão enfrenta vários estresses abióticos, como salinidade, seca, metais tóxicos e poluentes ambientais. Cientistas estão empenhados em desenvolver cultivares tolerantes a estes estresses, utilizando abordagens agronômicas, genéticas e moleculares (Ahmad; Hasanuzzaman, 2020).

Segundo o Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2025), os efeitos das alterações climáticas já se manifestam de forma perceptível tanto em sistemas naturais quanto em sistemas humanos, indicando que a sociedade deverá lidar com cenários climáticos modificados nas próximas décadas. Diante desse panorama, e considerando a relevância econômica e social da produção de fibras, torna-se fundamental investigar os impactos das variações climáticas sobre a produtividade e a qualidade da fibra de algodoeiro. Tal análise visa compreender as possíveis implicações socioeconômicas nas principais regiões produtoras.

Apesar dos desafios enfrentados historicamente na cultura, sua produção mundial é marcada anualmente pelo crescimento. As mais recentes projeções do Departamento de Agricultura dos Estados Unidos (USDA) para o algodão em 2024/25 preveem estoques finais globais de 78,4 milhões de fardos, um aumento de 6% em relação a 2023/24 e o nível mais alto desde 2019/20. Todos os cinco principais países produtores de algodão devem aumentar seus estoques em 2024/25, liderados principalmente pelos Estados Unidos e Brasil. A produção global deve aumentar em 6,6%, alcançando 120,5 milhões de fardos, o nível mais alto desde 2017/18. Prevê-se que o crescimento da produção mundial supere a estimativa de uso industrial (USDA, 2025).

Conforme estimativas apresentadas no quinto relatório 2024/25, elaborado pela Companhia Nacional de Abastecimento (CONAB, 2025), prevê-se uma diminuição de 3% na produtividade na safra brasileira de 2024/25, atribuída a condições climáticas menos propícias e ao atraso na plantação no Mato Grosso, consequência da colheita tardia da soja em determinadas áreas. Apesar disso, projeta-se um aumento de 1,6% na safra em comparação com a anterior, devendo alcançar cerca de 3,76 milhões de toneladas. Este crescimento será possível graças à expansão das áreas dedicadas ao cultivo, especialmente em regiões de alta produtividade.

Além de registrar a maior safra da história, as exportações brasileiras de algodão em 2024 atingiram níveis sem precedentes, totalizando 2,77 milhões de toneladas. Este feito elevou o

Brasil à posição de maior exportador mundial de algodão em pluma, superando os Estados Unidos. Tal sucesso deve-se à excelente qualidade e competitividade de preço da fibra produzida no país, tornando-a altamente atrativa no mercado internacional. Espera-se que o Brasil mantenha sua liderança no comércio global em 2025, com um aumento projetado de 2,73% no volume exportado, atingindo 2,93 milhões de toneladas (CONAB, 2025).

Analisando o panorama histórico da produção global, é evidente que o cultivo de algodão se destaca por sua notável volatilidade no âmbito das *commodities* agrícolas. A produção algodoeira é significativamente afetada por uma série de variáveis, sendo a flutuação dos estoques mundiais de fibra o fator preponderante. Essas oscilações nos estoques têm o poder de impulsionar ou retrain a demanda global, conforme seus níveis atuais (Klein; Luna, 2023).

A indústria algodoeira no Brasil é particularmente sensível a essas flutuações, dado que a maior parte de sua produção é direcionada ao mercado externo. Este cenário torna o setor altamente responsivo às dinâmicas do mercado internacional, com as variações nos estoques globais exercendo uma influência direta sobre as decisões de plantio e as estratégias de comercialização dos produtores brasileiros (Alves *et al.*, 2014).

Essa interconexão entre os estoques mundiais e a produção nacional ressalta a natureza global do mercado de algodão e a posição estratégica do Brasil como um dos principais atores neste cenário (Klein; Luna, 2023). A capacidade de adaptação rápida às mudanças nas condições de mercado tornou-se, portanto, uma competência crucial para os cotonicultores brasileiros, que precisam equilibrar as oportunidades de exportação com as demandas do mercado interno e as flutuações nos preços internacionais.

A trajetória da cotonicultura no Brasil remonta à década de 1930, quando o governo implementou políticas de incentivo em resposta à crise cafeeira. Inicialmente, o cultivo do algodão concentrou-se principalmente nos estados do Paraná e São Paulo, onde se estabeleceu e ganhou força ao longo das décadas subsequentes. Esta fase de expansão e consolidação da produção algodoeira brasileira perdurou por várias décadas, contribuindo significativamente para a economia agrícola do país. O algodão tornou-se uma importante alternativa econômica, especialmente nas regiões onde a cafeicultura enfrentava dificuldades (Alves *et al.*, 2014).

Contudo, o setor enfrentou um revés significativo na década de 1980 com o surgimento de um desafio fitossanitário de grande magnitude: a infestação do bicudo-do-algodoeiro. Esta praga, originária da América Central, causou danos extensivos às plantações, representando uma ameaça sem precedentes para os produtores. A chegada do bicudo-do-algodoeiro, combinada com outros fatores como as flutuações no mercado internacional, mudanças nas

políticas agrícolas e desafios econômicos internos, desencadeou uma crise profunda no setor. O impacto foi tão severo que resultou em uma desestabilização generalizada da cotonicultura nacional (Miranda; Rodrigues, 2015).

A revitalização da indústria algodoeira brasileira ocorreu somente em meados dos anos 1990, após uma profunda reestruturação da cadeia produtiva e uma redefinição estratégica do setor. Este período marcou o início de uma nova era para a cotonicultura nacional, caracterizada por um crescimento sustentado e inovações significativas. O renascimento do setor foi impulsionado pela adoção de um modelo de produção mais avançado, baseado em latifúndios altamente mecanizados. Este novo paradigma produtivo foi acompanhado pelo surgimento de instituições de apoio cruciais, incluindo fundações de pesquisa, associações de produtores e programas governamentais direcionados ao desenvolvimento do setor (Alves *et al.*, 2014).

Paralelamente a estas transformações estruturais, observou-se uma notável migração geográfica da produção algodoeira. O epicentro da cotonicultura deslocou-se para a região Centro-Oeste e Sudeste do Brasil, uma área que oferecia condições edafoclimáticas favoráveis e vastas extensões de terra adequadas para o cultivo em larga escala. O Centro-Oeste emergiu como o novo polo da cotonicultura brasileira, onde o setor se consolidou e continua a prosperar até os dias atuais. Desde então, a região tem sido palco de avanços contínuos em termos de produtividade e qualidade da fibra. A implementação de técnicas agrícolas de ponta, aliada a investimentos em pesquisa e desenvolvimento, resultou em incrementos progressivos nos índices de produção e na qualidade do algodão brasileiro (Klein; Luna, 2023; CONAB, 2025).

Este novo modelo de cotonicultura, caracterizado pela alta tecnificação, escala de produção e integração da cadeia produtiva, não apenas revitalizou o setor, mas também posicionou o Brasil como um *player* global significativo no mercado internacional de algodão. A transformação bem-sucedida da indústria algodoeira brasileira serve como um exemplo notável de como a inovação, a reestruturação estratégica e o apoio institucional podem revitalizar um setor agrícola em crise.

## **1.2. Aspectos agronômicos e morfologia**

O gênero *Gossypium*, que compreende a cultura do algodoeiro, abrange aproximadamente 50 espécies distribuídas em áreas tropicais e subtropicais de todos os continentes. A espécie consiste em uma angiosperma da classe das dicotiledôneas, pertencente à ordem Malvales, família Malvaceae, tribo *Gossypieae*. De todas as espécies descritas pertencentes a esse gênero,



apenas quatro são cultivadas comercialmente, sendo *Gossypium hirsutum* a responsável majoritariamente pela produção mundial de fibras (Barros *et al.*, 2020).

O algodoeiro se destaca entre as culturas agrícolas por sua estrutura excepcionalmente complexa. Apresenta natureza de cultura semi-perene, com porte arbustivo e crescimento indeterminado. Seu ciclo total varia, em média, de 160 a 180 dias para as condições ambientais brasileiras. Essas características, aliadas a uma alta sensibilidade às variações ambientais, torna seu manejo um desafio particular para os agricultores (Borém; Freire, 2014).

A natureza indeterminada do algodoeiro significa que suas fases de desenvolvimento podem ocorrer simultaneamente na planta, com crescimento vegetativo continuando mesmo após o início da fase reprodutiva. Esta característica, embora vantajosa em termos de adaptabilidade, também torna a cultura particularmente sensível a estresses ambientais em diferentes estágios de desenvolvimento (Rehman; Farooq, 2019).

A compreensão detalhada destas fases de desenvolvimento é fundamental para o manejo eficiente da cultura, permitindo intervenções precisas em termos de irrigação, nutrição, controle de pragas e doenças, além de determinação do momento ideal para a colheita. Além disso, esta complexidade estrutural e fisiológica do algodoeiro oferece oportunidades significativas para melhoramento genético, visando maior produtividade, qualidade de fibra e resistência a estresses bióticos e abióticos (Rehman; Farooq, 2019).

A morfologia do algodoeiro apresenta características distintivas que contribuem para sua adaptabilidade e mecanismos de defesa. O caule do algodoeiro é ascendente, apresentando uma arquitetura que favorece a captação de luz solar. A planta desenvolve dois tipos principais de ramos vegetativos responsáveis pelo crescimento e expansão da planta, além de ramos frutíferos onde se desenvolvem as estruturas reprodutivas (botões florais, flores e maçãs). Além disso, a espécie apresenta uma particularidade, que consiste na presença de glândulas produtoras de gossipol, distribuídas em quase sua totalidade (Borém; Freire, 2014).

O gossipol é um composto polifenólico complexo, sintetizado naturalmente pela planta como parte de seu sistema de defesa. Confere defesa contra pragas devido à toxicidade para diversos insetos herbívoros e também proteção contra patógenos, por possuir propriedades antimicrobianas. No entanto, a presença do gossipol também reflete um desafio nutricional para cultura por apresentar toxicidade para animais não-ruminantes, o que limita o uso de subprodutos do algodão na alimentação de certas espécies (Gadelha *et al.*, 2014).

O desenvolvimento de cultivares com baixo teor de gossipol nas sementes, mantendo níveis normais nas partes vegetativas, tem sido um objetivo importante no melhoramento

genético do algodoeiro. Isso visa ampliar o uso dos subprodutos na alimentação animal, mantendo os benefícios defensivos da substância para a planta.

Quanto ao sistema radicular, o algodoeiro desenvolve uma raiz pivotante robusta, que pode atingir profundidades de até 2,5 metros em condições favoráveis, permitindo a exploração de camadas mais profundas do solo em busca de água e nutrientes, além de proporcionar estabilidade à planta, especialmente importante em regiões sujeitas a ventos fortes. A altura das plantas pode variar dependendo da espécie e das condições de cultivo. O *G. hirsutum*, tipicamente de fibra branca, é a espécie mais explorada comercialmente e apresenta altura entre 0,6 m e 1,5 m, enquanto a *G. barbadense*, caracterizada por suas fibras longas e brilhantes, pode atingir alturas de até 2,7 m (Borém; Freire, 2014).

O sistema reprodutivo do algodoeiro é classificado como intermediário, entre autogamia e alogamia. Na ausência de agentes polinizadores, as plantas realizam autofecundação eficientemente, garantindo a reprodução mesmo em condições de isolamento. Contudo, na presença de polinizadores ou sob certas condições ambientais, podem ser observadas elevadas taxas de polinização cruzada, frequentemente superando 80% (Aquino *et al.*, 2014). Fatores como a abundância de insetos polinizadores, condições climáticas, morfologia floral e sincronização da floração influenciam significativamente essa taxa.

Esta característica reprodutiva tem implicações importantes para a ecologia da espécie, o manejo agrícola e, principalmente, para o melhoramento genético e produção de sementes. O sistema reprodutivo intermediário promove a diversidade genética em populações naturais, mas requer cuidados especiais no isolamento de campos de produção de sementes para manter a pureza varietal (Aquino *et al.*, 2014).

Apesar das diferenças genéticas entre os grupos de maturação e das variações nas condições ambientais dos locais de cultivo, o algodoeiro geralmente inicia o florescimento por volta dos 50 dias após a emergência, estendendo-se até cerca de 120 dias ou mais. O período de maior intensidade floral ocorre, em média, entre 70 e 80 dias. O pegamento das flores tende a ser mais eficiente nos primeiros 30 a 40 dias do florescimento, sendo favorecido pelo bom estado fisiológico das plantas e por condições ambientais adequadas (Chiavegato *et al.*, 2009).

Ao longo de grande parte do ciclo, o algodoeiro apresenta sobreposição de fases fenológicas, caracterizada pela ocorrência simultânea de crescimento vegetativo, formação de gemas reprodutivas, florescimento, desenvolvimento e maturação dos frutos (Figura 1) (Rosolem, 2001).




FIGURA 1 - Eventos fenológicos no ciclo do algodoeiro

Fonte: adaptado de Rosolem (2001).

O surgimento dos botões florais obedece a um padrão em espiral, com intervalo de emissão variável de acordo com a cultivar e as condições de cultivo. Após a ocasião da fertilização, as flores dão origem ao fruto denominado maçã, o qual, quando aberto, origina o capulho, estrutura que expõe as fibras do algodão maduras e possui, em média, de 30 a 40 sementes (Borém; Freire, 2014).

Cada estágio do desenvolvimento das plantas apresenta exigências climáticas específicas; desvios em relação a essas condições ideais podem comprometer tanto a produtividade quanto a qualidade das fibras obtidas. Nesse sentido, pesquisas que busquem orientar práticas de manejo agrícola com base nas condições climáticas são essenciais para a melhoria da eficiência produtiva. Ademais, a compreensão da hierarquização das variáveis climáticas e de manejo, conforme sua influência sobre os atributos tecnológicos da fibra, pode contribuir significativamente para a otimização do planejamento agrícola e para o aperfeiçoamento das estimativas de produtividade e qualidade (Soares, 2015).

As sementes do algodão são notáveis por seu alto valor nutricional, contendo entre 30-35% de óleo e 40-45% de proteína. A sua superfície é coberta por dois tipos distintos de células especializadas que se desenvolvem em fibras. O primeiro tipo origina as fibras longas e fiáveis, que são o principal produto comercial do algodão, amplamente utilizadas na indústria têxtil e determinantes do valor econômico da cultura. O segundo tipo forma uma camada de fibras curtas, fortemente aderidas às sementes, conhecida como línter (Borém; Freire, 2014).

A composição do algodão em caroço é de aproximadamente 40% fibra e 60% caroço. As fibras são destinadas principalmente à indústria têxtil, enquanto o caroço tem aplicações

diversificadas. Este subproduto é utilizado em várias indústrias, incluindo a alimentícia, farmacêutica, de celulose e de ração animal. Esta versatilidade do caroço de algodão aumenta significativamente o valor agregado da cultura, permitindo o aproveitamento integral da produção (Rehman; Farooq, 2019).

### **1.3. A fibra do algodão e suas características tecnológicas**

As células responsáveis pela formação das fibras, embora presentes no óvulo, iniciam seu crescimento imediatamente antes da antese. Inicialmente, forma-se a fibra propriamente dita, seguida pelo desenvolvimento do línter a partir do quinto dia após a antese. Em média, cada semente de algodão apresenta cerca de 10 mil fibras e de 5 a 10 mil fibras de línter (Rosolem, 2001).

No início do desenvolvimento das maçãs, ocorre a elongação das fibras, formadas a partir de células individuais localizadas na epiderme das sementes. Posteriormente, inicia-se a fase de espessamento, caracterizada pela deposição diária de microfibrilas de celulose na parede secundária dessas células. Essa deposição ocorre de forma sequencial e no interior do crescimento do dia anterior, formando zonas concêntricas, com o lúmen em seu interior. Essa disposição estrutural resulta na orientação das microfibrilas em diferentes ângulos, o que confere resistência à fibra, propriedade determinante para sua capacidade de torção durante a fiação (Chiavegato *et al.*, 2009) (Figura 2).




FIGURA 2 - Representação esquemática da estrutura da fibra de algodão

Fonte: adaptada de Parry (1981).

As fibras de algodão são estruturalmente diferenciadas, formadas por zonas concêntricas e um miolo central denominado lúmen. Elas possuem uma membrana plasmática e duas paredes. A parede primária é mais externa e coberta pela cutícula, composta por ceras e graxas, e a secundária é composta por três camadas, sendo a camada média a mais grossa e essencialmente composta por celulose (Parry, 1981).

Durante a fase de alongação, é definido o comprimento da fibra, e na fase de deposição de celulose, o seu diâmetro. A quantidade de celulose depositada irá determinar características como maturidade, resistência e micronaire, as quais definem a qualidade da fibra e são fortemente influenciadas pelas condições ambientais durante o ciclo da cultura e, consequentemente, pela interação genótipo x ambiente (Chiavegato *et al.*, 2009).

As fibras maduras do algodão são estruturas complexas, compostas por até 25 camadas de celulose, um polissacarídeo que constitui aproximadamente 95% de sua composição total. Esta alta concentração de celulose confere às fibras suas características únicas de resistência e flexibilidade. Um componente menor, mas crucial, são os chamados mordentes da fibra, que representam 1,3% da constituição da fibra. Estas proteínas têm um papel fundamental na indústria têxtil, pois são responsáveis por receber e fixar os corantes durante o processo de tingimento dos tecidos (Delhom; Kelly; Martin, 2018).

A qualidade da fibra do algodoeiro é determinada por diversos fatores, entre os quais se destacam aspectos genéticos da cultivar, condições edafoclimáticas, época de semeadura,

manejo fitossanitário, nutrição das plantas, tipo de equipamento utilizado na colheita, bem como os processos de beneficiamento e armazenamento. Dessa forma, embora cada cultivar apresente um padrão de qualidade de fibra geneticamente definido, esse potencial pode ser influenciado pelas condições ambientais e pelas práticas de manejo adotadas ao longo do ciclo da cultura (Freire, 2015).

A definição do valor de comercialização da fibra do algodão é realizada com base na classificação das características intrínsecas e extrínsecas da fibra, conforme procedimentos padronizados e desenvolvidos pelo Departamento de Agricultura dos Estados Unidos da América do Norte - USDA (Resende *et al.*, 2014). Anteriormente realizada de forma manual, a classificação das fibras do algodoeiro passa hoje por um processo de automação, permitindo uma maior rapidez e precisão na obtenção de dados, a partir de uma pequena quantidade de amostras.

A avaliação precisa das características tecnológicas da fibra de algodão é realizada através de um processo de classificação intrínseca, utilizando um instrumento especializado chamado *High Volume Instrument* (HVI). Atualmente, os principais países produtores e importadores de fibra adotam o padrão universal estabelecido pelo USDA para a classificação da fibra de algodoeiro. Esses padrões são revisados e atualizados anualmente, e os equipamentos do tipo HVI são calibrados em conformidade com as modificações estabelecidas (Sestren; Lima, 2015).

Este equipamento avançado fornece uma análise detalhada de várias propriedades cruciais da fibra, incluindo: comprimento da fibra, uniformidade do comprimento, alongamento, maturidade, resistência das fibras, índice de fibras curtas e micronaire. Cada uma dessas características tem um impacto direto na qualidade geral da fibra, influenciando significativamente a eficiência do processamento têxtil e, conseqüentemente, o valor comercial do produto final (Lana; Ribas; Chanselme, 2014).

O comprimento da fibra é uma das medidas mais importantes, representando o comprimento médio dos 50% das fibras mais longas na amostra, ou comprimento médio da metade superior (*Upper Half Mean Length* – UHML). Fibras mais longas geralmente resultam em fios mais resistentes e uniformes, influenciando diretamente sua qualidade e a do tecido final. Esta medida é tipicamente expressa em milímetros ou polegadas e tem um impacto significativo no processo de fiação e nas propriedades do tecido acabado (Fonseca; Santana, 2002).

A uniformidade do comprimento (UNF), expressa como uma porcentagem, indica a variação do comprimento das fibras em uma amostra. Uma maior uniformidade resulta em fios

mais consistentes e homogêneos, afetando diretamente a eficiência do processo de fiação. Amostras com alta uniformidade acarretam menor desperdício durante o processamento e contribuem para a produção de tecidos de qualidade superior (Fonseca; Santana, 2002).

O alongamento ou alongação à rotura da fibra (ELG) é uma característica associada a resistência e mede o quanto um feixe de fibras cede no sentido longitudinal até o momento da rotura, sendo expresso como uma porcentagem do comprimento original. Esta característica é crucial para determinar a resistência e elasticidade dos tecidos, afetando seu comportamento durante o uso e lavagem. Fibras com bom alongamento contribuem para a durabilidade e conforto dos produtos têxteis finais (Fonseca; Santana, 2002).

A maturidade da fibra indica o grau de desenvolvimento da parede celular. Fibras com parede secundária espessa e lúmen reduzido são classificadas como maduras, e fibras que não apresentam esse espessamento são imaturas. Fibras mais maduras tendem a ser mais resistentes e absorvem melhor os corantes, influenciando significativamente a qualidade do tingimento e o desempenho geral do tecido. A maturidade é frequentemente medida indiretamente através do micronaire, uma característica que combina informações sobre finura e maturidade (Fonseca; Santana, 2002).

O índice de micronaire, uma medida adimensional, resulta da combinação entre a finura e maturidade da fibra e influencia a capacidade de fiação, o toque do tecido e a absorção de corantes. A sua determinação é feita por meio de um teste no qual a amostra de fibras é submetida a um fluxo de ar, à pressão constante, em câmara de volume definido. O aparelho determina a vazão do ar que passou pela amostra de fibras, que está em função do diâmetro externo e da espessura da parede secundária das fibras, formada pelas camadas de celulose que estão diretamente relacionadas à maturidade da fibra (Lima, 2018) (Figura 3).




FIGURA 3 - Representação esquemática do micronaire com base na maturidade e finura da fibra  
Fonte: adaptado de Moraes (2020).

Legenda: azul refere-se à espessura da parede celular da fibra de algodão, branco ao lúmen.

Valores de micronaire muito baixos ou muito altos podem indicar fibras imaturas ou excessivamente grossas, respectivamente. Esta característica afeta o rendimento da fiação e a qualidade do produto final, sendo um fator crucial na determinação do valor e da aplicabilidade do algodão (Fonseca; Santana, 2002).

A resistência das fibras é medida pela força necessária para romper um feixe de fibras, geralmente expressa em gramas por tex ( $\text{g tex}^{-1}$ ). Esta característica é crucial para a durabilidade do fio e do tecido final, afetando diretamente o desempenho durante o processamento têxtil e a vida útil do produto acabado (Fonseca; Santana, 2002).

O índice de fibras curtas representa a porcentagem de fibras com comprimento inferior a 12,7 mm (1/2 polegada). Um alto índice pode resultar em fios mais fracos e com mais imperfeições, afetando negativamente a eficiência da fiação e a qualidade do fio. Este índice é importante para determinar o melhor uso para um lote específico de algodão e pode influenciar significativamente seu valor comercial (Fonseca; Santana, 2002).

A análise HVI permite uma avaliação objetiva e padronizada dessas propriedades, fornecendo dados quantitativos que são essenciais para determinar a qualidade e o valor comercial do algodão, estabelecer padrões de qualidade na indústria têxtil, otimizar os processos de fiação e tecelagem e prever o desempenho do tecido final. Além disso, a possibilidade de obtenção desses dados é imprescindível para guiar as decisões no melhoramento genético do algodoeiro, visando ao desenvolvimento de cultivares de algodão



com características específicas da fibra que atendam às demandas do mercado e às necessidades da indústria têxtil moderna (Kelly; Hequet; Dever, 2012).

O uso generalizado da tecnologia HVI na indústria algodoeira tem contribuído para a padronização global da classificação do algodão, facilitando o comércio internacional e permitindo uma melhor correspondência entre as características da fibra e as necessidades específicas dos diferentes processos têxteis. Esta abordagem tecnológica para a avaliação da qualidade da fibra é fundamental para manter a competitividade e a inovação na cadeia produtiva do algodão (Nawaz; Sattar; Malik, 2019).

#### **1.4. Fatores agrometeorológicos e qualidade da fibra**

Durante o desenvolvimento das fibras, os fatores ambientais podem influenciar de forma intrínseca todas as suas propriedades, em função de variáveis como condições climáticas, época de semeadura, características do solo, práticas de manejo, incidência de estresses bióticos, abióticos, entre outros. Assim, torna-se essencial compreender o efeito desses fatores sobre os atributos tecnológicos da fibra, os quais são determinantes tanto para a definição de seu valor comercial quanto para a qualidade das matérias-primas obtidas (Echer; Rosolem; Raphael, 2018).

A necessidade hídrica de uma cultura varia de acordo com o estágio fenológico ao longo do ciclo. No algodoeiro, as fases vegetativas iniciais, pós-emergência, são marcadas por uma demanda hídrica menor. Com o desenvolvimento das plantas rumo à fase reprodutiva, há um crescimento expressivo da área foliar e, conseqüentemente, a demanda hídrica aumenta (Chiavegato *et al.*, 2009). A planta de algodão necessita de aproximadamente 650 a 800 mm de água bem distribuídos durante o seu ciclo de desenvolvimento, a depender das condições meteorológicas locais.

O estresse hídrico caracteriza-se pela discrepância entre a disponibilidade e a demanda de água em determinada fase fenológica do ciclo de uma cultura. Considerando que a fibra de algodão é uma célula que depende diretamente da água para sua expansão e crescimento, condições de restrição hídrica podem acarretar diretamente na redução do comprimento da fibra (Allen; Aleman, 2011).

Além disso, a falta de água estimula a síntese de ácido abscísico, fitohormônio responsável pelo controle da abertura e fechamento dos estômatos, o que reduz o potencial hídrico foliar. Esse fenômeno afeta negativamente a interceptação de luz, a assimilação de carbono e, por

consequência, a disponibilidade de carboidratos para o desenvolvimento das maçãs e formação das fibras (Allen; Aleman, 2011).

De forma semelhante, o excesso de água devido ao encharcamento do solo também gera uma condição de estresse para o desenvolvimento das plantas. Esta condição reduz a disponibilidade de oxigênio para as raízes do algodoeiro, o que prejudica a absorção de nutrientes, em especial, o ferro e nitrogênio, resultando na redução da área foliar e, conseqüentemente, na interceptação luminosa, atividade fotossintética e desenvolvimento das plantas (Echer; Rosolem; Raphael, 2018).

Além da disponibilidade hídrica, o desenvolvimento do algodoeiro também é diretamente influenciado pela temperatura, sendo que cada fase do ciclo da planta requer uma quantidade específica de calor acumulado para ocorrer de forma adequada. A faixa de temperatura ideal para a cultura compreende entre 20°C e 30°C, apresentando alta sensibilidade a temperaturas inferiores à basal, que acarretam um alongamento do ciclo. Ademais, a formação e o desenvolvimento da qualidade da fibra podem ser prejudicados devido à redução do metabolismo celular e atividade enzimática (Echer; Rosolem; Raphael, 2018).

Em contrapartida, sob condições de temperaturas elevadas, o algodoeiro apresenta uma menor retenção de capulhos, devido à modificação da relação fonte-dreno na planta, podendo prejudicar tanto a produtividade quanto a qualidade da fibra (Lokhande; Reddy, 2014). Por ser uma planta de mecanismo C3, altas temperaturas também resultam em um aumento da taxa respiratória e, conseqüentemente, na fotorrespiração, comprometendo a demanda de fotoassimilados e a produção final (Chiavegato *et al.*, 2009).

Dessa forma, a consequência de temperaturas persistentes fora da faixa ideal ou a ocorrência de alta amplitude térmica ao longo do ciclo será prejudicial não apenas na produtividade das plantas, mas também na qualidade das fibras, resultando em fibras imaturas, de baixa resistência, comprimento e micronaire.

Embora a disponibilidade hídrica e a temperatura do ar sejam fatores cruciais no algodoeiro, a luminosidade também desempenha uma influência importante no desenvolvimento das plantas. A luz é um dos fatores que regulam o acúmulo de matéria seca no algodoeiro, o qual pode ser estimado a partir da quantidade de radiação solar interceptada pelas plantas em um determinado período. Nos meses com maior ocorrência de chuvas, os períodos nublados prolongados podem ocorrer, e eles limitam a disponibilidade de luz e, por consequência, a radiação fotossinteticamente ativa (Echer; Rosolem, 2015).

Durante a fase reprodutiva, o sombreamento reduz a fotossíntese nas folhas e limita a síntese e o transporte de fotoassimilados para os frutos jovens. Essa restrição pode desencadear uma série de respostas fisiológicas que comprometem a qualidade pós-colheita. O efeito direto dessa limitação é o suprimento insuficiente de açúcares, o que reduz a síntese de celulose e resulta em fibras imaturas. Indiretamente, a menor disponibilidade de carboidratos para botões florais e frutos recém-formados pode causar sua abscisão, diminuindo o número de capulhos por área (Echer; Rosolem, 2015).

Além das condições agrometeorológicas, outros fatores como época de semeadura, nutrição mineral, práticas de manejo, densidade populacional de plantas, uso de reguladores de crescimento e desfolhantes também condicionam a eficiência produtiva do algodoeiro e devem ser cautelosamente manejados ao longo de todo o ciclo para garantir a melhor qualidade de fibra.

### **1.5. Domesticação e melhoramento genético**

O algodoeiro é uma das plantas cultivadas mais antigas conhecidas pela humanidade, com uma história que se estende por milênios. Estima-se que sua teve início há aproximadamente 4.000 anos, marcando um ponto crucial na evolução da agricultura e da tecnologia têxtil. As primeiras referências históricas do cultivo do algodão são encontradas na região sul da Arábia (Grover *et al.*, 2022). O algodão desempenhou um papel fundamental no desenvolvimento de civilizações antigas, não apenas como uma fonte de fibra para vestuário, mas também como um bem valioso para o comércio. Evidências arqueológicas e registros históricos indicam que o algodão era cultivado e utilizado em várias partes do mundo antigo, incluindo o subcontinente indiano, o Egito e as Américas (Grover *et al.*, 2022; Gross; Strasburg; 2010).

Existem duas formas principais de algodão domesticado, ambas originárias do Novo Mundo. O *G. barbadense*, conhecido como algodão Pima ou Egípcio, foi domesticado nos Andes peruanos entre 4.000 e 5.000 anos atrás. O algodão conhecido como *Upland Cotton*, *G. hirsutum*, constitui a maior parte da produção mundial de algodão e foi domesticado aproximadamente na mesma época na península de Yucatán (Grover *et al.*, 2022).

Tanto o algodão Pima quanto o *Upland* sofreram muitas mudanças fenotípicas durante o processo de domesticação, incluindo reduções na dormência das sementes, uma mudança para uma arquitetura de planta mais compacta e perda da sensibilidade ao fotoperíodo, ou seja, a planta não depende mais de mudanças no comprimento do dia para induzir a floração. A principal mudança, no entanto, é observada nos tricomas das sementes que compõem a fibra do

algodão, que se tornaram mais longos, mais finos e mais fortes na cultura, em comparação com a forma selvagem. Isso ocorreu para atender as demandas e exigências das indústrias (Gross; Strasburg; 2010).

No contexto brasileiro, a história da cotonicultura precede a chegada dos colonizadores europeus em 1500. Os povos indígenas que habitavam o território que viria a se tornar o Brasil já possuíam conhecimentos sofisticados sobre o cultivo e o processamento do algodão. Eles demonstravam habilidades notáveis em várias etapas da produção têxtil e esses conhecimentos eram aplicados na confecção de itens essenciais para seu cotidiano, como redes e cobertores (AMIPA, 2025).

A presença e o uso do algodão pelos povos indígenas antes da colonização europeia demonstram não apenas a antiguidade do cultivo dessa planta no território brasileiro, mas também o alto nível de desenvolvimento tecnológico e cultural desses povos. Esse conhecimento indígena sobre o algodão foi posteriormente incorporado e expandido durante o período colonial, contribuindo para o estabelecimento do Brasil como um importante produtor de algodão nos séculos seguintes (AMIPA, 2025).

O melhoramento genético do algodão no Brasil tem uma história que remonta ao início do século XX. Os esforços sistemáticos começaram nas primeiras décadas, com o Instituto Agrônomo de Campinas (IAC), iniciando um programa crucial em 1920. Na década de 1930, houve uma expansão significativa com a criação de estações experimentais em várias regiões do país, que focou no desenvolvimento de cultivares resistentes a doenças e pragas, além do melhoramento na qualidade da fibra. Nas décadas de 1940 e 1950 viram avanços importantes no desenvolvimento de cultivares de algodão herbáceo adaptadas ao Nordeste brasileiro, expandindo a cotonicultura na região (Teles; Fuck, 2016).

Um marco significativo ocorreu em 1973 com a fundação da Embrapa, seguida pela criação da Embrapa Algodão em 1975, que se tornou um ator fundamental na pesquisa do algodão. Nas décadas de 1970 e 1980, o foco voltou-se para o desenvolvimento de cultivares resistentes a doenças, especialmente à doença azul do algodoeiro (Teles; Fuck, 2016). A década de 1990 trouxe a incorporação de técnicas de biotecnologia, incluindo o uso de marcadores moleculares para seleção assistida.

Um ponto de virada ocorreu em 2005, quando o Brasil aprovou o uso de algodão geneticamente modificado, marcando uma nova era no melhoramento genético. Ao longo dessa história, parcerias público-privadas desempenharam um papel crucial, com colaborações entre instituições de pesquisa e empresas privadas, o que impulsionou avanços contínuos. O resultado

desses esforços ao longo do tempo foi o estabelecimento do Brasil como um dos principais produtores mundiais de algodão, com cultivares altamente produtivas e adaptadas às diversas condições regionais do país.

O cenário atual do melhoramento genético do algodão no Brasil é caracterizado por uma diversidade de programas, tanto públicos quanto privados, que trabalham para atender às demandas complexas e em constante evolução do setor algodoeiro. Esses programas visam desenvolver cultivares que não apenas satisfaçam as exigências do mercado global, mas também atendam às necessidades específicas dos produtores brasileiros e da indústria de beneficiamento (Khan *et al.*, 2020).

Os objetivos principais dos programas de melhoramento incluem: desenvolvimento de cultivares com ciclo médio a precoce, permitindo maior flexibilidade no manejo da cultura e potencialmente reduzindo custos de produção. Desenvolvimento de cultivares com alta produtividade por área, com ênfase no aumento da proporção de fibra em relação ao peso total do capulho. Melhoria nas características físicas da fibra para atender às exigências da indústria têxtil moderna. Adaptação às diversas condições edafoclimáticas das regiões produtoras de algodão no Brasil, desde o Cerrado até o semiárido nordestino. E, por fim, resistência a pragas e doenças, por meio da incorporação de genes de resistência ou tolerância aos principais desafios fitossanitários da cultura, reduzindo a necessidade de intervenções químicas e aumentando a sustentabilidade da produção (Soares, 2015).

O melhoramento genético do algodão, como em outras culturas, baseia-se no princípio fundamental da seleção de indivíduos superiores dentro de populações geneticamente diversas. Este processo é essencial para o desenvolvimento contínuo de cultivares que atendam às demandas em constante evolução do setor algodoeiro sucesso (Sedyama; Silva; Borém, 2015).

A seleção dos genitores e identificação das melhores combinações híbridas é uma etapa inicial e fundamental, pois determina o potencial genético das populações subsequentes. A escolha dos genitores deve ser baseada em uma avaliação cuidadosa de suas características, histórico de desempenho e capacidade de combinação. A identificação das melhores combinações híbridas permite concentrar esforços nas populações com maior potencial de sucesso (Sedyama; Silva; Borém, 2015).

A complexidade do processo de seleção de genitores, dada a vasta gama de materiais disponíveis e a diversidade de condições ambientais e sistemas de produção, demanda abordagens sofisticadas e eficientes. O uso de estratégias estatísticas avançadas e inteligência artificial (IA) está se tornando cada vez mais importante nesse cenário.

Essas abordagens oferecem várias vantagens no contexto do melhoramento do algodão no Brasil: lidam eficientemente com a heterogeneidade ambiental, permitindo a seleção de genitores adaptados a regiões específicas ou com ampla adaptabilidade; permitem a integração de múltiplos critérios de seleção, balanceando características agronômicas, de qualidade de fibra e de resistência a estresses; aceleram o processo de melhoramento, reduzindo o tempo necessário para desenvolver novas cultivares; otimizam o uso de recursos, focando esforços nas combinações mais promissoras e aumentam a precisão da seleção, especialmente para características complexas e de baixa herdabilidade (Farooq *et al.*, 2024; Xu *et al.*, 2022).

## **1.6. Inteligência computacional no melhoramento genético**

Estudos apontam que, até 2050, a produção agrícola mundial deverá duplicar para suprir a demanda estimada em função do crescimento populacional, das alterações nos hábitos alimentares e da elevação do consumo de biocombustíveis. Nesse contexto, o aumento da produtividade das culturas, em detrimento da expansão da área cultivada, torna-se a estratégia mais adequada para alcançar tal meta (Ray *et al.*, 2013).

As abordagens de melhoramento genético atuais têm possibilitado o desenvolvimento de diferentes culturas, elevando seu valor nutricional e produtividade para atender à crescente demanda por alimentos, fibras e biocombustíveis. Contudo, o atual ritmo de aumento da produtividade é insuficiente para suprir as necessidades futuras, de modo que cientistas e melhoristas enfrentam o desafio contínuo de aprimorar as culturas existentes e criar cultivares com maior rendimento, resistência a pragas e doenças, além de maior resiliência às condições climáticas adversas (Hickey *et al.*, 2019).

Diferentemente da domesticação inicial das culturas, o melhoramento hoje já dispõe de uma vasta gama de tecnologias inovadoras para aprimorar culturas agrícolas.

A revolução do sequenciamento de DNA permitiu-nos determinar os genomas completos de muitas plantas, incluindo organismos modelo como *Arabidopsis thaliana*. A introdução dos marcadores moleculares transformou o melhoramento genético, permitindo a seleção de genótipos de forma mais precisa e eficiente. Ao contrário da seleção tradicional, que dependia exclusivamente da avaliação fenotípica, a genômica permite a identificação de genes e regiões do DNA associados a características de interesse, como produtividade e rendimento. A utilização de marcadores viabilizou a seleção assistida, que tornou possível a seleção precoce de plantas, independentemente da influência do ambiente ou de fatores externos (Hickey *et al.*, 2019; Prabhu *et al.*, 2023).

A evolução das plataformas de sequenciamento genético permitiu o uso acessível de marcadores moleculares, possibilitando a dissecação de traços e melhoramento genético preditivo, além de proporcionar uma maior eficiência na seleção para características complexas como a tolerância a estresses ambientais (Hickey *et al.*, 2019).

A fenotipagem de alto rendimento ou *high-throughput phenotyping* (HTP) representou um avanço crucial para o melhoramento genético moderno, superando as limitações da avaliação manual de plantas. Ao empregar tecnologias como sensores e robótica, o HTP permitiu a coleta rápida, precisa e não destrutiva de dados fenotípicos em grande escala (Hall *et al.*, 2022). Essa capacidade de gerar informações detalhadas sobre características complexas, como produtividade, eficiência no uso da água e tolerância a estresses bióticos e abióticos, em diferentes estádios de crescimento, tem sido fundamental para desvendar a relação entre o genótipo e o fenótipo.

A integração dos dados de HTP com a seleção genômica assistida permitiu acelerar os ciclos de melhoramento, tornando possível identificar e selecionar genótipos superiores de forma mais eficiente e precisa, um requisito essencial para desenvolver cultivares mais adaptadas aos desafios impostos pelas mudanças climáticas e pela crescente demanda por alimentos (Hall *et al.*, 2022).

Neste contexto, a inteligência artificial (IA) surge como uma alternativa para auxiliar no processo de análise de dados em associação às tecnologias já empregadas no melhoramento. A complexidade dos dados gerados pelas tecnologias atuais, sejam dados fenotípicos ou genômicos, exige métodos avançados para a sua interpretação.

Modelos de aprendizado de máquina (*machine learning*) e aprendizado profundo (*deep learning*) conseguem identificar padrões e correlações não lineares entre genótipo, fenótipo e ambiente, superando alguns limites impostos por métodos estatísticos tradicionais. Essa integração permite a criação de modelos preditivos mais precisos para características complexas, como produtividade e adaptação a estresses climáticos (Centorame *et al.*, 2024).

A IA é algo interdisciplinar da ciência que investiga os fundamentos teóricos, o desenvolvimento e a implementação de algoritmos capazes de reproduzir aspectos da cognição humana. As técnicas empregadas baseiam-se em modelos computacionais que simulam o funcionamento do cérebro humano, processando informações provenientes de múltiplas fontes para tomada de decisão e buscando replicar processos cognitivos como aprendizado, generalização, adaptação a novas informações e descoberta de padrões (Centorame *et al.*, 2024; Cruz; Nascimento, 2018).

Na análise de dados, a IA é amplamente empregada para modelagem preditiva, classificação e reconhecimento de padrões, sendo aplicável em diferentes domínios da ciência. Dentre as principais abordagens, destacam-se a utilização de Redes Neurais Artificiais, Lógica Fuzzy e algoritmos baseados em Árvores de decisão, como *Random Forest* e *Regression Trees*, que simulam o funcionamento dos neurônios humanos para o processamento de dados (Cardoso *et al.*, 2021).

No âmbito da fenotipagem, a IA pode ajudar na classificação de características das plantas que não são facilmente quantificáveis ou têm componentes subjetivos, como, por exemplo, a cor da folha ou o vigor da planta. Sistemas baseados em árvores de decisão também podem auxiliar os melhoristas na tomada de decisões complexas, incorporando conhecimento especializado e lidando com múltiplos critérios, às vezes conflitantes. Esses sistemas podem ajudar na seleção de parentais para cruzamentos ou na decisão sobre quais linhagens avançar em programas de melhoramento (Silva *et al.*, 2014; Cardoso *et al.*, 2021).

No que se trata das interações genótipo-ambiente, os modelos de inteligência computacional podem capturar as relações complexas e frequentemente não-lineares entre genótipos e fatores ambientais. Isso é particularmente útil para entender e prever o desempenho das culturas em diversos ambientes (Carneiro *et al.*, 2019).

Como vantagens do uso destas ferramentas no melhoramento de plantas, podemos citar: habilidade de processar e integrar grandes volumes de dados heterogêneos; flexibilidade para se adaptar a diferentes tipos de problemas e dados; potencial para descobrir padrões não evidentes em abordagens tradicionais e o aprendizado contínuo da ferramenta, ou seja, a capacidade de melhorar continuamente com mais dados (Silva *et al.*, 2014).

Dessa forma, as alternativas de inteligência artificial oferecem um poderoso conjunto de ferramentas para o melhoramento de plantas, capazes de lidar com a complexidade e a escala dos dados modernos de melhoramento. Sua aplicação está transformando muitos aspectos do processo de melhoramento, desde a seleção de parentais até a previsão de desempenho de cultivares. À medida que a tecnologia avança e mais dados se tornam disponíveis, é provável que as IAs desempenhem um papel cada vez mais central nos programas de melhoramento, acelerando o desenvolvimento de novas cultivares e ajudando a enfrentar os desafios da segurança alimentar e das mudanças climáticas.



## 1.7. Algoritmos de árvores de decisão

*Machine learning* (ML) é um subcampo da inteligência artificial que desenvolve algoritmos capazes de aprender a executar tarefas específicas a partir de conjuntos de dados. As abordagens se dividem principalmente em aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, o objetivo é prever uma saída, um rótulo no caso de uma classificação ou um valor numérico em uma regressão, a partir de variáveis de entrada, treinando modelos com dados rotulados. O aprendizado não supervisionado, por sua vez, busca padrões em dados não rotulados, auxiliando na interpretação e preparação de dados para uso posterior em modelos supervisionados (Van Dijk *et al.*, 2021).

Diversos algoritmos foram desenvolvidos, cada um com pontos fortes e limitações. Entre as abordagens modernas, destacam-se as árvores de decisão e métodos de comitê (*ensemble methods*), como *Random Forest* e *Extra Trees*, que combinam múltiplos modelos para melhorar o desempenho preditivo em relação a modelos individuais. Outras técnicas incluem *deep learning*, redes neurais convolucionais e recorrentes, *boosting* e máquinas de vetores de suporte, cada uma adaptada a tipos específicos de dados e problemas (Van Dijk *et al.*, 2021).

As árvores de decisão constituem métodos geralmente simples, de fácil interpretação, aplicáveis tanto a tarefas descritivas quanto preditivas. Esses algoritmos são capazes de identificar relações não lineares, superando as limitações impostas por abordagens lineares, como a regressão. Para isso, empregam o particionamento recursivo, técnica na qual o conjunto de dados é sucessivamente dividido em subgrupos, os quais são posteriormente analisados por modelos específicos (Martins, 2020).

O algoritmo de *Random Forest* (floresta aleatória) é composto por uma coleção de árvores de decisão. Cada árvore no conjunto é composta por uma amostra de dados extraída de um conjunto de treinamento com reposição, chamada de amostra *bootstrap*. Dessa amostra de treinamento, um terço geralmente é reservado como dados de teste, conhecidos como amostra *out-of-bag* (Bruce; Bruce, 2019).

Em cada divisão dentro das árvores, apenas um subconjunto aleatório de preditores é considerado como candidato para a separação. Isso introduz duas fontes de aleatoriedade, na seleção dos dados e na escolha das variáveis. Cada árvore traz, portanto, uma visão ligeiramente diferente dos padrões subjacentes (Bruce; Bruce, 2019).

Para uma tarefa de regressão, as árvores de decisão individuais são calculadas em média, e para uma tarefa de classificação, uma votação majoritária, ou seja, a variável categórica mais

frequente produzirá a classe prevista. Finalmente, a amostra *out-of-bag* é então usada para validação cruzada interna, permitindo avaliar a performance sem usar um conjunto de teste separado e, assim, finalizando a predição (Bruce; Bruce, 2019) (Figura 4).

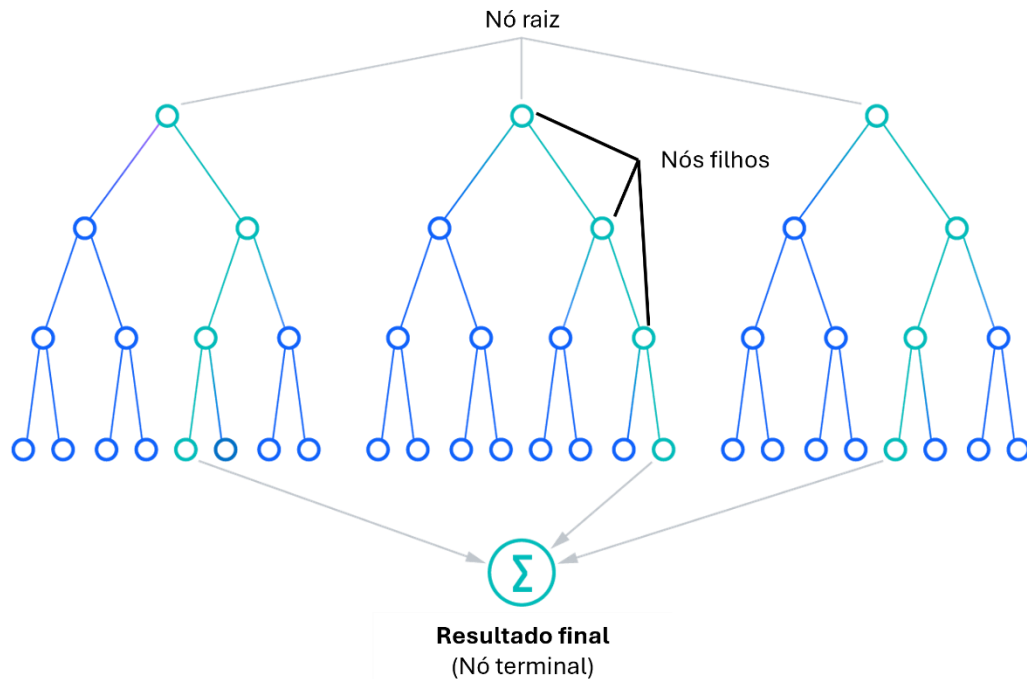


FIGURA 4 - Representação esquemática de uma árvore de decisão

O *Extra Trees* (*Extremely Randomized Trees*) é conceitualmente similar ao *Random Forest*, mas apresenta diferenças-chave que aumentam a aleatoriedade e, conseqüentemente, reduzem a variância. Enquanto no *Random Forest* a escolha da variável e do ponto de corte em cada nó é baseada na busca pelo melhor split entre um subconjunto de variáveis, no *Extra Trees* tanto a seleção da variável quanto o ponto de corte são determinados aleatoriamente. Isso significa que o algoritmo não procura otimizar o ponto de divisão em cada nó, tornando o treinamento mais rápido e, em alguns casos, mais resistente a ruídos nos dados (Bruce; Bruce, 2019).

Além disso, o *Extra Trees* geralmente constrói as árvores usando todo o conjunto de treinamento, sem amostragem *bootstrap*, o que pode resultar em menor viés, embora com maior dependência entre as árvores. Essas diferenças tornam o *Extra Trees* potencialmente mais eficiente em termos computacionais e mais adequado para cenários com grande quantidade de variáveis irrelevantes (Bruce; Bruce, 2019).

## 1.8. Fenotipagem digital

A aplicação de inteligência computacional e *machine learning* no melhoramento tem avançado não apenas na análise de dados climáticos e genéticos, mas também na coleta e interpretação de informações fenotípicas. Nesse contexto, a fenotipagem digital ou *high-throughput phenotyping* (HTP) surge como uma abordagem complementar, capaz de gerar dados padronizados sobre o crescimento e a qualidade de culturas (Pabuyon *et al.*, 2019).

Com o uso de sensores ópticos, imagens RGB, multiespectrais e hiperespectrais, drones e plataformas terrestres, esses sistemas automatizados transformam o fenótipo em variáveis numéricas que podem ser diretamente integradas a modelos de classificação e predição de características de interesse agrônômico. Assim, a fenotipagem digital fornece dados de alta resolução que alimentam modelos computacionais, ampliando sua capacidade de prever características complexas (Pabuyon *et al.*, 2019).

No algodoeiro, estudos com o uso de HTP possibilitaram revelar a base genética de traços dinâmicos e sua relação com produtividade e adaptação. Pauli *et al.* (2016) usaram uma plataforma de campo para medir temperatura de dossel, reflectância, NDVI e altura em uma população mapeada de *G. hirsutum*, identificando QTLs com padrões temporais e colocalizações com QTLs agrônômicos, uma evidência direta de que traços capturados por sensores são informativos para seleção.

Muitos estudos têm sido realizados para identificar e classificar plantas quanto ao vigor e estresse com o uso de HTP. No entanto, outras características, como qualidade de fibra também podem ser inferidas a partir de séries temporais de imagens. Usando RGB e multiespectral obtidos por UAS e modelos de ML, estudos conseguiram estimar parâmetros HVI como comprimento de fibra, índice de uniformidade e micronaire com bom desempenho, indicando que assinaturas espectrais e estruturais do dossel durante o ciclo guardam relação com a qualidade intrínseca da fibra (Xu *et al.*, 2023).

Em paralelo, índices de vegetação e texturas derivados de RGB têm sido empregados para prever produtividade com alta acurácia, o que favorece decisões de manejo e seleção em redes multiambiente (Ma *et al.*, 2022).

Para o algodão naturalmente colorido, a fenotipagem digital permite quantificar objetivamente a cor da fibra e classificar amostras por intensidade e tonalidade usando imagens RGB e visão computacional. Estudos evidenciaram a possibilidade de mensurar a cor do algodão em pluma e classificar genótipos com o uso de modelos de *machine learning*, reduzindo a subjetividade e padronizando critérios na avaliação (Fischer *et al.*, 2023).

## REFERÊNCIAS

- AHMAD, F.; MUHAMMAD, N.; MUHAMMAD, A. A.; MUHAMMAD, N. A. Heat Stress in Cotton: responses and adaptive mechanisms. *In*: AHMAD, S.; HASANUZZAMAN, M. **Cotton Production and Uses**. Singapore: Springer, 2020. p. 393-428.
- ALLEN, R. D.; ALEMAN, L. Abiotic stress and cotton fiber development. *In*: OOSTERHUIS, D. M. **Stress physiology in cotton**. Cordova: The Cotton Foundation Reference Book Series, 2011. p. 149-160.
- ALVES, L. R. A.; FERREIRA FILHO, J. B. S.; LIMA, F. F.; OSAKI, M.; IKEDA, V. Y.; GOTTARDO, L. C. B. Impacto do uso de tecnologias geneticamente modificadas no setor produtivo de algodão. **Informações Econômicas**, São Paulo, v. 44, n. 2, p. 50-65, 2014. Disponível em: <http://www.ica.agricultura.sp.gov.br/ftpica/publicacoes/ie/2014/tec5-0414.pdf>. Acesso em: 22 jan. 2025.
- AQUINO, L. A.; BERGER, P. G.; LIMA NEVES, J. C.; AQUINO, R. F. B. A. Acúmulo e exportação de nutrientes pelo algodoeiro com a aplicação parcelada de fósforo. **Bioscience Journal**, v. 30, p. 12–21, 2014. Disponível em: <https://seer.ufu.br/index.php/biosciencejournal/article/view/13949>. Acesso em: mai. 2025.
- ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE ALGODÃO. **Algodão no mundo**. Disponível em: <https://www.abrapa.com.br/Paginas/dados/algodao-no-mundo.aspx>. Acesso em 22 jan. 2025.
- ASSOCIAÇÃO MINEIRA DE PRODUTORES DE ALGODÃO. **História do algodão**. Disponível em: [http://www.sincti.com/clientes/ampa/site/qs\\_historia.php](http://www.sincti.com/clientes/ampa/site/qs_historia.php). Acesso em: 23 jan. 2025.
- BARROS, M. A. L.; DA SILVA, C. R. C.; LIMA, L. M.; FARIAS, F. J. C.; RAMOS, G. A.; SANTOS, R. C. A review on the evolution of cotton in Brazil: GM, white and colored cultivars. **Journal of Natural Fibers**, v. 19, n. 1, p. 209-221, 2020. DOI: <https://doi.org/10.1080/15440478.2020.1738306>.
- BORÉM, A.; FREIRE, E. C. **Algodão: do plantio a colheita**. Viçosa-MG: Editora UFV, 2014.
- BRUCE, P.; BRUCE, A. **Estatística prática para cientistas de dados: 50 conceitos essenciais**. 1. ed. Rio de Janeiro: Alta Books, 2019.
- CARDOSO, D. B.O.; MEDEIROS, L. A.; CARVALHO, G. O.; PIMENTEL, I. M.; ROJAS, G. X.; SOUZA, L. A.; SOUZA, G. M.; SOUSA, L. B. Use of computational intelligence in the genetic divergence of colored cotton plants. **Bioscience Journal**, Uberlândia, v. 37, e37007, p. 1-9, 2021. DOI: <https://doi.org/10.14393/BJ-v37n0a2021-53634>.
- CARNEIRO, A. R. T.; SANGLARD, D. A.; AZEVEDO, A. M.; SOUZA, T. L. P. O.; PEREIRA, H. S.; MELO, L. C. Fuzzy logic in automation for interpretation of adaptability and stability in plant breeding studies. **Scientia Agricola**, Piracicaba-SP, v. 76, n. 2, p. 123-129, 2019. DOI: <http://dx.doi.org/10.1590/1678-992X-2017-0207>.
- CENTORAME, L.; GASPERINI, T.; ILARI, A.; DEL GATTO, A.; FOPPA PEDRETTI, E. An overview of machine learning applications on plant phenotyping, with a focus on sunflower. **Agronomy Journal**, v. 14, n. 719, p. 1-23, 2024. DOI: <https://doi.org/10.3390/agronomy14040719>.

CHIAVEGATO, E. J.; SALVATIERRA, D. K.; GOTTARDO, L. C. B. **Agrometeorologia dos cultivos**: O fator meteorológico da produção agrícola – Algodão. 1. ed. Brasília, DF: INMET, 2009. Disponível em: [https://portal.inmet.gov.br/uploads/publicacoesDigitais/agrometeorologia\\_dos\\_cultivos.pdf](https://portal.inmet.gov.br/uploads/publicacoesDigitais/agrometeorologia_dos_cultivos.pdf). Acesso em: 09 abr. 2025.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Boletim da safra de grãos**: grãos Safra 2019/20. 5º Levantamento - Safra 2024/25, Brasília: CONAB, 2025. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 12 jan. 2025.

CRUZ, C. D.; NASCIMENTO, M. **Inteligência computacional aplicada ao melhoramento genético**. Viçosa-MG: Editora UFV, 2018.

DELHOM, C. D.; KELLY, B.; MARTIN, V. Physical Properties of Cotton Fiber and Their Measurement. In: FANG, D.D. **Cotton Fiber**: physics, Chemistry and Biology. 1 ed. Cham, Switzerland: Springer, 2018.

ECHER, F.R.; ROSOLEM, C.A. Cotton yield and fiber quality affected by row spacing and shading at diferent growth stages. **European Journal Of Agronomy**, v. 65, p. 18-26, 2015. DOI: <https://doi.org/10.1016/j.eja.2015.01.001>.

ECHER, F.; ROSOLEM, C. A.; RAPHAEL, J. P. A. Desenvolvimento da planta e qualidade da fibra. In: **Manual de qualidade de fibra da AMPA – safra 2018**. Cuiabá: IMAmt – Instituto Matogrossense do Algodão, p. 206-237, 2018. Disponível em: [https://www.researchgate.net/publication/325131032\\_Desenvolvimento\\_da\\_planta\\_e\\_qualidade\\_da\\_fibra](https://www.researchgate.net/publication/325131032_Desenvolvimento_da_planta_e_qualidade_da_fibra). Acesso em: 12 jan. 2025.

FAROOQ, M. A.; GAO, S.; HASSAN, M. A.; HUANG, Z.; RASHEED, A.; HEARNE, S.; PRASSANA, B.; LI, X.; LI, H. Artificial intelligence in plant breeding. **Trends in Genetics**, v. 40, n.10, p. 891-908, 2024.DOI: <https://doi.org/10.1016/j.tig.2024.07.001>.

FISHER, O. J.; RADY, A.; EL-BANNA, A. A.; WATSON, N. J.; EMAISH, H. H. An image processing and machine learning solution to automate Egyptian cotton lint grading. **Textile Research Journal**, Thousand Oaks, California, EUA, v. 93, n. 11-12, p. 2558-2575, 2023. DOI: <https://orcid.org/0000-0002-1158-6751>.

FONSECA, R. G.; SANTANA, J. C. F. **Resultados de ensaio HVI e suas interpretações (ASTM D-4605)**. Campina Grande: Embrapa, 2002. (Circular Técnica, 66). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/275874/1/CIRTEC66.pdf>. Acesso em: 22 jan. 2025.

FREIRE, E. C. **Algodão no cerrado do Brasil**. In: ABRAPA. 3 ed. Brasília: Gráfica e Editora Positiva, p.301-332, 2015.

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**, London, 2014. DOI: <https://doi.org/10.1155/2014/231635>.

GROSS, B. L.; STRASBURG, J. L. Cotton domestication: dramatic changes in a single cell. **BMC Biology**, v. 8, n. 137. 2010. Disponível em: <http://www.biomedcentral.com/1741-7007/8/139>. Acesso em: 29 mar. 2025.

GROVER, C. E.; ARICKLL, M. A.; TRASH, A.; SHARBROUGH, J.; HU, G.; YUAN, D.; SNODGRASS, S.; MILLER, E. R.; RAMARAJ, T.; PETERSON, D. G.; UDAL, J. A.;

WENDEL, J. F. Dual domestication, diversity, and differential introgression in old world cotton diploids. **Genome Biology and Evolution**, v. 14, n. 12, 2022. DOI: <https://doi.org/10.1093/gbe/evac170>.

HALL, R. D.; D'AURIA, J. C.; SILVA FERREIRA, A. C.; GIBON, Y.; KRUSZKA, D.; MISHRA, P.; ZEDDE, R. V. High-throughput plant phenotyping: a role for metabolomics? **Trends in Plant Science**, v. 27, n. 6, 2022. DOI: <https://doi.org/10.1016/j.tplants.2022.02.001>.

HICKEY, L. T.; HAFEEZ, A. N.; ROBINSON, H.; JACKSON, S. A.; LEAL-BERTIOLI, S. C. M.; TESTER, M.; GAO, C.; GODWIN, I. D.; HAYES, B. J.; WULFF, B. B. H. Breeding crops to feed 10 billion. **Nature biotechnology**, v. 37, p. 744-754, 2019. DOI: <https://doi.org/10.1038/s41587-019-0152-9>.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Special Report on the Ocean and Cryosphere in a Changing Climate**. Geneva: IPCC, 2025. Disponível em: <https://www.ipcc.ch/srocc/>. Acesso em: 23 abr. 2025.

KELLY, C. M.; HEQUET, E. F.; DEVER, J. K. Interpretation of AFIS and HVI Fiber Property Measurements in Breeding for Cotton Fiber Quality Improvement. **The Journal of Cotton Science**, v. 16, p. 1-16, 2012. Disponível em: <https://www.semanticscholar.org/paper/BREEDING-AND-GENETICS-Interpretation-of-AFIS-and-in-Kelly-Hequet/3d59a124e84b64da726f43ed2ff29d5e91c648f2>. Acesso em: 21 jan. 2025.

KHAN, M. A.; WAHID, A.; AHMAD, M.; TAHIR, M. T.; AHMED, M.; AHMAD, S.; HASANUZZAMAN, M. World Cotton Production and Consumption: An Overview. In: AHMAD, S.; HASANUZZAMAN, M. **Cotton Production and Uses**. 1 ed. Singapore: Springer, p. 2-8, 2020. Disponível em: [https://www.researchgate.net/publication/339726149\\_World\\_Cotton\\_Production\\_and\\_Consumption\\_An\\_Overview](https://www.researchgate.net/publication/339726149_World_Cotton_Production_and_Consumption_An_Overview). Acesso em: 10 fev. 2025.

KLEIN, H. S.; LUNA, F. V. The complex evolution of Brazilian cotton production. **América Latina en la Historia Económica**, v. 30, n. 2, p. 1-35, 2023. DOI: <https://doi.org/10.18232/20073496.1374>.

LANA, V.; RIBAS, P. V.; CHANSELME, J. A classificação do algodão. In: IMAMT. **Manual de beneficiamento do algodão**. Primavera do Leste: Casa da Árvore, 2014. cap.15, p.299-367. Disponível em: [https://imamt.org.br/wp-content/uploads/2025/04/Manual\\_de\\_Beneficiamento\\_2a\\_EDICAO\\_2025.pdf](https://imamt.org.br/wp-content/uploads/2025/04/Manual_de_Beneficiamento_2a_EDICAO_2025.pdf). Acesso em: 21 jan. 2025.

LIMA, J. J. Classificação do algodão em pluma. In: **Safra 2018 – Manual de Qualidade de fibra da AMPA**. Cuiabá: IMAMT-Instituto Matogrossense Do Algodão, 2018. Disponível em: [https://imamt.org.br/wp-content/uploads/2018/03/manual\\_qualidade\\_apresentacao.pdf](https://imamt.org.br/wp-content/uploads/2018/03/manual_qualidade_apresentacao.pdf). Acesso em: 21 jan. 2025.

LOKHANDE, S.; REDDY, K. R. Quantifying temperature effects on cotton reproductive efficiency and fiber quality. **Agronomy Journal**, v.106, p.1275-1282, 2014. DOI: <https://doi.org/10.2134/agronj13.0531>.

MA, Y.; MA, L.; ZHANG, Q.; HUANG, C.; YI, X.; CHEN, X.; HOU, T.; LV, X.; ZHANG, Z. Cotton Yield Estimation Based on Vegetation Indices and Texture Features Derived From

RGB Image. **Frontiers in Plant Science**, v. 13, 2022. DOI: <https://doi.org/10.3389/fpls.2022.925986>.

MARTINS, I. T. A. **Qualidade de fibra de diferentes cultivares brasileiras de algodão e sua relação com as condições meteorológicas**. 2020. (Dissertação de Mestrado). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba-SP, 2020. Disponível em: <https://repositorio.usp.br/item/003007700>. Acesso em: 22 jan. 2025.

MIRANDA, J. E.; RODRIGUES, S. M. M. História do bicudo no Brasil. In: BELOT, J. L. **O bicudo-do-algodoeiro (*Antohonomus grandis* BOH., 1843) nos cerrados brasileiros: Biologia e medidas de controle**. Cuibá: Instituto Mato-grossense do Algodão, 2015. Disponível em: [https://www.researchgate.net/profile/Jose-Malaquias/publication/281117630\\_O\\_controle\\_biologico\\_do\\_bicudo-do-algodoeiro\\_-\\_Biological\\_control\\_of\\_cotton\\_boll\\_weevil/links/5727856c08ae262228b44ea3/O-controle-biologico-do-bicudo-do-algodoeiro-Biological-control-of-cotton-boll-weevil.pdf](https://www.researchgate.net/profile/Jose-Malaquias/publication/281117630_O_controle_biologico_do_bicudo-do-algodoeiro_-_Biological_control_of_cotton_boll_weevil/links/5727856c08ae262228b44ea3/O-controle-biologico-do-bicudo-do-algodoeiro-Biological-control-of-cotton-boll-weevil.pdf). Acesso em: 04 abr. 2025.

MORAIS, J. P. S.; KELLY, B. R.; SAYEED, A.; HEQUET, E. F. Effects of non-lint material on heritability estimates of cotton fiber length parameters. **Euphytica**, v. 216, n. 2, p. 24, 2020. DOI: <https://doi.org/10.1007/s10681-019-2536-9>.

NAWAZ, B.; SATTAR, S.; MALIK, T. A. Genetic analysis of yield components and fiber quality parameters in upland cotton. **International Multidisciplinary Research Journal**, v. 9, p. 13-19, 2019. Disponível em: <https://updatepublishing.com/journal/index.php/imrj/>. Acesso em: 23 jan. 2025.

PABUAYON, I.; SUN, Y.; GUO, W.; RITCHIE, G. L. High-throughput phenotyping in cotton: a review. **Journal of Cotton Research**, v. 2, n. 18, 2019. DOI: <https://doi.org/10.1186/s42397-019-0035-0>.

PARRY, G. Le cotonnier et ses produits. In: COSTE, R. (Ed.). **Techniques Agricoles et Producciones Tropicales**. Paris, France: G-P Maisonneuve et Larose Paris, p. 502, 1981.

PAULI, D.; ANDRADE-SANCHEZ, P.; CARMO-SILVA, A. E.; GAZAVE, E.; FRENCH, A. N.; HEUN, J.; HUNSAKER, D. J.; LIPKA, A. E.; SETTER, T. L.; STRAND, R. J.; THORP, K. R.; WANG, S.; WHITE, J. W.; GORE, M. A. Field-Based High-Throughput Plant Phenotyping Reveals the Temporal Patterns of Quantitative Trait Loci Associated with Stress-Responsive Traits in Cotton. **G3**, v. 6, p. 865-879, 2016. DOI: <https://doi.org/10.1534/g3.115.023515>.

PRABHU, K. R.; KUMAR, A.; YUMKHAIBAM, R. S.; JANEJA, H. S.; KRISHNA, B.; TALEKAR, N. A review on conventional and modern breeding approaches for developing climate resilient crop varieties. **Journal of Applied and Natural Science**, v. 15, n. 3, p. 987 – 997, 2023. DOI: <https://doi.org/10.31018/jans.v15i3.4653>.

RAY, D. K.; MUELLER, N. D.; WEST, P. C.; FOLEY, J. A. Yield trends are insufficient to double global crop production by 2050. **PLOS One**, v. 8, n. 6, p. 1-8, 2013. DOI: <https://doi.org/10.1371/journal.pone.0066428>.

REHMAN, A.; FAROOQ, M. Morphology, Physiology and Ecology of Cotton. In: JABRAN, K.; CHAUBAN, B. S. **World Agriculture Series: Cotton Production**. 1 ed. Wiley Blackwell, 2019.



RESENDE, M. A. V.; FREITAS, J. A.; LANZA, M. A.; RESENDE, M. D. V. AZEVEDO, C. F. Divergência genética e índice de seleção via BLUP em acessos de algodoeiro para características tecnológicas da fibra. **Pesquisa Agropecuária Tropical**, v. 44, n. 3, p. 334-340, 2014. DOI: <https://doi.org/10.1590/S1983-40632014000300006>.

ROSOLEM, C. A. Ecofisiologia e manejo da cultura do algodoeiro. **Potafos: Informações Agronômicas**, n. 95, p. 1-9, 2001.

SESTREN, J. A.; LIMA, J. J. Características e classificação da fibra de algodão. In: FREIRE, E. C. (Ed.). **Algodão no cerrado do Brasil**. 3 ed. Brasília, DF: ABRAPA, 2015.

SILVA, G. N.; TOMAZ, R. S.; SANT'ANNA, I. C.; NASCIMENTO, M.; BHERING, L. L.; CRUZ, C. D. Neural networks for predicting breeding values and genetic gains, **Scientia Agricola**, v. 71, n. 6, p. 494-498, 2014. DOI: <https://doi.org/10.1590/0103-9016-2014-0057>.

SOARES, L. C. S. **Efeito da temperatura e chuva sobre a qualidade da fibra e produtividade de algodão no estado do Mato Grosso**. 2015. (Dissertação de Mestrado). Escola Superior de Agricultura "Luiza de Queiroz", Universidade de São Paulo, 2015. DOI: <https://doi.org/10.11606/T.11.2015.tde-22092015-144144>

TELES, G. C.; FUCK, M. P. Pesquisa e desenvolvimento de cultivares: o perfil tecnológico da cotonicultura brasileira. **Informe Gepec**, Toledo, v. 20, n. 1, p. 61-77, 2016. DOI: <https://doi.org/10.48075/igepec.v20i1.13377>.

United States Department of Agriculture (USDA). Cotton and Wool Outlook Tables: February 2025. Disponível em: <https://www.ers.usda.gov/publications/pub-details?pubid=110929>. Acesso em: 05, fevereiro 2025.

VAN DIJK, A. D. J.; KOOTSTRA, G.; KRUIJER, W.; RIDDER, D. Machine learning in plant science and plant breeding. **iScience**, v. 24, n. 1, 2021. DOI: <https://doi.org/10.1016/j.isci.2020.101890>.

XU, Y.; ZHANG, X.; LI, H.; ZHENG, H.; ZHANG, J.; OLSEN, M. S.; VARSHNEY, R. K.; PRASANNA, B. M.; QIAN, Q. Smart breeding driven by big data, artificial intelligence, and integrated genomic-enviromic prediction. **Molecular Plant**, v. 15, p. 1664-1695, 2022. DOI: <https://doi.org/10.1016/j.molp.2022.09.001>.

XU, W.; YANG, W.; CHEN, P.; ZHAN, Y.; ZHANG, L.; LAN, Y. Cotton Fiber Quality Estimation Based on Machine Learning Using Time Series UAV Remote Sensing Data. **Remote Sensing**, v. 15, 2023. DOI: <https://doi.org/10.3390/rs15030586>.



## **Capítulo 1**

# **PREDIÇÃO DA QUALIDADE DE FIBRA DO ALGODOEIRO COM BASE EM VARIÁVEIS CLIMÁTICAS EM MINAS GERAIS**

## RESUMO

O algodão (*Gossypium hirsutum* L.) é a principal fibra têxtil natural. Para enfrentar desafios como as mudanças climáticas e o aumento da demanda, o melhoramento genético é crucial para aprimorar a qualidade e a produtividade. A inteligência artificial está revolucionando esse processo, acelerando o desenvolvimento de novas cultivares e otimizando a seleção de características desejáveis. Sendo assim, o objetivo do presente trabalho foi avaliar o uso de metodologias baseadas em *machine learning* na predição de características de qualidade de fibra de algodoeiro utilizando variáveis climáticas dos municípios de cultivo no estado de Minas Gerais. Os dados de qualidade de fibra (micronaire, maturidade, resistência, alongamento, uniformidade do comprimento, índice de fibras curtas e índice de fiabilidade) são provenientes de 32 cultivares comerciais de algodão, cultivadas em 32 fazendas produtoras localizadas em 21 municípios mineiros, nas safras 2020/21, 2021/22, 2022/23 e 2023/24. Os dados climáticos mensais, de dezembro a junho de cada local e ano/safra, (temperatura máx. e mín. média e precipitação acumulada) foram obtidos com base em suas coordenadas geográficas. A análise de dados foi realizada no Software Python (Scikit-learn, matplotlib, statsmodels, shap e seaborn). Modelos de *machine learning* foram aplicados para estimar as características da fibra do algodão usando dados climáticos. O modelo Random Forest superou a regressão linear e a Extra Trees, indicando maior precisão. A precipitação e a temperatura mínima em meses específicos foram as variáveis climáticas mais influentes na qualidade da fibra. Embora os modelos apresentem potencial, a expansão do banco de dados com a inclusão de informações de manejo pode aumentar significativamente a acurácia das previsões, tornando os modelos mais robustos para diferentes regiões produtoras.

**PALAVRAS-CHAVE:** *Gossypium hirsutum* L; machine learning; florestas aleatórias.

## ABSTRACT

Cotton (*Gossypium hirsutum* L.) is the world's leading natural textile fiber. To address challenges such as climate change and increasing demand, genetic breeding is crucial for improving quality and productivity. Artificial intelligence is revolutionizing this process, accelerating the development of new cultivars and optimizing the selection of desirable traits. The objective of this study was to evaluate the use of machine learning methodologies to predict cotton fiber quality characteristics using climate variables from growing municipalities in the state of Minas Gerais, Brazil. Fiber quality data (micronaire, maturity, strength, elongation, length uniformity, short fiber index, and spinning consistency index) were collected from 32 commercial cotton cultivars grown on 32 farms located in 21 municipalities in Minas Gerais, during the 2020/21, 2021/22, 2022/23, and 2023/24 crop seasons. Monthly climate data (average maximum and minimum temperature, and accumulated precipitation) from December to June for each location and crop season were obtained based on their geographic coordinates. Data analysis was performed using Python software (Scikit-learn, matplotlib, statsmodels, shap, and seaborn). Machine learning models were applied to estimate cotton fiber characteristics using climate data. The Random Forest model outperformed linear regression and Extra Trees, indicating higher accuracy. Precipitation and minimum temperature in specific months were the most influential climate variables on fiber quality. Although the models show potential, expanding the database to include management information could significantly increase the accuracy of predictions, making the models more robust for different producing regions.

**KEYWORDS:** *Gossypium hirsutum* L; machine learning; random forest.

## INTRODUÇÃO

A agricultura desempenha um papel fundamental nas economias nacionais, particularmente nos países em desenvolvimento, sendo o algodão uma cultura comercial de grande relevância. No cenário global, a fibra de algodão destaca-se como uma matéria-prima essencial para a indústria têxtil, gerando um impacto econômico anual estimado em, no mínimo, 600 bilhões de dólares (Ashraf *et al.*, 2024).

A produção mundial de algodão atinge aproximadamente 25 milhões de toneladas por ano e os cinco principais países produtores são: Brasil, Estados Unidos, Índia, China e Paquistão (ICAC, 2025). O sucesso do Brasil no mercado de algodão é resultado de décadas de investimento em pesquisa e desenvolvimento, melhoramento genético e adoção de práticas agrícolas avançadas, atingindo produtividades crescentes a cada ano (Echer *et al.*, 2024).

No entanto, à medida que a população mundial continua em crescimento e com a necessidade crescente por matérias-primas renováveis, enfrentamos desafios como mudanças climáticas, escassez de recursos e aumento da demanda por alimentos e fibras naturais (Hickey *et al.*, 2019). O melhoramento genético desempenha um papel fundamental na adaptação das culturas às condições ambientais em constante mudança, no aumento da resistência a pragas e doenças, e na melhoria da qualidade e produtividade (Cardoso *et al.*, 2021).

Neste contexto, a inteligência artificial (IA) está revolucionando o processo de melhoramento genético, acelerando significativamente o desenvolvimento de novas cultivares e otimizando a seleção de características desejáveis. A IA, através de técnicas como *machine learning* e visão computacional, permite aos pesquisadores analisar vastas quantidades de dados genômicos, fenotípicos e ambientais em uma fração do tempo que seria necessário usando métodos tradicionais (Cardoso *et al.*, 2021).

Por exemplo, algoritmos de aprendizado profundo podem ser treinados para identificar padrões complexos em dados genéticos que estão associados a características desejáveis, como tolerância à seca ou produtividade. Esses modelos podem então prever quais cruzamentos têm maior probabilidade de produzir progênie com as características desejadas, otimizando assim o processo de seleção (Cardoso *et al.*, 2021).

A integração da IA no melhoramento genético do algodão e de outras culturas não apenas acelera o processo de desenvolvimento de novas cultivares, mas também aumenta a precisão da seleção, resultando em culturas mais resilientes e produtivas. Isso é particularmente

importante no contexto das mudanças climáticas, nos quais a capacidade de desenvolver rapidamente cultivares adaptadas a novas condições ambientais é crucial (Cardoso *et al.*, 2021).

À medida que a população mundial continua a crescer, a demanda por fibras naturais como o algodão também aumentará. Novas ferramentas associadas ao melhoramento serão fundamentais para garantir que possamos atender a essa demanda de forma sustentável, produzindo mais com menos recursos e minimizando o impacto ambiental (Zhang *et al.*, 2024).

Dessa forma, a convergência do melhoramento genético com as tecnologias de IA representa uma poderosa ferramenta para enfrentar os desafios agrícolas do século XXI.

Sendo assim, o objetivo do presente trabalho foi avaliar o uso de metodologias baseadas em *machine learning* na predição de características de qualidade de fibra de algodoeiro utilizando variáveis climáticas dos municípios de cultivo no estado de Minas Gerais.

## MATERIAL E MÉTODOS

### 2.1. Ensaios - Municípios e Cultivares

Os dados de qualidade de fibra são provenientes de 32 fazendas produtoras localizadas em 21 municípios mineiros (Figura 5), nas safras 2020/21, 2021/22, 2022/23 e 2023/24.

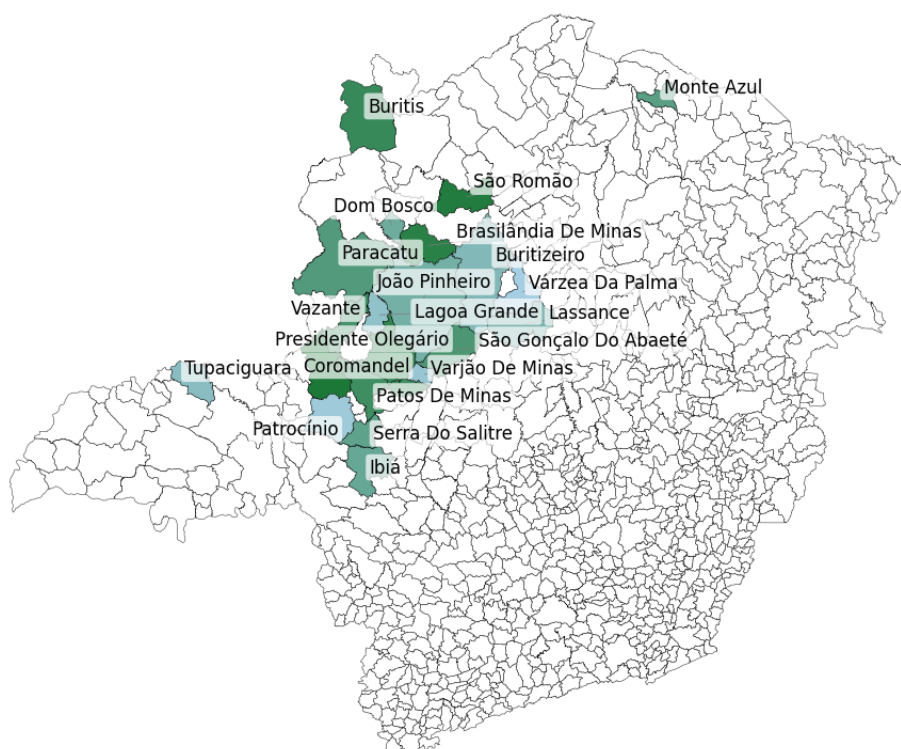


FIGURA 5 - Mapa dos municípios de Minas Gerais produtores de algodão empregados no presente estudo  
Fonte: IBGE (2025).

Os dados climáticos mensais de cada local de produção foram obtidos com base em suas coordenadas geográficas, sendo estes: temperatura máxima média (°C), temperatura mínima média (°C) e precipitação acumulada (mm) durante os meses de dezembro, janeiro, fevereiro, março, abril, maio e junho em cada ano/safra (NASA/POWER, 2025). Os dados climáticos são estimados baseados em satélites e modelos de alta precisão e os parâmetros meteorológicos são amparados em modelo de assimilação MERRA-2, estimando a incerteza associada a parâmetros solares e meteorológicos (NASA/POWER, 2025).

Foram utilizados dados de características tecnológicas da fibra de algodão de 32 cultivares comerciais brasileiras das empresas Tropical Melhoramento Genético (TMG),

Empresa Brasileira de Pesquisa Agropecuária (Embrapa), Instituto Mato-Grossense do Algodão (IMAmt), Deltapine (Bayer) e Fibermax (BASF) (Tabela 1). O número total de dados avaliados foi de 511, gerados a partir da média entre os todos os fardos analisados em cada amostra composta por cultivar x local x ano-safra.

TABELA 1 - Cultivares analisadas e número de dados por cultivar de algodão utilizado no presente estudo

<b>Cultivar</b>	<b>n</b>	<b>Cultivar</b>	<b>n</b>
BRS 293	7	FM 942 TLP	15
BRS 600 B3RF	3	FM 944GL	66
BRS-500 B2 RF	3	FM 970 GLTP	23
DP 1536 B2RF	3	FM 974 GLT	56
DP 1637 B2RF	3	FM 976 TLP	3
DP 1746 B2RF	10	FM 978 GLTP	43
DP 1786 B2RF	6	FM 983GLT	11
DP 1786 RF	4	FM 985GLTP	58
DP 1857 B3RF	13	IMA 2106	5
DP 1866 B3RF	19	IMA 5801	20
DP 1949 B3RF	13	TMG 22 GLTP	10
DP 2077 B3RF	3	TMG 30 B3RF	3
DP 2176 B3RF	4	TMG 31 B3RF	7
FM 906GLT	14	TMG 66 GL	3
FM 911 GLTP	33	TMG44B2RF	16
FM 912 GLTP	31	TMG47B2RF	3
<b>Soma</b>	<b>169</b>		<b>342</b>
<b>Total (n)</b>		<b>511</b>	

Fonte: a autora.

Cada um dos fardos analisados foi amostrado com a retirada de aproximadamente 200g de fibra, compostas por 100g de amostra de ambos os lados do fardo. As amostras foram devidamente identificadas e acondicionadas. Uma vez que as características mensuradas (principalmente a resistência) são influenciadas pelo teor de umidade do algodão e pela metodologia de condicionamento, as amostras foram então armazenadas em locais com temperatura ( $21 \pm 1^\circ\text{C}$ ) e teor de umidade ( $65 \pm 2\%$ ) controlados, de modo que estivessem em equilíbrio com as condições atmosféricas aprovadas, antes e durante os testes. A média das características tecnológicas da fibra de todos os fardos por cultivar, em cada localidade e ano safra testados, geraram os 511 dados analisados.

## 2.2. Características avaliadas

Após as amostras de algodão terem sido acondicionadas a uma temperatura atmosférica padrão para os ensaios têxteis, por um período compreendido entre 24 a 48 horas, elas foram destinadas a análise de qualidade da fibra.

A análise foi realizada com o auxílio do sistema HVI (*High Volume Instruments*), no laboratório Minas Cotton, pertencente a Associação Mineira de Produtores de Algodão, em Uberlândia-MG. Dentre as medições realizadas por este equipamento, destacam-se: uniformidade do comprimento de fibra (UNF, em %), alongamento da fibra (ELG, em %), resistência da fibra (STR, em gf tex<sup>-1</sup>), micronaire (MIC, adimensional), maturidade da fibra (MAT), índice de fibras curtas (SFI, em %) e índice de fiabilidade (SCI).

O SCI (*Spinning Consistency Index*) é uma métrica que quantifica a consistência do processo de fiação e seu impacto na qualidade do fio (Hossain *et al.*, 2025) e é derivado de uma combinação de diversos parâmetros de qualidade da fibra, incluindo resistência, comprimento, finura, uniformidade, refletância Rd e +b.

A interpretação das características tecnológicas da fibra foi submetida aos padrões estabelecidos pela Empresa Brasileira de Pesquisa Agropecuária (Fonseca; Santana, 2002) (Tabela 2).

TABELA 2 - Definição e interpretação das características tecnológicas da fibra de algodão segundo classificação proposta pela EMBRAPA (Fonseca; Santana, 2002)

Caract.	Definição	Interpretação
UNF (%)	Relação entre o comprimento médio e o comprimento médio da metade mais longa do feixe de fibras, expresso em porcentagem.	Muito baixo: menor que 77; Baixo: de 77 A 79; Regular: de 80 A 82; Elevado: de 83 A 85; Muito elevado: acima de 85.
ELG (%)	Quanto o material cede no sentido longitudinal até o momento de rotura, expresso em porcentagem, em função do comprimento inicial.	Muito frágil: menor que 5%; Frágil: de 5,0 a 5,9%; Regular: de 5,9 a 6,7%; Elevado: de 6,8 a 7,6%; Muito elevado: acima de 7,6%.
STR (gf tex <sup>-1</sup> )	Força requerida para romper um feixe de fibras de um <i>tex</i> (equivale a 1000 m lineares de fibra).	Muito baixo: menor que 20; Baixo: de 21 a 23; Regular: de 24 a 27; Elevado: de 27 a 29; Muito elevado: acima de 30.



MIC	Comportamento e resistência ao ar de um feixe de fibras definida em fluxo de ar a uma pressão constante.	Muito fina: menor que 3; Fina: de 3 a 3,9; Regular: de 4 a 4,9; Grossa: de 5 a 5,9; Muito grossa: maior ou igual a 6.
SFI (%)	Porcentagem de fibras curtas, com comprimento inferior a 12,7 mm presentes na amostra.	Muito baixo: menor que 6%; Baixo: de 6 a 9%; Regular: de 10 a 13%; Elevado: de 14 a 17%; Muito elevado: acima de 17%.
MAT	Grau que indica a espessura das camadas de celulose da parede secundária em relação ao seu diâmetro externo da fibra.	Inadequado: menor que 0,70; Imaturo: de 0,70 a 0,80; Inferior ao médio: de 0,80 a 0,85; Maduro: de 0,85 a 0,95; Superior ao médio: de 0,95 a 1,00.

---

Fonte: Embrapa (2002).

Legenda: \* UNF: uniformidade do comprimento; ELG: alongamento da fibra; STR: resistência; MIC: micronaire; SFI: índice de fibras curtas; MAT: maturidade da fibra; Caract.: características tecnológicas da fibra.

### 2.3. Análise estatística

Foram realizadas as análises de correlação de Pearson, componentes principais, agrupamento por k-means, teste e validação dos modelos de predição por regressão linear, *Random Forest* e *Extra Trees* e estimativa dos erros, importância por permutação das características e síntese de Shapley.

Foi elaborada uma matriz de correlação entre as variáveis climáticas mensais e as características de qualidade da fibra por meio da Correlação de Pearson (r):

$$r = (n * \Sigma(xy) - (\Sigma x * \Sigma y)) / \sqrt{[(n * \Sigma(x^2)) - (\Sigma x)^2] * [(n * \Sigma(y^2)) - (\Sigma y)^2]}$$

Onde:

r é o coeficiente de correlação de Pearson.

n é o número de pares de dados (x, y).

$\Sigma(xy)$  é a soma dos produtos dos valores de x e y.

$\Sigma x$  é a soma dos valores de x.

$\Sigma y$  é a soma dos valores de y.

$\Sigma(x^2)$  é a soma dos quadrados dos valores de x.

$\Sigma(y^2)$  é a soma dos quadrados dos valores de y.

Considerando o grande volume de informações analisadas no estudo abrangendo múltiplas cultivares de algodoeiro, condições climáticas e características tecnológicas da fibra, recorreu-se à utilização de técnicas multivariadas com o objetivo de identificar agrupamentos de cultivares com comportamentos semelhantes, com base nos atributos de qualidade da fibra avaliados.

Foram realizadas as análises de componentes principais (PCA) e agrupamento k-means para clusterização. A PCA é um método estatístico que permite a redução de dimensionalidade em dados multivariados. Ela opera por meio da geração de componentes ortogonais, formadas como combinações lineares das originais, que capturam sequencialmente a maior parte da variação dos dados (Jolliffe; Cadima, 2016). O primeiro componente retém o máximo de variância e os demais seguem essa ordem, mantendo ortogonalidade entre si. Essa técnica permite representar dados complexos, como características da fibra ou variáveis climáticas mensais, em um espaço de menor dimensão mantendo o essencial da distribuição original.

No agrupamento por k-means, são definidos centróides com base em pontos aleatórios no espaço dos dados; então, cada uma das cultivares é atribuída ao centróide mais próximo com base em distância euclidiana. Após todas as cultivares serem atribuídas, os centróides são recalculados tendo como base as médias dos pontos que pertencem a ele. Estes passos são então repetidos até que os centróides não mudem mais, convergindo o modelo. Dessa forma, formam-se os clusters, maximizando a similaridade dentre as cultivares de um mesmo grupo e, consequentemente, a diferença entre grupos (Aslam *et al.*, 2023; Leite *et al.*, 2018).

Após verificada a correlação entre as características analisadas, realizou-se a predição das características tecnológicas da fibra com base nas variáveis climáticas, empregando Regressão Linear (RL) e técnicas de *Machine Learning*: *Random Forest* (RF) e *Extra Trees* (ET). Foram separados 80% dos dados de entrada para teste do modelo e 20% para testes de treinamento do modelo, utilizando os métodos *Random Forest* (RF), *Extra Trees* (ET) e Regressão Linear (RL) em suas configurações padrões.

Também foram calculados a importância por permutação das variáveis e os valores de SHAP (*Shapley Additive exPlanations*) para explicar as decisões dos modelos de *machine learning* avaliando o peso das variáveis no modelo. Todas as avaliações foram rodadas com o auxílio do software Python e das bibliotecas: Scikit-learn, matplotlib, statsmodels, shap e seaborn.

## RESULTADOS E DISCUSSÃO

A análise de correlação de Pearson (Figura 6) entre as condições climáticas e as características tecnológicas da fibra evidenciou que os estádios reprodutivos, sobretudo aqueles compreendidos entre os meses de março a maio, correspondentes à formação de maçãs e alongamento das fibras, apresentaram as maiores correlações com atributos como micronaire, maturidade e alongamento de fibra. Isso sugere que a temperatura nesse período influencia o metabolismo fisiológico relacionado à deposição de celulose e à maturação das fibras, refletindo nos índices de qualidade (Ahmad *et al.*, 2020).




FIGURA 6 - Correlação de Pearson para características abióticas e características tecnológicas de fibra  
Fonte: a autora.

Legenda: MIC: micronaire, STR: resistência, ELG: alongamento, MAT: maturidade, SFI: índice de fibras curtas, SCI: índice de fiação, UNF: uniformidade, TMIN: temperatura mínima, TMAX: temperatura máxima, PREC: precipitação acumulada.

Para os atributos como MIC e MAT, a correlação positiva com temperaturas mínimas pode parecer contraintuitiva, considerando que a soma térmica, ou soma dos graus-dia é um fator determinante para o desenvolvimento das plantas e, conseqüentemente, para a qualidade da fibra. No entanto, sabe-se que existe uma faixa ideal de temperatura noturna, entre 15 e 21°C, para o desenvolvimento adequado da fibra, e valores muito inferiores ou superiores a esse

intervalo podem comprometer e degradar sua qualidade (Saini *et al.*, 2023; Ahmad *et al.*, 2020; Lokhande; Reddy, 2014).

Portanto, como a temperatura mínima média registrada nos municípios durante o período observado está compreendida neste intervalo, uma correlação positiva com atributos como MIC e MAT pode refletir condições ótimas de enchimento da parede celular. Além disso, Lokhande e Reddy (2014) observaram que, em temperaturas mais amenas, a atividade de enzimas como sucrose sintase e menor atividade de  $\beta$ -1,3-glucanase contribuem para uma deposição celular mais intensa e consistente da parede secundária, gerando fibras mais maduras e consistentes.

No mesmo estudo, Lokhande e Reddy (2014) verificaram também que, nas condições testadas, a redução no alongamento e, conseqüentemente, no comprimento da fibra em altas temperaturas foi maior do que em baixas temperaturas. Fibras mais longas (>30 mm) foram observadas a 22°C, e o comprimento da fibra diminuiu ligeiramente na menor temperatura testada. Contudo, a redução em alta temperatura foi mais acentuada do que em baixa, e os autores verificaram que o comprimento da fibra foi inibido em alta temperatura, aproximadamente 29,5°C (<28 mm).

Apesar de o processo de alongação das fibras ser compreendido principalmente nos primeiros 15 ou 20 dias após a antese, esta característica apresentou correlação negativa com as temperaturas máximas e mínimas em todo o ciclo. Estudos apontam que o ELG é altamente sensível a extremos térmicos, e pode ser afetado negativamente por amplitudes térmicas elevadas ao longo do dia. Grandes flutuações térmicas aumentam a rigidez da parede celular, favorecendo quebras mecânicas durante a colheita ou processamento, o que pode resultar em um ELG inferior e, conseqüentemente, um SFI elevado (Bradow; Davidonis, 2000; Zafar *et al.*, 2018).

Os resultados corroboram os estudos realizados com cultivares brasileiras de algodoeiro (Gomes *et al.*, 2022). Martins (2020), ao analisar a qualidade de fibra de 32 cultivares brasileiras de algodão e sua relação com as condições meteorológicas no estado do Mato Grosso, verificou que a alongação apresentou correlação negativa com oito variáveis climáticas, dentre elas: temperatura máxima, média e mínima, radiação solar e precipitação.

O Ano-Safra agrega efeitos médios de todo o ambiente, e tem influência de fatores como clima, estratégias de manejo empregadas e controle de insetos-praga. Também apresenta correlação moderada positiva com MIC e MAT (0,37 e 0,35, respectivamente), negativa com SFI (-0,34), mas não supera as correlações mensais-clima.

A identificação de condições edafoclimáticas que favorecem a expressão de características desejáveis de qualidade de fibra pode orientar tanto a seleção de genótipos mais responsivos, quanto o refinamento de estratégias de zoneamento agrícola e manejo cultural. Ademais, esses resultados podem embasar modelos preditivos baseados em inteligência artificial, integrando dados meteorológicos históricos com desempenho fenotípico, de modo a subsidiar decisões de recomendação varietal mais assertivas e adaptadas às realidades microclimáticas da região (Honda Filho *et al.*, 2022).

A análise de componentes principais (PCA) é uma técnica estatística amplamente utilizada para simplificar conjuntos de dados com muitas variáveis correlacionadas, extraindo a essência dos dados com mínima perda de informação. Dessa forma, é possível representar visualmente e analisar um sistema complexo de múltiplas variáveis usando apenas os primeiros componentes principais, reduzindo assim sua complexidade (Jolliffe; Cadima, 2016).

Na Figura 7 está representada a distribuição das cultivares de algodoeiro em dois diferentes espaços multivariados, espaço de qualidade de fibra (Figura 7a) e espaço climático (Figura 7b), permitindo a visualização da variabilidade associada à expressão das características de interesse. Essa abordagem é relevante em programas de melhoramento genético, pois auxilia na distinção entre os efeitos genotípicos e os efeitos ambientais na variação observada, além de permitir a identificação de genótipos ampla ou especificamente adaptados a determinadas condições climáticas. Pela análise, verifica-se que os dois primeiros componentes principais capturam cerca de 68,5 % da variação climática anual e 80,9 % da variação tecnológica das fibras (Figura 7a e 7b).

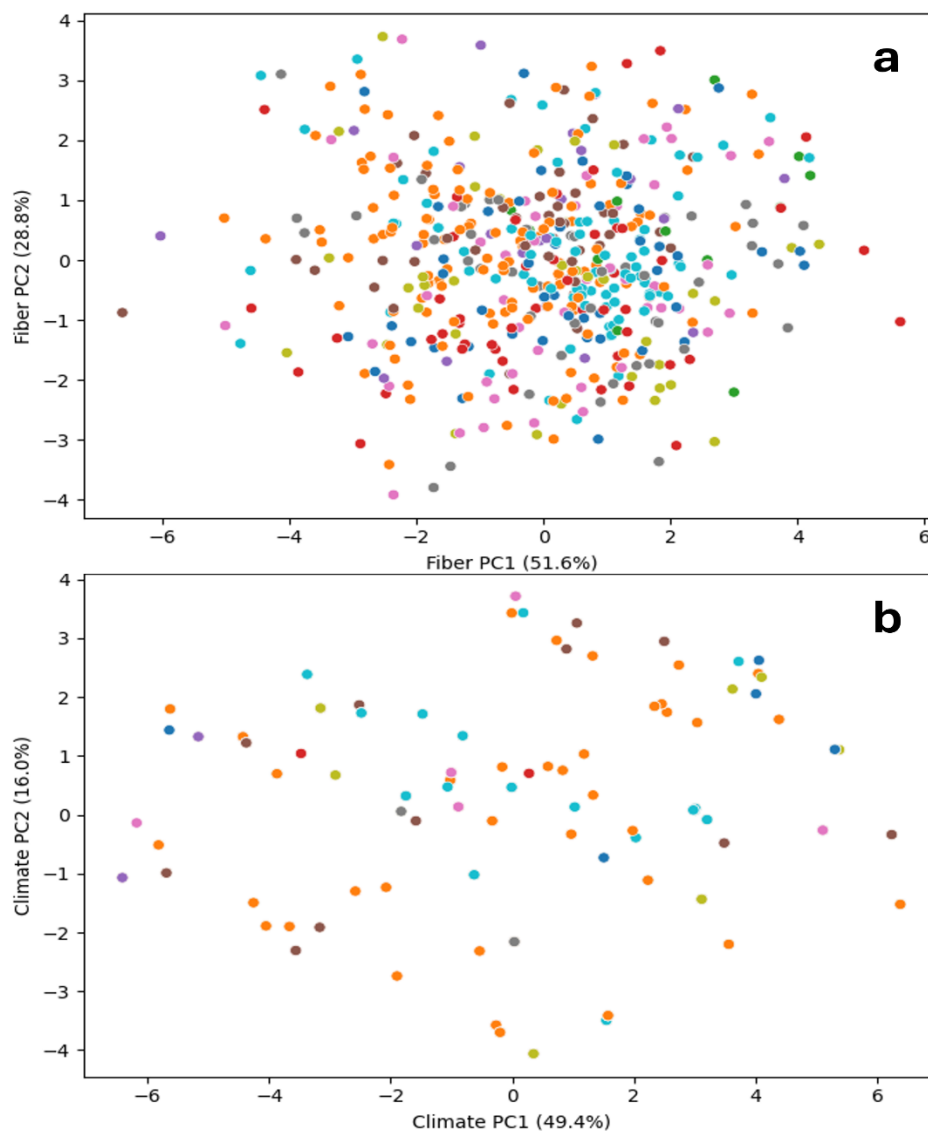


FIGURA 7 - Análise de componentes principais na interação cultivares no espaço fibra e cultivares no espaço climático

No painel (a), a dispersão dos pontos, cada um representando uma combinação entre genótipo, local e ano, demonstra uma grande sobreposição entre as cultivares, o que sugere que no espaço de qualidade de fibra, há baixa diferenciação fenotípica. Isso possivelmente indica estabilidade na expressão dessas características, desejável em termos de uniformidade da qualidade industrial, ou que a variabilidade intrínseca entre cultivares é relativamente pequena frente à influência ambiental.

Já no painel (b), observa-se uma maior dispersão dos pontos no espaço amostral, com formação de agrupamentos mais definidos, refletindo a heterogeneidade climática entre os ambientes de cultivo. Isso evidencia que o componente ambiental contribui de forma significativa para a variação fenotípica observada e que diferentes localidades e anos-safra

impuseram condições térmicas e pluviométricas contrastantes, possivelmente impactando o desempenho dos genótipos de forma diferenciada.

Em conjunto, essas análises reforçam a importância de considerar a interação genótipo x ambiente nos programas de seleção, especialmente quando se busca desenvolver cultivares com ampla adaptação ou com desempenho superior em condições específicas. A PCA foi empregada em diversos estudos para compreender a influência de estresse hídrico e térmico em cultivares de algodão e auxiliou no processo de classificação dos genótipos quanto à tolerância (Xu *et al.*, 2022).

O algoritmo de agrupamento k-means ( $k = 3$ ) é uma técnica de aprendizado não supervisionado, que também é amplamente utilizado no processo de classificação de genótipos. Ao aplicá-lo sobre as médias padronizadas das sete características tecnológicas da fibra para cada cultivar analisada, obtivemos três grupos genéticos distintos ou “clusters” (Figura 8).




FIGURA 8 - Biplot genótipo x ambiente por k-means, com dispersão das 32 cultivares de algodão semeadas em município de Minas Gerais durante o período de 2020 a 2024

As análises de agrupamento têm como intuito empregar os valores das variáveis avaliadas na construção de um sistema de classificação capaz de reunir os objetos estudados em grupos, de forma que aqueles com maior similaridade permanecessem alocados em uma mesma classe. Dada a elevada quantidade de elementos analisados neste trabalho, incluindo cultivares de

algodoeiro, variáveis climáticas e atributos tecnológicos da fibra, optou-se pela utilização dessa abordagem como ferramenta para identificar padrões de proximidade entre as cultivares, considerando os parâmetros de qualidade da fibra, e assim possibilitar a formação de agrupamentos com significado biológico e agrônômico (Aslam *et al.*, 2023; Leite *et al.*, 2018).

Este biplot evidencia a existência de padrões diferenciados de adaptação dos genótipos frente à variabilidade climática dos ambientes avaliados. A dispersão dos pontos no eixo vertical (Climate PC1) demonstra que determinadas cultivares, como FM 911G e TMG 47B2R, aparecem posicionadas em extremos do gradiente climático, indicando que essas cultivares possivelmente foram cultivadas ou responderam sob condições edafoclimáticas distintas das demais. Já no eixo vertical (Fiber PC1), observa-se que parte dos genótipos mantém estabilidade na qualidade de fibra independentemente do ambiente, enquanto outros demonstram maior variação, o que denota diferenças na responsividade fenotípica ao ambiente ou plasticidade.

A estratificação em clusters permite uma melhor análise da compatibilidade dos genótipos nos ambientes. O cluster 0 inclui genótipos que, em geral, ocupam a parte superior do eixo Fiber PC1, associados a maiores valores agregados de qualidade de fibra e ampla presença ao longo do gradiente climático. Esses podem ser considerados genótipos de desempenho consistente e potencialmente de ampla adaptação.

O cluster 1 concentra genótipos mais distribuídos em extremos climáticos negativos, indicando maior sensibilidade ambiental e possível recomendação restrita a condições específicas, enquanto o cluster 2 agrega genótipos posicionados mais centralmente em ambos os eixos, sugerindo estabilidade intermediária, mas potencial para ambientes moderados.

Essa abordagem possibilita a identificação de materiais promissores tanto para cultivo em regiões de maior variabilidade climática quanto para exploração em programas de melhoramento com foco em estabilidade fenotípica e desempenho previsível. Naveen *et al.* (2023) analisaram 50 acessos de trigo, utilizando PCA e k-means para avaliar a diversidade genética e o estudo forneceu insights valiosos para melhoristas que visam aprimorar produtividade e outras características morfológicas por meio da heterose.

Além disso, a identificação de clusters distintos também pode ser estrategicamente utilizada para indicar cruzamento de genótipos com o intuito de aumentar a variabilidade genética e favorecer a obtenção de combinações híbridas com atributos desejáveis de qualidade e adaptação (Naik *et al.*, 2016; Leite *et al.*, 2018). A incorporação dessa análise em modelos preditivos ou redes neurais também amplia as possibilidades de recomendação varietal sob



diferentes cenários climáticos futuros, contribuindo diretamente para a resiliência da cotonicultura no Cerrado brasileiro.

Na Tabela 3 é possível verificar a distribuição das cultivares de algodão nos três clusters obtidos através do agrupamento K-means.

TABELA 3 - Agrupamento de cultivares de algodão por K-means com base em atributos de fibra e clima de cultivo em Minas Gerais

Cluster 0	Cluster 1	Cluster 2
BRS 293	DP 1637 B2RF	BRS 600 B3RF
DP 1746 B2RF	DP 1857 B3RF	DP 1536 B2RF
DP 1949 B3RF	DP 1866 B3RF	DP 1786 B2RF
FM 911 GLTP	FM 906GLT	DP 1786 RF
FM 912 GLTP	FM 983GLT	DP 2077 B3RF
FM 942 TLP	FM 985GLTP	DP 2176 B3RF
FM 944GL	TMG 30 B3RF	TMG 31 B3RF
FM 970 GLTP	TMG44B2RF	TMG 66 GL
FM 974 GLT	TMG47B2RF	
FM 976 TLP		
FM 978 GLTP		
IMA 2106		
IMA 5801		
TMG 22 GLTP		
BRS-500 B2 RF		

Legenda: BRS: Embrapa; DP: Deltapine (BASF); FM: Fibermax (Bayer); IMA: Instituto Mato-Grossense; TMG: Tropical Melhoramento Genético.

Ao comparar as condições climáticas médias dos três clusters (Tabela 4), observa-se que os clusters 0 e 1 foram associados a ambientes mais úmidos, com volume de precipitação dentro do recomendado (650 a 700mm) na cultura para favorecer o desenvolvimento vegetativo vigoroso das plantas (Ahmjad *et al.*, 2023). O cluster 0, em particular, apresentou a maior precipitação total entre os grupos (664 mm), o que pode beneficiar o potencial de carga reprodutiva e o comprimento das fibras. No entanto, a ocorrência de chuvas excessivas e prolongadas em determinados momentos do ciclo pode aumentar a suscetibilidade a doenças e comprometer a uniformidade da maturação da fibra.

TABELA 4 - Médias mensais de temperatura e precipitação nos municípios associados aos clusters varietais gerados por K-means

Var.	Clust.	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Média/Soma*
T <sub>Mín</sub> (°C)	0	20,15	19,77	19,75	19,35	18,21	15,67	15,09	18,28
	1	20,15	19,71	19,71	19,25	18,24	15,84	15,31	18,32
	2	21,41	20,70	20,46	20,35	19,25	17,33	15,98	19,35
T <sub>Máx</sub> (°C)	0	30,05	29,36	29,20	30,46	30,67	30,31	26,02	29,44
	1	30,05	29,62	29,13	30,62	31,02	30,29	26,34	29,58
	2	32,43	30,90	30,10	32,34	32,41	32,33	27,58	31,16
Prec (mm)	0	202,07	179,98	163,58	63,54	45,40	7,36	2,54	664,47
	1	201,64	164,05	181,36	54,00	39,63	8,74	2,10	651,52
	2	157,81	163,57	177,93	58,83	46,75	4,08	3,15	612,13

Legenda: var.: variável climática; Clust.: cluster; \*valores médios de temperatura ao longo do ciclo e soma da precipitação total durante o período de dezembro a junho.

Em contraste, o cluster 2 foi conduzido em regiões com menor precipitação total (612 mm), especialmente em dezembro, o que indica restrição hídrica no início do ciclo e possível adaptação das cultivares a ambientes mais secos. Além disso, esse grupo enfrentou temperaturas mais elevadas nos meses de abril, maio e junho, período crítico de maturação das fibras e abertura das maçãs, o que pode acelerar a desidratação e aumentar a proporção de fibras curtas (Zafar *et al.*, 2018).

O cruzamento entre genótipos de clusters distintos, especialmente entre os clusters 0 e 2, pode potencializar a recombinação de genes relacionados à resiliência térmica e à qualidade da fibra, conforme sugerem Farooq *et al.* (2023) e Miranda *et al.* (2020). A incorporação dessas variáveis em modelos preditivos ou redes neurais tem se mostrado eficaz na recomendação de cultivares para diferentes zonas agroclimáticas.

No caso da cultura da soja, Shook *et al.* (2021) integraram dados históricos de desempenho de cultivares com variáveis climáticas para desenvolver uma ferramenta preditiva baseada em redes neurais recorrentes. Os modelos resultantes permitiram explorar cenários de resposta genotípica às condições ambientais, oferecendo suporte à tomada de decisão em programas de melhoramento frente às mudanças climáticas. Entre as aplicações destacam-se a seleção de genótipos com maior plasticidade fenotípica para lançamento comercial e a definição estratégica de ambientes de teste, otimizando a representatividade e eficiência dos ensaios de campo.

Compreender a influência dos fatores abióticos no desempenho das cultivares é imprescindível para garantir a qualidade da produção. No entanto, é preciso utilizar estratégias seguras para fazer uso dos dados de forma assertiva na predição de características de interesse. Nesse contexto, a inteligência artificial tem contribuído fortemente com o melhoramento genético. A sua capacidade de processar grandes volumes de dados permite desenvolver modelos preditivos mais precisos para desvendar interações complexas e oferecer uma compreensão mais profunda da influência dos fatores abióticos no desempenho das cultivares (Ferraro *et al.*, 2009).

Ao comparar os métodos quanto à precisão da predição, verificou-se que os modelos de IA baseados em árvore (*RandomForest* e *ExtraTrees*) superaram a regressão linear em quase todos as características (MAT, MIC, SCI, SFI, STR, UNF) (Figura 9).




FIGURA 9 - Comparação de poder preditivo baseado em coeficiente de determinação, por modelo e característica tecnológica de fibra

Legenda: R²: coeficiente de determinação; ELG: alongamento; MAT: maturidade; MIC: micronaire; SCI: índice de fiabilidade; SFI: índice de fibras curtas; STR: resistência; UNF: uniformidade.

Kelly e McLaughlin (2024) comparam métodos de *machine learning* com modelos tradicionais para prever quatro traços quantitativos de *Arabidopsis thaliana* e também observaram superioridade dos modelos não-lineares, com ganhos estatisticamente significativos.

Elongamento foi a única exceção, na qual a RL alcançou desempenho semelhante (R²: 0,37) aos modelos de IA, o que indica que a relação com as variáveis climáticas e cultivares

pode ser explicitamente linear ou mais simples nesse caso. Em comparação com modelos de árvore como RF e ET, os modelos de regressão linear se destacam ao serem aplicados a dados que seguem uma distribuição normal ou apresentam linearidade em suas variáveis de entrada. Já os modelos de árvore, por sua vez, têm a vantagem de não dependerem dessas suposições de normalidade ou linearidade (Harrison, 2020).

O modelo de RF obteve as melhores precisões para as características SFI ( $R^2$ : 0,55 e RMSE: 0,88) UNF ( $R^2$ : 0,49 e RMSE: 0,108) e SCI ( $R^2$ : 0,48 e RMSE: 0,122). Apesar de serem valores moderados de coeficiente de determinação e erro quadrático médio (*Root Mean Square Error*), as características em questão são quantitativas e, portanto, influenciadas por diversos fatores genéticos, ambientais e interações complexas (Kelly; McLaughlin, 2024).

Souaibou *et al.* (2025) realizaram estudo para identificar fatores ambientais chave na influência da produtividade e qualidade da fibra por meio de *machine learning*. Ao comparar a performance preditiva de seis algoritmos distintos, tais como RF, LightGBM e XGBoost, verificaram que o Random Forest demonstrou um desempenho superior e consistente em múltiplas métricas de avaliação, alcançando valores de  $R^2$  de 0,39 para STR a 0,7 para porcentagem de fibra.

A análise de importância por permutação das variáveis aponta quais drivers mais discriminam a predição por RF. Observamos que quanto maior a barra representada na Figura 8, maior a perda de acurácia ao “embaralhar” a variável na análise (Figura 10).




FIGURA 10 - Importância por permutação das variáveis climáticas mensais no modelo preditivo RF para a característica SCI

O Random Forest classifica as variáveis de acordo com a importância por permutação de cada uma. Geralmente, se uma variável  $X$  é importante para a variável dependente  $Y$ , permutar a ordem de  $X$  irá quebrar a correlação entre  $X$  e  $Y$ , aumentando, assim, o erro de predição. Em outras palavras, quanto maior o aumento no erro após a permutação da variável  $X$ , mais crítica ela é (Li *et al.*, 2019).

O modelo identificou que a precipitação em dezembro e a temperatura mínima de junho são as variáveis climáticas mais importantes para prever o SCI. As precipitações e temperaturas mínimas ao longo de dezembro, maio, janeiro e março são, em geral, mais relevantes do que temperaturas máximas. Em contrapartida, as variáveis mar\_TMAX, abr\_TMAX e abr\_PREC têm importância próxima de zero, indicando que não afetam o desempenho do modelo ao serem permutadas.

Ainda que a magnitude das importâncias de permutação seja pequena, ela é comum, Gregorutti *et al.* (2017) indicam que, quando vários preditores compartilham relevância, cada um individualmente pode mostrar impacto pequeno, especialmente sob normalização ou múltiplas variáveis correlacionadas.

A análise de importância de permutação fornece uma visão global da dependência do modelo em cada variável, mas pode sofrer com multicolinearidade, ou seja, quando duas ou mais variáveis independentes estão fortemente correlacionadas entre si, e atribuir importância

fragmentada (Gregorutti *et al.*, 2017). Neste contexto, o cálculo dos valores SHAP (*Shapley Additive exPlanations*) é uma alternativa que oferece explicações mais detalhadas baseada na contribuição individual de cada variável, além de fornecer informações sobre o impacto na direção da predição (Flora *et al.*, 2022).

Os valores de SHAP corroboram os observados na importância por permutação para o índice de fiação (Figura 11). Verifica-se que mínimas de temperatura em dezembro, março e junho aparecem com grande impacto positivo ou negativo, dependendo do valor (azul ou vermelho). Isso confirma que temperaturas mínimas nos meses-chave afetam o desenvolvimento da fibra, sendo mais relevantes que máximas.




FIGURA 11 - Síntese do Shapley para a característica Índice de Fibras curtas (SFI)

Em relação à precipitação, fica evidente a influência do regime hídrico, principalmente nos meses do início do ciclo, dezembro e janeiro, sobre a qualidade da fibra. Além disso, verifica-se que as variáveis de ciclo (TMIN\_mean\_cycle, TMAX\_mean\_cycle e PREC\_sum\_cycle) têm menor importância individual que os meses específicos, indicando que os efeitos mensais pontuais têm mais impacto que a média do ciclo inteiro.

As análises aplicadas à predição do índice de fiabilidade da fibra (SCI) permitiram interpretar, de forma individualizada e multivariada, a influência das variáveis climáticas na expressão desse importante caráter tecnológico do algodoeiro. O SCI, enquanto métrica

composta que reflete a consistência da fiação e a qualidade estrutural da fibra, mostrou-se sensível a variações climáticas ocorridas em momentos específicos do ciclo da cultura.

A predição de características associadas à qualidade da fibra com base em dados climáticos pode representar uma ferramenta valiosa para o planejamento agrícola e a recomendação de cultivares mais adaptadas a diferentes condições ambientais no Cerrado Mineiro. Identificar previamente cenários climáticos desfavoráveis e compreender seus possíveis impactos sobre a qualidade da fibra permite direcionar estratégias de manejo específicas, como ajustes no calendário agrícola, escolha de genótipos mais estáveis em ambientes de maior estresse ou no contexto do melhoramento, a recomendação de cruzamentos e a seleção de locais para conduzir ensaios e estruturas programas de melhoramento.

Apesar disso, a acurácia limitada observada em alguns modelos pode estar relacionada à dimensão da base de dados utilizada, sugerindo a necessidade de incluir um outras informações associadas à qualidade da fibra, como as práticas de manejo empregadas, características do solo e nutrição das plantas para aprimorar a robustez das predições.



## CONCLUSÕES

A aplicação de métodos de *machine learning* para estimar características tecnológicas da fibra a partir de variáveis climáticas demonstrou potencial na geração de modelos preditivos, embora com precisão ainda limitada em alguns casos.

Os dados climáticos mensais influenciam diretamente o desempenho dos modelos. A precipitação acumulada nos meses de dezembro e janeiro e a temperatura mínima em dezembro, março e junho foram os fatores mais influentes sobre as propriedades da fibra.

O modelo baseado em *Random Forest* apresentou melhor desempenho na predição das características da fibra, quando comparado à regressão linear e à técnica de *Extra Trees*.

A ampliação da base de dados e inclusão de dados como estratégias de manejo poderá contribuir significativamente para o aumento da acurácia dos modelos preditivos, especialmente quando aplicados a diferentes regiões produtoras de algodão.

## REFERÊNCIAS

- AHMAD, F.; MUHAMMAD, N.; MUHAMMAD, A. A.; MUHAMMAD, N. A. Heat Stress in Cotton: Responses and Adaptive Mechanisms. *In: Cotton Production and Uses*. Springer, p. 393-428, 2020. Disponível em: [https://www.researchgate.net/publication/339736446\\_Heat\\_Stress\\_in\\_Cotton\\_Responses\\_and\\_Adaptive\\_Mechanisms](https://www.researchgate.net/publication/339736446_Heat_Stress_in_Cotton_Responses_and_Adaptive_Mechanisms). Acesso em: 02 mar. 2025.
- AHMJAD, F.; AMIR, S.; ASIF, A.; JEHANZEB, F.; MUHAMMAD, R.; SHAFQAT, C. W.; GHULAM, S.; YASIR, R.; Genetic variability predicting breeding potential of upland cotton (*Gossypium hirsutum* L.) for high temperature tolerance. **Journal of Cotton Research**, v. 6, n. 7, 2023. DOI: <https://doi.org/10.1186/s42397-023-00144-z>.
- ASHRAF, S.; CH, K M.; ASHRAF, I.; AKBAR, N. A phenomenological inquiry into farmers' experiences growing cotton in Punjab, Pakistan. **Scientific Reports Nature**, v. 14, n. 13846, 2024. DOI: <https://doi.org/10.1038/s41598-024-62950-y>.
- ASLAM, S.; HUSSAIN, S. B.; BABER, M.; SHASHEEN, S.; ASLAM, S.; WAHEED, R.; SEO, H.; AZHAR, M. T. Estimation of drought tolerance indices in Upland Cotton under water deficit conditions. **Agronomy**, v. 13, n. 984, p.1-20, 2023. DOI: <https://doi.org/10.3390/agronomy13040984>.
- ASSOCIAÇÃO MINEIRA DE PRODUTORES DE ALGODÃO. **História do algodão**. Disponível em: [http://www.sincti.com/clientes/ampa/site/qs\\_historia.php](http://www.sincti.com/clientes/ampa/site/qs_historia.php). Acesso em: 23 jan. 2025.
- BRADOW, J. M.; DAVIDONIS, G. H. Quantitation of fiber quality and the cotton production-processing interface: a physiologist's perspective. **The Journal of Cotton Science**, v. 4, p-34-64, 2000. Disponível em: <https://www.cotton.org/journal/2000-04/1/upload/jcs04-034.pdf>. Acesso em: 23 jan. 2025.
- CARDOSO, D. B.O.; MEDEIROS, L. A.; CARVALHO, G. O.; PIMENTEL, I. M.; ROJAS, G. X.; SOUZA, L. A.; SOUZA, G. M.; SOUSA, L. B. Use of computational intelligence in the genetic divergence of colored cotton plants. **Bioscience Journal**, Uberlândia, v. 37, p. 9, 2021. DOI: <https://doi.org/10.14393/BJ-v37n0a2021-53634>
- CRUZ, C. D.; NASCIMENTO, M. **Inteligência computacional aplicada ao melhoramento genético**. Viçosa, MG: Ed. UFV, 2018. 414 p.
- ECHER, F. R.; GALDI, L. V.; SILVA, G. R. A.; SANTOS, J. W. S.; ROCHA, C. H.; CAGNA, C. P.; TORMENA, C. A.; SILVA, I. F.; ATARASSI, R. Components of High-Yielding Cotton Grown in Rain-Fed Conditions in the Brazilian Cerrado. **Agronomy**, v. 14, n. 2920, 2024. DOI: <https://doi.org/10.3390/agronomy14122920>.
- FAROOQ, A.; SHAKEEL, A.; SAEED, A.; FAROOQ, J.; RIZWAN, M.; CHATTHA, W. S.; SARWAR, G.; RAMZAN, Y. Genetic variability predicting breeding potential of upland cotton (*Gossypium hirsutum* L.) for high temperature tolerance. **Journal of Cotton Research**, v. 6, n. 7, 2023. DOI: <https://doi.org/10.1186/s42397-023-00144-z>.
- FERRARO, D. O.; RIVERO, D. E.; GHERSA, C. M. An analysis of the factors that influence sugarcane yield in Northern Argentina using classification and regression trees. **Field Crops Research**, v. 112, p. 149-157, 2009. DOI: <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v36n5p895-901/2016>.

FLORA, M.; POTVIN, C.; MCGOVERN, A.; HANDLER, S. Comparing Explanation Methods for Traditional Machine Learning Models Part 2: Quantifying Model Explainability Faithfulness and Improvements with Dimensionality Reduction. **Preprint Vix**, 2022.

FONSECA, R. G.; SANTANA, J. C. F. **Resultados de ensaio HVI e suas interpretações (ASTM D-4605)**. Campina Grande: Embrapa, 2002. (Circular Técnica, 66). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/275874/1/CIRTEC66.pdf>. Acesso em: 22 jan. 2025.

GOMES, I. H. R. A.; CAVALCANTI, J. J. V.; FARIAS, F. J. C.; PAIXÃO, F. J. R.; SILVA FILHO, J. L. S.; SUASSUNA, N. D. Selection of cotton genotypes for yield and fiber quality under water stress. **Brazilian Journal of Agricultural and Environmental Engineering**, v. 26, n. 8, p. 610-617, 2022. DOI: <http://dx.doi.org/10.1590/1807-1929/agriambi.v26n8p610-617>.

GREGORUTTI, B.; MICHEL, B.; SAINT-PIERRE, P. Correlation and variable importance in random forests. **Statistics and Computing**, v. 27, p. 659-678, 2017.

HARRISON, M. **Machine Learning Pocket Reference: Working with Structured Data in Python**. 1. ed. U.S.A.: O'Reilly Media, 2020.

HICKEY, L. T.; HAFEEZ, A. N.; ROBINSON, H.; JACKSON, S. A.; LEAL-BERTIOLI, S. C. M.; TESTER, M.; GAO, C.; GODWIN, I. D.; HAYES, B. J.; WULFF, B. B. H. Breeding crops to feed 10 billion. **Nature biotechnology**, v. 37, p. 744-754, 2019. DOI: <https://doi.org/10.1038/s41587-019-0152-9>.

HONDA FILHO, C. P.; PEREIRA, F. A. C.; REZENDE, T. T.; SILVA, F. A.; CARVALHO, S. P. Genetic diversity and correlation network approach on cotton genotypes in southern of Minas Gerais. **Revista Ceres**, v. 69, n.6, p. 703-708, 2022. DOI: <https://doi.org/10.1590/0034-737X202269060009>.

HOSSAIN, M.A., SRIJAN, S.K., RINAZ, K.R., KHAN, S.Q. AND JALAL UDDIN, A. Investigations of the spinning consistency index (SCI) and its impact on yarn quality. **Research Journal of Textile and Apparel**, 2025. DOI: <https://doi.org/10.1108/RJTA-07-2024-0129>

INTERNATIONAL COTTON ADVISORY COMMITTEE. **Cotton: world statistics report**. Washington, DC: ICAC, 2025. Disponível em: <https://icac.org/>. Acesso em: 12 maio 2025.

JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. **Philosophical Transactions of The Royal Society**, 2016. DOI: <http://dx.doi.org/10.1098/rsta.2015.0202>.

KELLY, C. M.; MCLAUGHLIN, R. L. Comparison of machine learning methods for genomic prediction of selected Arabidopsis thaliana traits. **PLoS ONE**, v. 19, n. 8, 2024. DOI: <https://doi.org/10.1371/journal.pone.0308962>.

LEITE, W. S.; UNÊDA-TREVISOLI, S. H.; SILVA, A. J.; DI MAURO, A. O. Identification of superior genotypes and soybean traits by multivariate analysis and selection index. **Revista Ciência Agronômica**, v. 49, n. 3, 2018. Disponível em: <https://periodicos.ufc.br/revistacienciaagronomica/article/view/88743/242120>. Acesso em: 10 jul. 2025.

LI, J., VEERANAMPALAYAM-SIVAKUMAR, A.; BHATTA, M.; GARST, N. D.; STOLL, H.; BAENZIGER, P. S.; BELAMKAR, V.; HOWARD, R.; GE, Y.; SHI, Y. Principal

variable selection to explain grain yield variation in winter wheat from features extracted from UAV imagery. **Plant Methods**, v. 15, n.123, 2019. DOI: <https://doi.org/10.1186/s13007-019-0508-7>.

LOKHANDE, S. REDDY, R. Quantifying Temperature Effects on Cotton Reproductive Efficiency and Fiber Quality. **Agronomy Journal**, v. 104, n. 4, p. 1275-1282, 2014.

MARTINS, I. T. A. **Qualidade da fibra de diferentes cultivares brasileiras de algodão e sua relação com as condições meteorológicas**. Dissertação (Mestrado em Ciências) – Escola superior de Agricultura Luiza de Queiroz, Piracicaba, 2020. Disponível em: [https://www.teses.usp.br/teses/disponiveis/11/11152/tde-13102020-095751/publico/Isabella\\_Theresa\\_de\\_Almeida\\_Martins\\_versao\\_revisada.pdf](https://www.teses.usp.br/teses/disponiveis/11/11152/tde-13102020-095751/publico/Isabella_Theresa_de_Almeida_Martins_versao_revisada.pdf). Acesso em: 20 jun. 2025.

MIRANDA, M. C. C.; CARDOSO, D. B. O.; PAIVA, T. S.; FARIAS, F. J. C.; SOUSA, L. B. Determining genetic diversity in cotton genotypes to improve variability. **Revista Ceres**, v. 67, n. 6, p. 464-473, 2020. DOI: <https://doi.org/10.1590/0034-737X202067060006>.

NAIK, B. M.; SATISH, Y.; BABU, D. R. Genetic diversity analysis in American cotton (*Gossypium hirsutum* L.). **Electronic Journal of Plant Breeding**, v. 7 n. 4, p. 1002-1006, 2016. Disponível em: [https://www.researchgate.net/publication/316551104\\_Genetic\\_diversity\\_analysis\\_in\\_American\\_cotton\\_Gossypium\\_hirsutum\\_L](https://www.researchgate.net/publication/316551104_Genetic_diversity_analysis_in_American_cotton_Gossypium_hirsutum_L). Acesso em: 20 jun. 2025.

**NASA POWER Project**. *POWER Data Access Viewer*. NASA Langley Research Center, Hampton, VA, USA, 2024. Disponível em: <https://power.larc.nasa.gov/>. Acesso em: 15 jan. 2025.

SAINI, D. K.; IMPA, S. M.; MCCALLISTER, D.; PATIL, G. B.; ABIDI, N.; RITCHIE, G.; JACONIS, S. Y.; JAGADISH, S.V. High day and night temperatures impact on cotton yield and quality - current status and future research direction. **Journal of Cotton Research**, v. 6, n. 16, p. 1-17, 2023. DOI: <https://doi.org/10.1186/s42397-023-00154-x>.

SILVA, G. N.; TOMAZ, R. S.; SANT'ANNA, I. C.; NASCIMENTO, M.; BHERING, L. L.; CRUZ, C. D. Neural networks for predicting breeding values and genetic gains. **Scientia Agricola**, v. 71, n. 6, p. 494-498, 2014. DOI: <https://doi.org/10.1590/0103-9016-2014-0057>.

SHOOK, J.; GANGOPADHYAY, T.; WU, L.; GANAPATHYSUBRAMANIAN, B.; SARKARID, S.; SINGH, A. Crop yield prediction integrating genotype and weather variables using deep learning. **Plos One**, v. 16, n. 6, 2021. DOI: <https://doi.org/10.1371/journal.pone.0252402>.

SOUAIBOU, M.; YAN, H.; DAI, P.; PAN, J.; LI, Y.; SHI, Y.; GONG, W.; SHANG, H.; GONG, J.; YUAN, Y. Machine Learning-Driven Identification of Key Environmental Factors Influencing Fiber Yield and Quality Traits in Upland Cotton. **Plants**, v. 14, 2025. DOI: <https://doi.org/10.3390/plants14132053>.

ZAFAR, S. A.; NOOR, M. A.; WAQAS, M. A.; WANG, X.; SHAHEEN, T.; RAZA, M.; MEHBOOB-UR-RAHMAN. Temperature Extremes in Cotton Production and Mitigation Strategies. **InTech**, 2018. DOI: <http://dx.doi.org/10.5772/intechopen.74648>.

ZHANG, T.; WANG, S.; CHEN, J.; ZHU, S.; ZHU, Q.; ZHAO, T. Advances in Cotton Genomics, Genetics and Breeding. **Plants**, v. 13, n. 2579, 2024. DOI: <https://doi.org/10.3390/plants13182579>.

ZONTA, J. H.; BEZERRA, J. R. C.; SOFIATTI, V.; BRANDÃO, Z. N. Yield of cotton cultivars under different irrigation depths in the Brazilian semi-arid region. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.19, n.8, p.748–754, 2015. DOI: <https://doi.org/10.1590/1807-1929/agriambi.v19n8p748-754>.

XU, Y.; ZHANG, X.; LI, H.; ZHENG, H.; ZHANG, J.; OLSEN, M. S.; VARSHNEY, R. K.; PRASANNA, B. M.; QIAN, Q. Smart breeding driven by big data, artificial intelligence, and integrated genomic-enviromic prediction. **Molecular Plant**, v. 15, p. 1664-1695, 2022. DOI: <https://doi.org/10.1016/j.molp.2022.09.001>.

## **Capítulo 2**

### **CLASSIFICAÇÃO DIGITAL DE FIBRAS DE ALGODÃO NATURALMENTE COLORIDAS POR IMAGENS RGB**

## RESUMO

A fenotipagem baseada em imagens representa uma abordagem inovadora na pesquisa de melhoramento genético, pois permite medições rápidas e confiáveis que auxiliam na tomada de decisões. Este estudo usou a análise de imagens para quantificar a intensidade da coloração da fibra em genótipos de algodão (*Gossypium hirsutum* L.) e investigou o impacto de capulhos colhidos nos terços superior, médio e inferior das plantas nessas características. Dezesete genótipos de algodão, incluindo 5 cultivares e 12 genótipos da geração F2:3, foram avaliados quanto à intensidade da coloração da fibra nos diferentes terços de desenvolvimento da planta. Quinze capulhos foram colhidos manualmente por parcela, sendo 5 capulhos por terço de desenvolvimento. Três capulhos representativos foram fotografados, incluindo um Colorcard nas imagens, e processados no software ImageJ para correção de brilho e coloração. A análise dos dados foi realizada no software R, usando o pacote FIELDDimageR para calcular os índices BI, SI e NGRDI. A calibração das imagens com o Colorcard resultou em médias mais altas, mas não alterou o agrupamento das médias observadas. O terço superior mostrou menor intensidade de coloração da fibra, com uma variação de 6,25% em comparação com os outros terços, mas não houve interação entre os genótipos e os terços. O índice SI permitiu a distinção dos genótipos pela saturação da cor da pluma. O índice BI mostrou correlação com as características da fibra UI, STR e UHML, com um coeficiente de determinação de 0,77; 0,80 e 0,88, respectivamente.

**PALAVRAS-CHAVE:** algodão; fibra naturalmente colorida; fenotipagem de alto rendimento.

## ABSTRACT

Image-based phenotyping represents an innovative approach in genetic improvement research, allowing rapid and reliable measurements that aid in decision-making. This study used image analysis to quantify the intensity of fiber coloration in cotton genotypes (*Gossypium hirsutum* L.) and investigated the impact of bolls harvested in the upper, middle and lower thirds of the plants on these traits. Seventeen cotton genotypes, including 5 cultivars and 12 F<sub>2:3</sub> generation genotypes, were evaluated in relation to the intensity of fiber coloration in the different thirds of the plant development. Fifteen bolls were manually harvested per plot, with 5 bolls per third of development. Three representative bolls were photographed including a Colorcard in the images and these were processed in the ImageJ software for correction of brightness and coloration. Data analysis was performed in the R software, using the FIELDDimageR package to calculate the BI, SI and NGRDI indices. Calibration of the images with Colorcard resulted in higher averages, but did not change the grouping of the observed averages. The upper third showed lower fiber staining intensity, with a variation of 6.25% compared to the other thirds, but there was no interaction between the genotypes and the thirds. The SI index allowed the distinction of the genotypes by the saturation of the plume color. The BI index showed correlation with the fiber characteristics UI, STR and UHML, with a coefficient of determination of 0,77; 0,80 and 0,88, respectively.

**KEYWORDS:** cotton; naturally colored fiber; high-throughput phenotyping.



## INTRODUÇÃO

O algodão (*Gossypium hirsutum* L.) é a fibra vegetal mais importante do mundo e é cultivado em mais de 60 países. O Brasil ocupa o segundo lugar em exportações e o terceiro na produção global, atrás da China e da Índia. Para a safra 2023/24, a produção brasileira atingiu 3,6 milhões de toneladas, com um aumento de 3% na área em relação à safra anterior e uma produtividade média equivalente a 1.889 kg ha<sup>-1</sup> (ABRAPA, 2025; USDA, 2025; CONAB, 2025).

Historicamente, a produção brasileira de algodão baseou-se principalmente no cultivo de genótipos de fibra branca, com cultivares de alto potencial produtivo e boas características de fibra disponíveis no mercado. Portanto, o melhoramento genético do algodão concentrou-se majoritariamente no de fibra branca, enquanto o de fibra naturalmente colorida tem sido utilizado, principalmente, para fins artesanais e ornamentais (Carvalho; Farias; Rodrigues, 2015).

O algodão colorido atende a um nicho de mercado específico que valoriza fibras com cores naturais, oferecendo uma alternativa sustentável ao impacto ambiental negativo do tingimento, já que a eliminação dessa etapa pode reduzir os custos de fabricação em até 50% e minimizar o uso de água e o descarte de resíduos tóxicos (Naoumkina *et al.*, 2024).

No entanto, essa categoria ainda representa uma pequena parcela do mercado global, principalmente devido à menor produtividade e qualidade de suas fibras em comparação com as cultivares de algodão branco disponíveis no mercado, que apresentam fibras mais curtas e com menor resistência (Penna, 2005). Além disso, a falta de padrões de classificação, a limitação de cores e a não uniformidade da coloração dificultam sua escalabilidade na indústria têxtil.

A identificação de parentais de algodão colorido com cor uniforme e estável e características tecnológicas adequadas aos padrões da indústria é essencial para a produção de tecidos ecológicos de alta qualidade (Cardoso *et al.*, 2010). No entanto, a avaliação visual da coloração dessas fibras é demorada, subjetiva e imprecisa. Uma solução para essas limitações é o uso da fenotipagem baseada em imagens, que permite uma caracterização mais eficiente e precisa da cor e da uniformidade. As técnicas de visão computacional já são aplicadas em diversas culturas, como frutas, azeitonas (Hassan *et al.*, 2011; Mojaravski; Magalhães, 2024), pimentões (Bac *et al.*, 2013) e tomates (Zhao *et al.*, 2016), e têm se mostrado alternativas promissoras para o algodão colorido.

Portanto, os objetivos deste estudo foram: (i) utilizar a fenotipagem baseada em imagens para mensurar a intensidade da cor da fibra para um grupo de 17 cultivares comerciais de genótipos de algodão na geração F<sub>2:3</sub>; (ii) investigar a influência das maçãs colhidas nos terços inferior, médio e superior do desenvolvimento da planta nessas características; e (iii) avaliar o efeito do uso de cartões de cor (*colorcards*) na extração de índices baseados em imagens.

## **MATERIAL E MÉTODOS**

### **1.1. Material vegetal e ensaios a campo**

O experimento foi conduzido na safra 2023/24, com semeadura em 6 de janeiro de 2024, na Fazenda Glória da Universidade Federal de Uberlândia (UFU), em Uberlândia-MG. Foram testados dezessete genótipos de algodão naturalmente colorido e um genótipo de algodão branco. Os genótipos BRS Rubi, BRS Jade, BRS Verde, BRS Topázio (algodão colorido) e Suregrow 821 (algodão branco) foram utilizados como genótipos fixos. Além disso, foram incluídos os genótipos de algodão colorido UFUJP-01, UFUJP-02, UFUJP-03, UFUJP-04, UFUJP-10, UFUJP-11, UFUJP-13, UFUJP-14, UFUJP-15, UFUJP-17 e UFUJP-18, desenvolvidos pelo Programa de Melhoramento Genético do Algodão (PROMALG) da UFU, na geração F<sub>2:3</sub>.

O delineamento utilizado foi de blocos aumentados, com quatro repetições. A parcela experimental consistiu em quatro fileiras de cinco metros de comprimento, espaçadas em 0,9 metro, totalizando 18 m<sup>2</sup>, e a área útil consistiu nas duas fileiras centrais.

A quantidade de fertilizante utilizada na semeadura foi de 20 kg ha<sup>-1</sup> de nitrogênio e 60 kg ha<sup>-1</sup> de fósforo e 60 kg ha<sup>-1</sup> de nitrogênio e 30 kg ha<sup>-1</sup> de potássio em cobertura, que foram divididos em duas aplicações: a primeira aos 25 dias após a emergência (DAE) e a segunda aos 45 DAE. Adicionalmente, 1 kg ha<sup>-1</sup> de boro foi aplicado e segregado em quatro aplicações foliares.

O manejo do crescimento do algodão foi realizado com a aplicação de reguladores de crescimento, utilizando o ingrediente ativo cloreto de clorimequat. A primeira aplicação foi feita aos 45 DAE, e as aplicações subsequentes foram realizadas de acordo com a taxa de crescimento, visando a uma altura de colheita de 1,3 metro. Para a avaliação das maçãs, cinco delas por terço da planta foram colhidas, incluindo maçãs apicais, medianas e inferiores (terços superior, médio e inferior), totalizando 15 maçãs por parcela.

### **1.2. Aquisição de imagens e análise**

Após a colheita, as maçãs foram processadas para a obtenção da fibra de algodão em caroço. A fibra proveniente de cada lóculo da maçã foi retirada e disposta de forma que as diferentes tonalidades ao longo da fibra pudessem ser expostas e capturadas nas fotos. As maçãs

foram agrupadas de acordo com o terço da planta de onde foram colhidas, e três maçãs representativas de cada terço foram fotografadas juntas.

O método de processamento das maçãs visa agilizar o preparo e a aquisição das imagens, permitindo que a avaliação seja realizada com alíquotas de fibra removidas durante o processo de colheita do material. Para a aquisição das imagens, as amostras foram colocadas em uma caixa de luz (*lightbox*) equipada com duas fontes de luz difusa e um fundo azul, e fotografadas com uma câmera de iPhone 14 Pro Max™ (teleobjetiva 2x, 12 megapixels, 48 mm, abertura  $\theta/1.78$ ) (fabricado pela Apple, Zhengzhou, China) (Figura 12). Um cartão de correção de cor (*Pixel Perfect Camera Color Correction Card*, 5"x7") foi incluído em cada foto para compensar possíveis variações de iluminação e exposição. A calibração do conjunto de dados foi realizada através do software ImageJ (Schneider; Rasband; Eliceiri, 2012).

A análise do conjunto de 96 imagens foi realizada através do software R (R Core Team, 2023). Para todas as imagens, o fundo foi removido de acordo com limites de cor (*color thresholds*) para diferenciar a pluma do fundo das fotos, e cada foto foi inspecionada visualmente para garantir a precisão, com o auxílio do pacote FIELDimageR (Matias; Caraza-Harter; Endelman, 2020). O plugin fieldIndex foi usado para mensurar os valores médios de vermelho (R), verde (G) e azul (B) da área selecionada em uma escala de 0-255. Esses valores foram usados para mensurar os seguintes índices e fórmulas padrão:

a. Índice de Brilho (BI): Avalia a intensidade da cor, que é baseada na média dos quadrados dos valores RGB e representa a intensidade da cor, sendo que quanto maior o valor, mais intensa é a cor (Richardson; Wiegand, 1977).

$$BI = \sqrt{\frac{(R^2 + G^2 + B^2)}{3}}$$

b. Índice de Diferença Normalizada Vermelho-Verde (NGRDI): A uniformidade da cor é avaliada com base na diferença entre as bandas de vermelho e verde, sendo que um valor mais alto pode indicar maior uniformidade (Tucker, 1979).

$$NGRDI = \frac{(G - R)}{(G + R)}$$

c. Índice de Saturação de Inclinação Espectral (SI): Avalia a saturação espectral em relação às bandas de vermelho e azul, sendo que um valor mais alto pode indicar uma cor mais saturada (Escadafal *et al.*, 1994).

$$SI = \frac{(R - B)}{(R + B)}$$

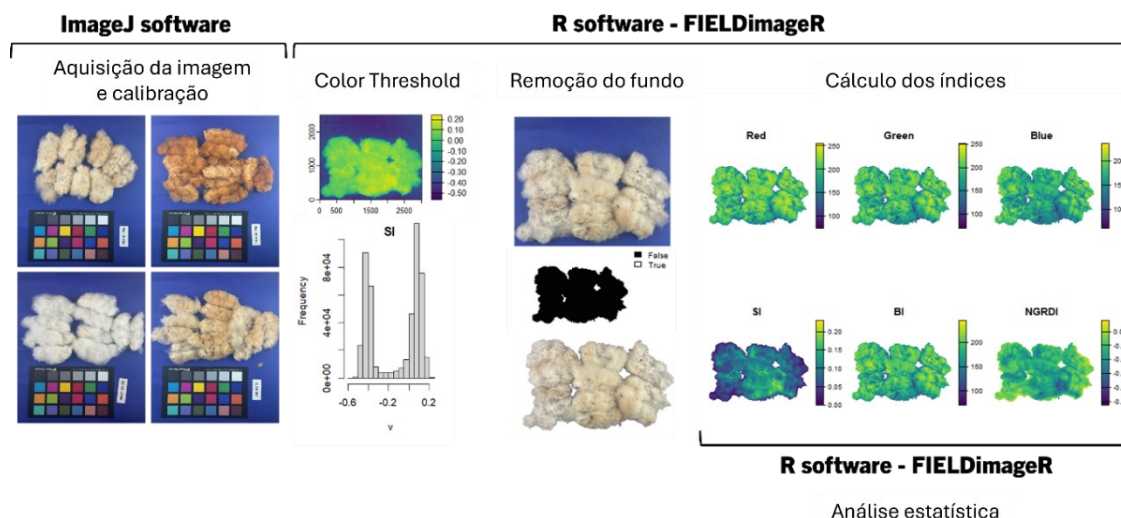


FIGURA 12 - Montagem Experimental: (i) aquisição e calibração da imagem, (ii) Color Threshold, (iii) remoção do fundo, (iv) cálculo dos índices e (v) análise estatística

### 1.3. Avaliação das características tecnológicas da fibra

As maçãs de cada terço de desenvolvimento da planta foram coletadas separadamente e beneficiadas com um descaroçador de 20 serras para obter a fibra do algodão. As fibras foram então devidamente embaladas e analisadas pelo Laboratório Minas Cotton, pertencente à Associação Mineira dos Produtores de Algodão (AMIPA). Um equipamento *High-Volume Instrument* (HVI) foi utilizado para analisar as características tecnológicas das fibras, que incluíram os seguintes parâmetros:

- Comprimento da fibra (mm) (UHML): o comprimento médio das fibras.
- Uniformidade de comprimento (%) (UI): a consistência do comprimento da fibra.
- Resistência à tração ( $\text{gf tex}^{-1}$ ) (STR): a força necessária para romper as fibras.
- Micronaire (MIC): relação entre a finura e a maturidade das fibras, expressas em uma unidade adimensional.
- Elongação (%) (ELG): a capacidade da fibra de esticar antes de romper.
- Maturidade (%) (MAT): a maturidade da fibra.
- SCI: o índice de fiação da fibra (*Spinning Consistency Index*).
- Índice de fibra curta (SF): o percentual de fibras curtas na amostra.
- Reflectância (RD): a capacidade da fibra de refletir a luz.
- Amarelamento (+b): a intensidade do amarelamento da fibra.

k. Umidade (%) (MST): a umidade da fibra.

#### 1.4. Análise estatística

Utilizando o software R (R Core Team, 2023), uma análise individual foi realizada para os índices com e sem calibração de imagem via Colorcard, considerando as maçãs coletadas em cada terço de desenvolvimento da planta. Em seguida, uma análise de variância conjunta foi realizada para avaliar a existência de diferenças entre os terços para as características avaliadas ( $p \leq 0,05$ ). Para a análise de variância conjunta, a seguinte fórmula foi utilizada:

$$Y_{ijk} = m + b_{j(c)} + g_i + a_k + (ga)_{ik} + \epsilon_{ij(k)}$$

Em que:

$m$  = Média geral de todas as observações.

$b_{j(c)}$  = Efeito do bloco  $j$  dentro do Colorcard  $c$ , que leva em consideração a variação devido aos blocos em cada uso do Colorcard.

$g_i$  = Efeito do genótipo  $i$ , ou seja, a contribuição do genótipo específico para o valor observado.

$a_k$  = Efeito do ambiente  $k$ , que captura a variação devido às diferenças entre os ambientes.

$(ga)_{ik}$  = Interação entre o genótipo  $i$  e o ambiente  $k$ , que representa o efeito conjunto entre essas duas variáveis.

$\epsilon_{ij(k)}$  = Erro experimental.

O mesmo procedimento de análise conjunta foi realizado para analisar se existia uma diferença significativa entre as médias de acordo com cada terço de desenvolvimento. Além disso, foram estimados os parâmetros genéticos de herdabilidade no sentido amplo ( $H^2$ ), variabilidade genética ( $\sigma^2_g$ ) e variabilidade ambiental ( $\sigma^2_e$ ).

As médias obtidas foram comparadas por meio do teste de Scott-Knott ( $p \leq 0,05$ ), e um teste de correlação de Pearson foi realizado, que mensura as associações lineares entre variáveis contínuas e expressa suas relações. Adicionalmente, a distância euclidiana foi calculada e, subsequentemente, um dendrograma foi desenvolvido com o agrupamento dos 17 genótipos avaliados.

## RESULTADOS E DISCUSSÃO

Foi observado um efeito significativo do uso do colorcard para a extração dos índices nas imagens ( $p \leq 0,01$ ). No entanto, não houve interação entre os índices de cada genótipo e o uso do colorcard para calibração (Tabela 4).

TABELA 4 - Análise de variância conjunta de genótipos de algodão de fibra colorida e branca em relação ao uso de fotos via color card, de acordo com os índices avaliados nos terços superior, médio e inferior do desenvolvimento da planta. Uberlândia-MG

FV	GL	QM Terço superior		
		SI	BI	NGRDI
Genótipo (G)	4	4.53**	17177.60**	31.90**
Colorcard (C)	1	0.14**	401.30**	0.67**
GxC	4	2.70 <sup>4ns</sup>	216.60 <sup>ns</sup>	0.13 <sup>ns</sup>
Resíduo	27	0.19	650.90	2.05
QM Terço médio				
Genótipo (G)	4	4.81**	18797.50**	35.29**
Colorcard (C)	1	0.15**	947.40**	0.04**
GxC	4	4.10 <sup>4ns</sup>	435.50 <sup>ns</sup>	0.45 <sup>ns</sup>
Resíduo	27	0.07	760.10	1.69
QM Terço inferior				
Genótipo (G)	4	4.81**	22145.00**	40.12**
Colorcard (C)	1	0.15**	267.10**	0.80**
GxC	4	4.10 <sup>4ns</sup>	3.80 <sup>ns</sup>	0.00 <sup>ns</sup>
Resíduo	27	0.07	456.80	0.68

Legenda: \*\*: significativo a 1% de probabilidade pelo teste F; ns: não significativo pelo teste F; FV: fator de variação; GL: graus de liberdade; QM: quadrado médio; SI: índice de saturação de inclinação espectral (transformado via  $\log(x \cdot 100)$ ); BI: índice de brilho; NGRDI: índice de diferença normalizada vermelho-verde (transformado via  $\sqrt{(x \cdot (-100))}$ ).

Ao realizar a calibração de imagem com correção de brilho e cor, as médias dos índices foram maiores para BI e SI e menores para o índice NGRDI. No entanto, como não houve interação com os genótipos, uma vez que a ordem de classificação dos genótipos não mudou com o uso do colorcard, para estimar as características de cor e categorização dos genótipos, o uso do colorcard não se mostrou essencial, considerando a diversidade de cores de fibra analisadas neste estudo (Tabela 4).

A análise revelou uma diferença estatisticamente significativa ( $p < 0,01$ ) entre as médias dos genótipos para todos os índices avaliados. Isso indica uma variação fenotípica substancial entre os genótipos de algodão em estudo. Além disso, uma interação notável foi observada entre

os genótipos e os terços de desenvolvimento para o índice de saturação de inclinação espectral (SI). Este achado sugere o potencial de empregar técnicas de fenotipagem de alto rendimento para identificar genótipos de algodão com cor de fibra mais saturada, particularmente ao considerar diferentes estágios de desenvolvimento da planta.

Todos os índices testados apresentaram valores de  $H^2$  acima de 0,8 que podem ser considerados altos e são atribuídos a características altamente herdáveis, o que possibilita a seleção em populações iniciais de melhoramento (Bonifácio *et al.*, 2015).

TABELA 5 - Análise de variância de genótipos de algodão de fibra colorida e branca em relação aos índices avaliados nos terços superior, médio e inferior do desenvolvimento da planta

FV	GL	QM		
		SI	BI	NGRDI
Genótipo	16	0,03**	23474,70**	48,08**
Terço	2	6,60**	171,00**	0,39**
Genótipo x Terço	32	0,16 <sup>ns</sup>	723,00 <sup>ns</sup>	1,21 <sup>ns</sup>
Resíduo	42	0,1676	767,00	1,72
$\sigma^2_g$		3,40 $10^{-3}$	363,35	1,25 $10^{-5}$
$\sigma^2_e$		2,50 $10^{-5}$	3,57	1,00 $10^{-4}$
$H^2$		0,9	0,9	0,8

Legenda: \*\*: significativo a 1% de probabilidade pelo teste F; ns: não significativo pelo teste F; FV: fator de variação; GL: graus de liberdade; QM: quadrado médio;  $\sigma^2_g$ : variabilidade genética;  $\sigma^2_e$ : variabilidade ambiental;  $H^2$ : herdabilidade; SI: índice de saturação de inclinação espectral (transformado via  $\log(x \cdot 100)$ ); BI: índice de brilho; NGRDI: índice de diferença normalizada vermelho-verde (transformado via  $\sqrt{(x \cdot (-100))}$ ).

A alta herdabilidade está associada à característica dominante da coloração da fibra, na qual a cor da fibra é governada por um gene, *GhTT2-3A*, localizado no cromossomo A07 (Zheng *et al.*, 2024). A cor marrom é parcialmente dominante sobre a cor branca, no entanto, no caso de outras cores, como a acinzentada, a coloração branca é dominante (Carvalho *et al.*, 2014). Nesse sentido, a avaliação via índices SI, BI e NGRDI pode auxiliar na seleção de genótipos em gerações iniciais, distinguindo genótipos com tonalidades mais saturadas, o que pode corresponder à homozigotidade do gene que atribui a característica de cor, considerando que genótipos com heterose para essa característica apresentam uma tonalidade de fibra menos intensa.

De acordo com o SI, um valor mais alto indica uma intensidade de cor de fibra mais forte, ou seja, as fibras brancas ou de tons mais claros apresentaram valores próximos de 0,00, enquanto fibras de cores mais intensas, como a BRS Rubi, apresentaram valores próximos de 0,20 (Tabela 6). Esse comportamento é inversamente proporcional quando se avalia o BI, no



qual as fibras brancas apresentam valores mais altos porque esse índice estima a luminosidade do material analisado. Para o NGRDI, as fibras de algodão colorido apresentaram valores negativos em comparação com as fibras brancas, em que quanto mais intensa a cor, menores os valores obtidos.

TABELA 6 - Médias do índice de brilho (BI), índice de saturação de inclinação espectral (SI) e índice de diferença normalizada vermelho-verde (NGRDI) de diferentes genótipos de algodão naturalmente colorido e branco

<b>Genótipo</b>	<b>SI</b>	<b>BI</b>	<b>NGRDI</b>
BRS Rubi	0,22a	153,04h	-0,10f
UFU-18	0,18b	162,30g	-0,06e
UFU-14	0,18b	161,90g	-0,06e
UFU-05	0,16c	168,04f	-0,05d
UFU-01	0,16c	167,04f	-0,05d
UFU-13	0,15c	160,30g	-0,05d
UFU-11	0,14d	169,01f	-0,05d
UFU-04	0,14d	166,71f	-0,04d
UFU-10	0,14d	169,26f	-0,05d
UFU-03	0,14d	174,17e	-0,04d
UFU-02	0,14d	169,18f	-0,05d
UFU-15	0,13d	170,13f	-0,04d
UFU-17	0,13d	171,37f	-0,05d
BRS Jade	0,11e	178,13d	-0,03c
BRS Topázio	0,10e	186,79b	-0,03c
BRS Verde	0,07f	182,88c	-0,01b
Suregrow 821	0,02g	207,56a	0,00a

Legenda: médias seguidas por letras minúsculas distintas na coluna diferem entre si pelo teste de Scott–Knott a 5% de probabilidade. SI: índice de saturação de inclinação espectral; BI: índice de brilho; NGRDI: índice de diferença normalizada vermelho-verde.

Com base no agrupamento observado, foi possível diferenciar os genótipos de acordo com a classe de cor já estabelecida: marrom-avermelhado, marrom, creme e branco. Também foi possível observar a variação de cor dos genótipos classificados com a cor de fibra marrom. Assim, a aplicação dos índices avaliados neste estudo pode contribuir para a seleção de diferentes intensidades da cor da fibra do algodão (Figura 13).




FIGURA 13 - Variação na cor e tonalidade da fibra de diferentes genótipos de algodão. A - BRS Rubi; B - UFU-18; C - UFU-13; D - UFU-10; E - UFU-11; F - UFU-15; G - BRS Jade; H - BRS Verde; I - SG 821. Uberlândia-MG, 2024

A fenotipagem por imagem digital RGB auxilia na avaliação da tonalidade da fibra, reduzindo a subjetividade desse processo, uma vez que mesmo avaliadores experientes podem apresentar variações em suas análises. Além disso, a necessidade de um profissional especializado e treinado para realizar essa avaliação torna o processo mais oneroso. Ao capturar a imagem via um sensor RGB, indivíduos sem experiência prévia com algodão de fibra naturalmente colorida podem realizar a avaliação de forma eficiente.

No entanto, alguns pontos exigem atenção, como a necessidade de um ambiente com iluminação controlada e difusa e a padronização da captura das imagens. Embora a avaliação visual realizada por um profissional treinado possa ser mais rápida, ela tende a ser menos objetiva e pode apresentar precisão reduzida ao longo do tempo devido à fadiga do avaliador.

Estudos conduzidos por Gonçalves *et al.* (2015) também utilizaram imagens digitais para compor um método analítico e análise multivariada para a discriminação e classificação

de quatro cultivares de algodão naturalmente colorido (BRS 200 Marrom, BRS Topázio, BRS Rubi e BRS Safira). Os autores mostraram que o uso da análise de componentes principais revelou a presença de padrões amostrais para cada uma das cultivares estudadas, indicando que o método proposto pode ser usado para a classificação eficiente de amostras de algodão naturalmente colorido de maneira simples e de baixo custo. Essas aplicações incluem a identificação de cultivares de algodão pela cor da fibra como forma de combater a falsificação de amostras tingidas no mercado.

Para as médias dos índices avaliados por terço, o terço superior apresentou valores de SI mais baixos e valores de BI mais altos do que os outros terços de desenvolvimento da planta (Tabela 7). Isso ocorre porque a cor da fibra é adquirida após a abertura das maçãs, sendo influenciada pela luz solar. Considerando que as maçãs do terço superior são as últimas a abrir, há um período mais curto de exposição à radiação solar e, conseqüentemente, uma menor intensidade da cor da fibra (Carvalho *et al.*, 2011).

TABELA 7 - Médias do índice de brilho (BI), índice de saturação de inclinação espectral (SI) e índice de diferença normalizada vermelho-verde (NGRDI) de acordo com a calibração de imagem via Colorcard

Terço de desenvolvimento	Colorcard	Índice		
		SI	BI	NGRDI
Superior	Com	0.15a	183.23a	-0.05b
	Sem	0.12b	178.23b	-0.04a
Médio	Com	0.15a	179.34a	-0.05b
	Sem	0.13b	175.56b	-0.04a
Inferior	Com	0.16a	179.34a	-0.05b
	Sem	0.12b	175.56b	-0.04a

Legenda: médias seguidas por letras minúsculas distintas na coluna diferem entre si pelo teste de Scott-Knott a 5% de probabilidade. SI: índice de saturação de inclinação espectral; BI: índice de brilho; NGRDI: índice de diferença normalizada vermelho-verde.

Para os genótipos de fibra naturalmente colorida, os índices estudados mostraram fortes correlações com as características tecnológicas da fibra. Especificamente, o BI exibiu coeficientes de determinação de 0,77, 0,80 e 0,88 para o índice de uniformidade (UI), resistência (STR) e comprimento da fibra (UHML), respectivamente. Essas correlações robustas sugerem que aumentos no BI estão associados a valores mais altos dessas importantes características de qualidade da fibra (Figura 14).




FIGURA 14 - Matriz de correlação para o índice de brilho (BI), saturação de inclinação espectral (SI) e diferença normalizada vermelho-verde (NGRDI) em relação às características tecnológicas da fibra

Legenda: índice de fiação da fibra (SCI); umidade seca (Mst, %); micronaire (Mic): a finura e a maturidade das fibras, expressas em uma unidade micronaire adimensional; maturidade (Mat, %): a maturidade da fibra; comprimento da fibra (UHML, mm): o comprimento médio das fibras; uniformidade de comprimento (UI, %): a consistência do comprimento da fibra; índice de fibra curta (SF); resistência à tração (Str, gf tex<sup>-1</sup>): a força necessária para romper as fibras; alongação (Elg, %): a capacidade da fibra de esticar antes de romper; reflectância (Rd); e amarelamento (+b): a intensidade do amarelamento da fibra.

Em contrapartida, o índice SI apresentou correlações negativas fortes com essas características, UHML (-0,85), UI (-0,71) e STR (-0,75). Ao avaliar a correlação entre os índices espectrais, também observamos altos valores. O BI e o NGRDI foram negativamente correlacionados com o SI, com valores de -0,94 e -0,97, respectivamente. Além disso, uma correlação positiva significativa foi observada entre o BI e o NGRDI.

A correlação entre os índices BI e NGRDI pode ser explicada por suas respectivas funções e aplicações. O BI estima a quantidade de branco presente na imagem, refletindo a luminosidade da cor da fibra, sendo que quanto mais clara a fibra, maiores os valores observados neste índice (Richardson; Wiegand, 1977). Por outro lado, o NGRDI mede a diferença entre as bandas de vermelho e verde e é eficaz para distinguir as tonalidades de fibra analisadas. Este índice é amplamente utilizado para avaliar a tolerância ao déficit hídrico e o estado de saúde fisiológica das plantas. Uma maior reflectância de vermelho indica um pior estado fisiológico da planta. Portanto, ao aplicar o NGRDI, foi possível estimar a quantidade de material vermelho presente na fibra (Tucker, 1979; Elazab *et al.*, 2016).

Assim, quando apenas o NGRDI é utilizado, é possível classificar a cor da fibra e avaliar sua variabilidade dentro das populações. Este tipo de avaliação permite a seleção de diferentes tonalidades de fibra dentro de um programa de melhoramento, especialmente considerando a limitada disponibilidade de cores de fibra.

Na análise de divergência genética, vários métodos multivariados são utilizados, incluindo a análise de componentes principais, a análise de variáveis canônicas e métodos de

agrupamento. A escolha do método mais apropriado depende dos objetivos da pesquisa, da facilidade de análise e da natureza dos dados coletados (Cruz *et al.*, 1994). Cada um desses métodos oferece diferentes perspectivas sobre a divergência genética entre as amostras estudadas. Em programas de melhoramento genético, o uso de estimativas de dissimilaridade é relevante porque fornece informações sobre o grau de similaridade ou diferença entre dois ou mais genótipos, informações cruciais na seleção de parentais para a geração de novas populações (Cruz; Ferreira; Pessoni, 2011).

Assumindo que metade da amplitude da distância seja o ponto de corte no dendrograma (Figura 15), três grupos são obtidos, nos quais os genótipos SG821, BRS Jade e BRS Topázio são agrupados, mesmo apresentando variações na tonalidade da fibra. O segundo grupo foi composto pela cultivar BRS Rubi e pelos genótipos UFU 10, UFU 13, UFU 04 e UFU 18, que apresentaram tonalidade de fibra mais intensa; o terceiro grupo incluiu os demais genótipos, cuja cor da fibra variou de creme a marrom e verde em tons mais suaves.




FIGURA 15 - Mapa de calor resultante da análise de cluster de 17 genótipos de algodão obtidos pelo método hierárquico do vizinho mais próximo, com a distância euclidiana utilizada como medida de dissimilaridade. Uberlândia-MG, 2024

Assim, o cruzamento desses genótipos entre os grupos pode produzir populações mais segregantes em termos de tonalidade de fibra e características correlacionadas com a qualidade da fibra. A divergência entre eles mostra a ampla variabilidade na população do programa em questão e sugere a possibilidade de seleção de novas linhas superiores.

Ao realizar a análise de regressão entre os índices vegetativos estudados e as características intrínsecas da fibra, observou-se que os genótipos apresentaram altos coeficientes de determinação ( $R^2 > 77\%$ ) quando o índice de brilho (BI) foi utilizado para as características de UI, STR e UHML. Estes resultados sugerem que o índice pode ser utilizado como uma ferramenta para estimar essas características intrínsecas da fibra (Figura 16).

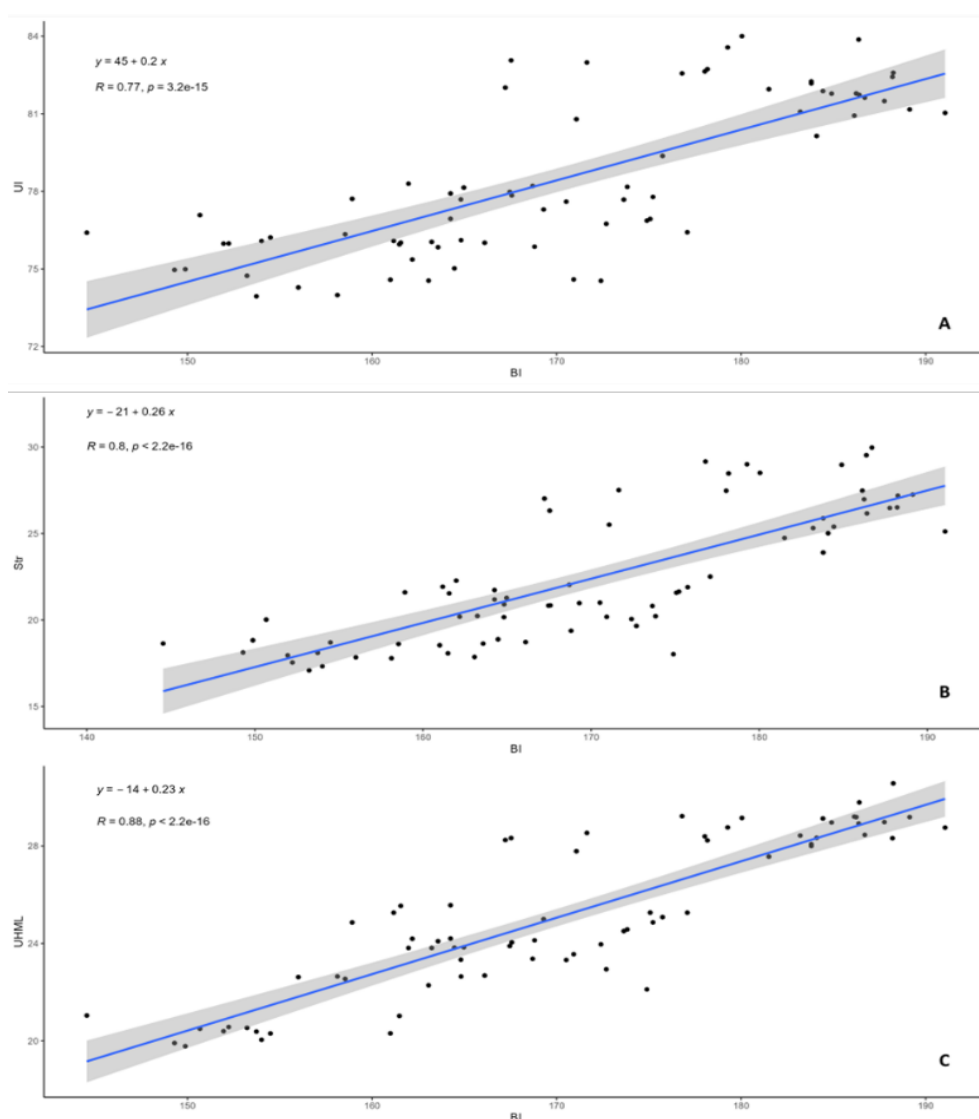


FIGURA 16 - Análise de regressão linear para as características de uniformidade de comprimento (UI) (A), resistência da fibra (STR) (B) e comprimento da fibra (UHML) (C) dos genótipos de algodão com fibras marrons naturalmente coloridas em função do índice de brilho (BI) obtido de imagens RGB

O uso da fenotipagem de alto rendimento tem se mostrado uma ferramenta importante para análises que apoiam a tomada de decisões em programas de melhoramento genético, permitindo que dados sejam obtidos de forma rápida, precisa e confiável. A associação destas tecnologias com indicadores de qualidade da fibra de algodão possibilita estimar tais características em larga escala de forma rápida, antecipada e não destrutiva (Xu *et al.*, 2023).

Os resultados apresentados aqui demonstram a possibilidade de uso de imagens para caracterizar fibras de algodão naturalmente colorido, e o aumento do número de estudos para essa finalidade é essencial para melhorar a escalabilidade do uso das fibras coloridas no mercado. Paralelamente, trabalhos que visam a melhoria da qualidade das características tecnológicas da fibra também são de suma importância para uma maior aceitação e aplicabilidade do algodão naturalmente colorido na indústria têxtil.

## CONCLUSÃO

A fenotipagem por imagem se mostrou um método eficaz para avaliar a intensidade da cor em fibras de algodão naturalmente coloridas. O índice de saturação de inclinação espectral (SI) emergiu como o método mais confiável para distinguir genótipos com base na saturação da cor da fibra.

O estudo revelou uma variação notável na coloração da fibra entre as diferentes partes da planta. As maçãs colhidas do terço superior das plantas apresentaram coloração de fibra menos intensa em comparação com as de outros terços, com uma variação de 6,25%.

O uso do colorcard não se mostrou essencial, considerando a diversidade de cores de fibra analisadas neste estudo.



## REFERÊNCIAS

- ABRAPA – Associação Brasileira dos Produtores de Algodão. *BI Cotton Brazil*, 2024. Disponível em: <https://cottonbi.com.br/>. Acesso em: 11 dez 2024.
- BAC, C.; HEMMING, J.; VAN HENTEN, E. Robust pixel-based classification of obstacles for robotic harvesting of sweet-pepper. **Computers and Electronics in Agriculture**, v. 96, p.148–162, 2013. DOI: <https://doi.org/10.1016/j.compag.2013.05.004>.
- BONIFÁCIO, D. O. C.; MUNDIM, F. M.; SOUSA, L. B. Variabilidade genética e coeficiente de determinação em genótipos de algodoeiro quanto a qualidade de fibra. **Revista Verde**, v. 10, n. 3, p. 66-71, 2015. DOI: <https://doi.org/10.18378/rvads.v10i3.3618>.
- CARAZA-HARTER, M. V.; ENDELMAN, J. B. Image-based phenotyping and genetic analysis of potato skin set and color. **Crop Science**, v. 60, p. 202–210, 2020. DOI: <https://doi.org/10.1002/csc2.20093>.
- CARDOSO, G. D.; ALVES, P. L. C. A.; BELTRÃO, N. E. M.; DO VALE, L. S. Períodos de interferência das plantas daninhas em algodoeiro de fibra colorida ‘BRS Safira’. **Revista Ciência Agronômica**, v. 3, p. 456-462, 2010. DOI: <https://doi.org/10.1590/S1806-66902010000300019>.
- CARVALHO, L. P.; ANDRADE, F. P.; SILVA FILHO, J. L. Cultivares de algodão colorido no Brasil. **Revista Brasileira de Oleaginosas e Fibrosas**, Campina Grande, v. 15, p. 37–44, 2011. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/910145/1/488rbof15127362011.pdf>. Acesso em: 10 ago. 2025.
- CARVALHO, L. P.; FARIAS, F. J. C. Inheritance of different fiber color in cotton (*Gossypium barbadense* L.). **Crop Breeding and Applied Biotechnology**, v. 4, p. 256-260, 2014. DOI: <https://doi.org/10.1590/1984-70332014v14n4n40>.
- CARVALHO, L. P.; FARIAS, F. J. C.; RODRIGUES, J. I. S. Selection for increased fiber length in cotton progenies from acala and nonacala types. **Crop Science**, v. 55, p. 985-991, 2015. DOI: <https://doi.org/10.2135/cropsci2014.08.0547>.
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **AgroConab**, 2024. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos>. Acesso em: 10 ago. 2025.
- CRUZ, C. D.; CARVALHO, S. P.; VENCOSKY, R. Estudos sobre divergência genética. II Eficiência da predição do comportamento de híbridos com base na divergência de progenitores. **Revista Ceres**, Viçosa-MG, v. 41, p. 183-190, 1994. Disponível em: <https://ojs.ceres.ufv.br/ceres/article/view/2070>. Acesso em 11 ago. 2025.
- CRUZ, C. D.; FERREIRA, F. M.; PESSONI, L. A. **Biometria aplicada ao estudo da diversidade genética**. Viçosa-MG: Editora UFV, 2011. Disponível em: <https://www.researchgate.net/profile/Fabio-Ferreira->

[18/publication/288608812\\_Diversidade\\_genetica\\_baseada\\_em\\_informacoes\\_fenotipicas/links/631188ce5eed5e4bd13bfd8e/Diversidade-genetica-baseada-em-informacoes-fenotipicas.pdf](https://doi.org/10.18888/288608812_Diversidade_genetica_baseada_em_informacoes_fenotipicas/links/631188ce5eed5e4bd13bfd8e/Diversidade-genetica-baseada-em-informacoes-fenotipicas.pdf). Acesso em 11 ago. 2025.

ESCADAFAL, R.; BELGHITH, A.; BEN-MOUSSA, H. Indices spectraux pour la télédétection de la dégradation des milieux naturels en Tunisie aride. *In: Symposium international sur les mesures physiques et signatures en télédétection* (p. 253–259), 1994. Centre National d'Étude Spatiale.

ELAZAB, A.; ORDÓÑEZ, R. A.; SAVIN, R.; SLAFER, G. A.; ARAUS, J. L. Detecting interactive effects of N fertilization and heat stress on maize productivity by remote sensing techniques. *European Journal of Agronomy*, v. 73, p. 11-24, 2016. DOI: <https://doi.org/10.1016/j.eja.2015.11.010>.

GONÇALVES, M. I. S.; VILAR, W. T. S.; MEDEIROS, E. P.; PONTES, M. J. C. A novel strategy for the classification of naturally colored cotton fibers based on digital imaging and pattern recognition techniques. *Analytical Methods*, v. 7, p. 5869 – 5875, 2015. DOI: <https://doi.org/10.1039/C5AY01116G>.

HASSAN, H.; EL-RAHMAN, A. A.; ATTIA, M. Color properties of olive fruits during its maturity stages using image analysis. *In: AIP Conference Proceedings: Vol. 1400. International Conference on Modeling, Simulation and Control* (pp. 101–106), 2011. American Institute of Physics. DOI: <https://doi.org/10.1063/1.3663057>.

MATIAS, F.; CARAZA-HARTER, M.; ENDELMAN, J. FIELDimageR: An R package to analyze orthomosaic images from agricultural field trials. *The Plant Phenome Journal*, v. 3, p. 1-6, 2020. DOI: <https://doi.org/10.1002/ppj2.20005>.

MOJARAVSKI, D.; MAGALHÃES, P. S. G. Comparative Evaluation of Color Correction as Image Preprocessing for Olive Identification under Natural Light Using Cell Phones. *AgriEngineering*, v. 6, p. 155-170, 2024. DOI: <https://doi.org/10.3390/agriengineering6010010>.

NAOUMKINA, M.; HINCHLIFFE, D. J.; THYSSEN, G. N. Naturally, colored cotton for wearable applications. *Frontiers in Plant Science*, v. 15, p. 1-7, 2024. DOI: <https://doi.org/10.3389/fpls.2024.1350405>

Penna, J. C. V. Melhoramento do algodão. *In: A. Borém (Ed.). Melhoramento de espécies cultivadas*. Viçosa-MG: Editora UFV, 2005, p. 15-53.

R Core Team. *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, 2023. DOI: <https://www.R-project.org/>.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, v. 43, p. 1541-1552, 1977. Disponível em: [https://www.asprs.org/wp-content/uploads/pers/1977journal/dec/1977\\_dec\\_1541-1552.pdf](https://www.asprs.org/wp-content/uploads/pers/1977journal/dec/1977_dec_1541-1552.pdf). Acesso em: 11 jul. 2025.

SCHNEIDER, C.; RASBAND, W.; ELICEIRI, K. NIH Image to ImageJ: 25 years of image analysis. **Nature Methods**, v. 9, p. 671–675, 2012. DOI: <https://doi.org/10.1038/nmeth.2089>.

Tucker, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, p. 127-150, 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). **Production – Cotton**, 2024. Disponível em: <https://fas.usda.gov/data/production/commodity/2631000> Acesso em: 2 nov. 2025.

XU, W.; YANG, W.; CHEN, P.; ZHAN, Y.; ZHANG, L.; LAN, Y. Cotton fiber quality estimation based on machine learning using time series UAV remote sensing data. **Remote Sensing**, v. 15, p. 1-19, 2023. DOI: <http://dx.doi.org/10.3390/rs15030586>.

ZHENG, L.; ZHANG, J.; HE, H.; MENG, Z.; WANG, Y.; GUO, S.; LIANG, S. Anthocyanin gene enrichment in the distal region of cotton chromosome A07: mechanisms of reproductive organ coloration. **Frontiers in Plant Science**, v. 15, p. 1-12, 2024. DOI: <https://doi.org/10.3389/fpls.2024.1381071>.

ZHAO, Y.; GONG, L.; ZHOU, B.; HUANG, Y.; LIU, C. Detecting tomatoes in greenhouse scenes by combining AdaBoost classifier and color analysis. **Biosystems Engineering**, v. 148, p. 127–137, 2016. DOI: <https://doi.org/10.1016/j.biosystemseng.2016.05.001>.

ZONTA, J. H.; SOFIATTI, V.; BEZERRA, J. R. C.; BRANDÃO, Z. N. Yield of cotton cultivars under different irrigation depths in the Brazilian semi-arid region. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.19, n.8, p.748–754, 2015. DOI: <http://dx.doi.org/10.1590/1807-1929/agriambi.v19n8p748-754>.